

BAB I

PENDAHULUAN UMUM

1.1 Latar Belakang

Wilayah Pengelolaan Perikanan Negara Republik Indonesia (WPPNRI) merupakan kawasan perairan yang dimanfaatkan untuk berbagai aktivitas perikanan, termasuk penangkapan ikan, budidaya, konservasi, serta penelitian dan pengembangan melalui kebijakan pengelolaan perikanan yang diatur dalam Permen KP No. 18/PERMEN-KP/2014. Salah satu WPP yang memiliki potensi sumber daya ikan (SDI) pelagis besar yang signifikan adalah WPP 714, yang menempati urutan ketiga sebagai wilayah dengan potensi ikan pelagis besar tertinggi di Indonesia (Kepmen KP No. 19 Tahun 2022). Potensi perikanan di WPP 714 didominasi oleh beberapa spesies pelagis besar yang memiliki nilai ekonomi tinggi, yaitu cakalang (*Katsuwonus pelamis*), madidihang (*Thunnus albacares*), dan tuna mata besar (*Thunnus obesus*), yang menjadi komoditas unggulan industri perikanan nasional maupun ekspor. Namun, meningkatnya intensitas penangkapan tanpa pengelolaan yang berkelanjutan telah menyebabkan fluktuasi stok dan bahkan eksploitasi berlebih (over-exploitation) pada beberapa spesies. Penelitian sebelumnya menunjukkan bahwa aktivitas penangkapan yang tidak terkendali dapat memberikan tekanan terhadap stok ikan (Nugroho & Budianto, 2021), sehingga diperlukan strategi pengelolaan yang berbasis ilmiah untuk menjaga keberlanjutan sumber daya perikanan (Balitbang KP, 2016).

Selain faktor antropogenik seperti intensitas penangkapan dan Illegal, Unreported, and Unregulated Fishing (IUUF), kondisi oseanografis di perairan WPP 714 juga berperan penting dalam menentukan kelimpahan dan distribusi ikan pelagis. Faktor-faktor oseanografi seperti suhu permukaan laut (Sea Surface Temperature/SST), kedalaman dan kecepatan arus, serta konsentrasi klorofil-a (Chlo-a) telah terbukti berpengaruh terhadap hasil tangkapan ikan (Haruna et al., 2019; Tangke et al., 2011). Misalnya, penelitian menunjukkan bahwa hotspot penangkapan cakalang terjadi pada bulan Oktober ketika suhu laut optimal berkisar 29,5–31,0°C dan konsentrasi Chlo-a 0,15–0,28 mg/m³ (Zainuddin et al., 2023). Demikian pula, tuna mata besar lebih sering ditemukan di perairan yang lebih dalam dengan karakteristik oseanografi tertentu (Vaihola et al., 2023).

Pola seasonal dari faktor oseanografi seperti upwelling, yang terjadi pada musim Timur di Laut Banda, turut mempengaruhi ketersediaan ikan di WPP 714. Proses ini menyebabkan perubahan sifat hidrologi laut yang memengaruhi distribusi plankton dan, secara tidak langsung, habitat ikan pelagis (Yusuf & Wouthuyzen, 1997). Oleh karena itu, pemahaman mengenai pola seasonal faktor oseanografi sangat penting dalam menentukan strategi penangkapan yang lebih berkelanjutan. Madidihang di WPP 714 berlangsung sepanjang tahun, dengan puncak terjadi pada Januari–April dan Oktober–Desember (Mallawa & Mahfud, 2009). Namun, praktik penangkapan yang tidak produktif dan menjadi tantangan utama (Mallawa & Mahfud, 2009), sehingga diperlukan informasi yang lebih akurat mengenai zona potensi penangkapan. Untuk itu, diperlukan pendekatan berbasis data dalam menentukan fishing ground bagi spesies pelagis besar, termasuk cakalang,



madidihang, dan tuna mata besar.

Dalam beberapa tahun terakhir, perkembangan teknologi telah membuka peluang bagi penerapan Machine Learning (ML) dalam analisis faktor oseanografi guna meningkatkan akurasi prediksi zona potensial penangkapan ikan secara spasio-temporal. Model berbasis ML memungkinkan analisis hubungan antara faktor-faktor teknis perikanan tangkap dan faktor oseanografi untuk menghasilkan prediksi dengan akurasi tinggi (Moertini & Adithia, 2020). Sejumlah metode ML telah diterapkan dalam penelitian perikanan, termasuk Random Forest (RF), Boosted Regression Tree (BRT), Generalized Additive Model (GAM), Empirical Cumulative Distribution Function (ECDF), k-means clustering, serta Maximum Entropy (MaxEnt) (Pritalia, 2022; Adriani & Ridwang, 2020). Pemanfaatan ML dalam riset oseanografi telah berkembang sejak tahun 1988 dalam wave model (WAMDI Team, 1988), analisis marine acoustics (Steinberg et al., 1991; Caiti & Parisini, 1994), hingga fish classification berbasis Principal Component Analysis (Turk & Pentland, 1991; Mika et al., 1999). Dalam perikanan, ML digunakan untuk memprediksi zona optimal penangkapan ikan dengan mempertimbangkan berbagai parameter oseanografi dan teknis.

Penelitian ini bertujuan untuk mengoptimalkan pemanfaatan sumber daya ikan pelagis besar di WPP 714 melalui analisis hubungan antara faktor oseanografi dan hasil tangkapan ikan. Tujuan utama penelitian ini meliputi (1) optimalisasi aktivitas kapal perikanan tangkap dengan menganalisis dinamika perikanan di WPP 714 berdasarkan data historis dan faktor oseanografi, serta (2) optimalisasi parameter oseanografi untuk menghasilkan prediksi area potensial penangkapan ikan pelagis secara spasio-temporal. Untuk mencapai tujuan tersebut, penelitian ini akan menggunakan pendekatan pemodelan berbasis ML dengan berbagai metode untuk membandingkan performa prediksi serta mengevaluasi akurasi dan Goodness of Fit dari model yang dihasilkan. Hasil akhir penelitian diharapkan dapat memberikan rekomendasi berbasis data untuk mendukung pengelolaan perikanan tangkap yang lebih efektif dan berkelanjutan di WPP 714.

Penelitian ini akan mencakup beberapa aspek utama yang dibahas dalam bab-bab berikutnya. BAB 2 akan membahas pola seasonal faktor-faktor oseanografi yang mempengaruhi distribusi ikan di WPP 714, memberikan dasar ilmiah dalam memahami dinamika perairan. BAB 3 akan mengkaji dinamika perikanan tangkap, termasuk pola penangkapan dan faktor teknis yang berperan dalam hasil tangkapan ikan pelagis besar. BAB 4 akan berfokus pada pemodelan faktor-faktor oseanografi menggunakan pendekatan ML untuk mendukung prediksi zona potensial penangkapan ikan. BAB 5 akan menyajikan pemetaan lokasi optimum penangkapan ikan, yang merupakan hasil akhir dari pemodelan dan analisis data yang dilakukan dalam penelitian ini. Selanjutnya, BAB 6 menyajikan pembahasan umum yang merangkum semua pembahasan dari semua BAB. Secara skematis digambarkan sebagaimana Gambar 1.1. berikut:




Gambar 1.1 Desain Penelitian

Dengan adanya pendekatan ilmiah berbasis data dan teknologi, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam perumusan strategi pengelolaan perikanan yang lebih efektif di WPP 714. Melalui pemanfaatan pemodelan ML, nelayan dapat memperoleh informasi yang lebih akurat mengenai zona potensial penangkapan ikan, sehingga kegiatan perikanan dapat berlangsung secara efisien, berkelanjutan, dan berbasis data ilmiah.

1.2 Studi Area Penelitian

Penelitian ini dilaksanakan pada bulan Januari 2023 - Desember 2024. Lokasi penelitian meliputi WPP 714, yang terdiri dari 5 provinsi, yaitu Sulawesi Tengah, Sulawesi Tenggara, Nusa Tenggara Timur, Maluku, dan Maluku Utara serta 24 kabupaten/kota, yang meliputi 3 (tiga) kabupaten di NTT (Alor, Lembata, dan Flores Timur); 8 (delapan) kabupaten/kota di Sultra (Buton, Muna, Konawe, Konawe Selatan, Bombana, Wakatobi, kota Kendari, dan kota Bau-bau); 2 (dua) kabupaten di Sulteng (Banggai Kepulauan, Banggai); 10 (sepuluh) kabupaten/kota di Maluku (Buru, Buru Selatan, Maluku Tenggara, Maluku Tenggara Barat, Maluku Tengah, Maluku Barat Daya, Seram Bagian Barat, Seram Bagian Timur, Kota Ambon, dan Kota Tual); dan 1 (satu) kabupaten di Maluku Utara (Kepulauan Sula). Area WPP 714 dapat dilihat pada gambar 1.2 berikut.





Gambar 1.2 Peta Lokasi Penelitian

Lokasi WPP 714 merupakan salah satu area pengelolaan perairan yang cukup menarik perhatian, tidak hanya bagi para nelayan pribumi, tapi juga nelayan asing. Tidak hanya itu, para periset juga menaruh minat yang cukup besar dalam kajian-kajian terkait WPP 714, tidak kurang dari 21 survey telah dilakukan di lokasi ini, sejak 1984 hingga Mei 2018, serta berbagai publikasi hasil-hasil penelitian.

Penelitian ini melakukan kajian pada tiga jenis ikan pelagis, yakni ikan cakalang (*Katsuwonus pelamis*), tuna madidihiang (*Thunnus albacares*), dan tuna mata besar (*Thunnus obesus*). Ketiga jenis ikan ini walaupun merupakan ikan pelagis, tetapi memiliki sejumlah perbedaan, sebagaimana ditunjukkan pada Tabel 1.1 berikut.

Tabel 1.1 Perbedaan madidihiang, cakalang, dan tuna mata besar

Aspek	Madidihiang	Cakalang	Tuna Mata Besar
Nama Ilmiah	<i>Thunnus albacares</i> (Swimmer et al., 2004)	<i>Katsuwonus pelamis</i> (Swimmer et al., 2004)	<i>Thunnus obesus</i> (Swimmer et al., 2004)
Nama Umum	Yellowfin Tuna, Madidihiang (Artetxe-Arrate et al., 2021)	Skipjack Tuna, Cakalang (Artetxe-Arrate et al., 2021)	Bigeye Tuna, Tuna Mata Besar (Artetxe-Arrate et al., 2021)
	Tubuh ramping, punggung biru tua metalik, garis kuning di sepanjang sisi, dan sirip punggung dan kuning (Schaefer & Fuller, 2013)	Bodi ramping, punggung biru keunguan tua, dan empat hingga enam pita gelap yang membentang secara horizontal di sepanjang sisi	Tubuh yang kuat, punggung biru tua metalik, dan kepala besar dengan mata besar (Schaefer & Fuller, 2013)



(Schaefer & Fuller, 2013)			
Ukuran	Hingga 2,4 meter, dan berat hingga 200 kg (Matsumoto et al., 2016)	Hingga 1 meter, dan berat mencapai 34.5 kg (Matsumoto et al., 2016)	Hingga 2.5 meter, dan berat mencapai 210 kg (Matsumoto et al., 2016)
Habitat	Zona epipelagic, dekat permukaan hingga kedalaman 100 meter (Schaefer et al., 2009)	Zona epipelagik ke mesopelagis, dari permukaan hingga kedalaman 260 meter (Schaefer et al., 2009)	Zona mesopelagis, dari kedalaman 200 hingga 500 meter (Schaefer et al., 2009)
Distribusi	Samudra tropis dan subtropis di seluruh dunia (Bushnell et al., 1990)	Perairan tropis dan subtropis dari semua lautan (Bushnell et al., 1990)	Samudra tropis dan subtropis di seluruh dunia (Bushnell et al., 1990)
Makanan	Ikan, cumi-cumi, dan krustasea (Roger, 1994)	Ikan, krustasea, dan moluska (Roger, 1994)	Ikan, cumi-cumi, dan krustasea (Roger, 1994)
Karakteristik Reproduksi	Bertelur di perairan tropis, dengan puncak musim pemijahan bervariasi menurut wilayah (Stéquert et al., 2001)	Bertelur sepanjang tahun di perairan hangat, dengan puncak di musim tertentu tergantung pada wilayahnya (Stéquert et al., 2001)	Bertelur di perairan tropis, biasanya selama musim panas (Stéquert et al., 2001)
Nilai Ekonomi	Sangat bernilai tinggi untuk sashimi, steak, dan tuna kalengan (Bojolly et al., 2017)	Penting untuk tuna kalengan dan hidangan tradisional (Boughattas et al., 2019)	Sangat dihargai untuk sashimi, steak, dan tuna kalengan (Bojolly et al., 2017)
Status Konservasi	Hampir Terancam (Artetxe-Arrate et al., 2021)	Tidak Terancam (Artetxe-Arrate et al., 2021)	Rentan (Artetxe-Arrate et al., 2021)

Tabel di atas membandingkan tiga spesies tuna utama: madidihang, cakalang, dan tuna mata besar, dari berbagai aspek. Madidihang dan tuna mata an yang lebih besar dibandingkan cakalang, dengan distribusi ran tropis dan subtropis di seluruh dunia. Ketiga spesies ini n yang serupa, yaitu ikan, cumi-cumi, dan krustasea, serta di perairan tropis. Namun, mereka berbeda dalam habitat ang di zona epipelagis, cakalang di zona epipelagis hingga na mata besar di zona mesopelagis. Dari segi nilai ekonomi,



ketiganya sangat penting, terutama untuk produk sashimi, steak, dan tuna kalengan, meskipun status konservasi mereka bervariasi; madidihang hampir terancam, cakalang tidak terancam, dan tuna mata besar masuk kategori rentan. Perbedaan karakteristik ini menunjukkan pentingnya strategi pengelolaan yang berbeda untuk setiap spesies guna menjaga keberlanjutan populasi mereka. Sejumlah penelitian telah dilaksanakan di lokasi WPP 714, baik terkait kajian ikan cakalang, tuna madidihang, dan tuna mata besar. Tabel 1.2 berikut adalah hasil-hasil kajian untuk cakalang.

Tabel 1.2 Hasil riset *Katsuwonus pelamis* di WPP 714

No	Uraian	Temuan	Sumber
1	Kegiatan Perikanan Tangkap	Perikanan Cakalang di WPP 714 didominasi oleh penggunaan pukat cincin dan jaring insang dengan penekanan pada pengelolaan sumber daya berkelanjutan.	Haruna et al., 2021
		Lokasi utama penangkapan Cakalang berada di perairan sekitar Pulau Kei, Pulau Tanimbar, dan Laut Banda yang kaya akan stok ikan pelagis.	Mawardi et al., 2020
		Penggunaan teknik penangkapan dengan kapal pukat dan jaring insang yang dioptimalkan melalui pemantauan stok ikan dan regulasi kuota tangkap.	Nasution et al., 2019
		Musim penangkapan Cakalang mencapai puncaknya antara Juni hingga Oktober, dengan variasi tangkapan yang dipengaruhi oleh perubahan iklim lokal.	Wijaya et al., 2022
		Penggunaan alat tangkap pukat cincin dan jaring insang diadaptasi dengan teknologi yang ramah lingkungan dan efisien untuk menjaga keberlanjutan tangkapan.	Haruna et al., 2021
	Biogeografis	Di perairan WPP 714, suhu optimal untuk	Yusuf et al., 2021



	penangkapan Cakalang berkisar antara 26-29°C. SST di wilayah ini memengaruhi distribusi ikan yang mendukung hasil tangkapan yang lebih tinggi.	
	Konsentrasi Chlo-a di perairan WPP 714 berhubungan dengan tingginya ketersediaan pakan alami, yang secara langsung berdampak pada kelimpahan ikan Cakalang di wilayah tersebut.	Rahardjo et al., 2019
	Kecepatan arus laut di WPP 714 yang berada di bawah 0,3 m/s menciptakan kondisi yang ideal untuk migrasi Cakalang, meningkatkan efektivitas penangkapan di wilayah ini.	Syahputra et al., 2020
	Salinitas perairan WPP 714 yang berkisar antara 33-35 PSU ditemukan ideal untuk habitat Cakalang, dengan tingkat salinitas tersebut mendukung produktivitas hasil tangkapan.	Nugroho et al., 2022
	Kedalaman lebih dari 200 meter di perairan WPP 714, bersama dengan faktor oseanografi lainnya, memberikan kondisi yang mendukung peningkatan populasi dan penangkapan Cakalang.	Prasetyo et al., 2018
 elling	Upwelling di perairan Laut Banda pada WPP 714 meningkatkan produktivitas perairan yang kaya nutrisi, sehingga mendukung peningkatan stok ikan Cakalang yang tertarik ke area ini selama periode upwelling.	Marpaung et al., 2022

4	Nursery Ground	Perairan selatan dan tenggara di WPP 714, khususnya sekitar Pulau Kei dan Tanimbar, berfungsi sebagai area nursery yang penting untuk Cakalang muda sebelum mereka berpindah ke perairan yang lebih dalam.	Syamsul et al., 2019
5	Distribusi Juvenil	Juvenil Cakalang cenderung terkonsentrasi di perairan Laut Banda selama musim tertentu, terutama saat suhu dan arus mendukung kondisi ideal bagi pertumbuhan dan kelangsungan hidup mereka.	Yusuf et al., 2021
6	Dampak Illegal Fishing	Aktivitas illegal fishing di WPP 714 menyebabkan tekanan yang signifikan pada populasi Cakalang, terutama pada musim migrasi mereka menuju area penangkapan utama.	Wibowo et al., 2020
7	Morfometrik	Studi morfometrik menunjukkan bahwa Cakalang di perairan WPP 714 memiliki ukuran tubuh yang lebih besar selama musim puncak migrasi, menunjukkan pertumbuhan yang baik di lingkungan oseanografis tersebut.	Hakim et al., 2018

Penelitian di WPP 714 menunjukkan perikanan Cakalang didominasi oleh penggunaan pukat cincin dan jaring insang dengan fokus pada pengelolaan berkelanjutan. Perairan di sekitar Pulau Kei, Pulau Tanimbar, dan Laut Banda menjadi lokasi utama penangkapan, didukung oleh kondisi oseanografis seperti suhu 26-29°C, salinitas 33-35 PSU, dan arus rendah yang mendukung migrasi



Laut Banda meningkatkan stok ikan, sementara perairan ra berfungsi sebagai nursery ground bagi juvenil Cakalang. ing memberikan tekanan signifikan pada populasi. Studi jukkan pertumbuhan tubuh optimal selama musim migrasi, nya strategi pengelolaan berkelanjutan untuk menjaga g di wilayah ini. Untuk kajian tuna madidihang, khususnya di 4) dapat dilihat pada tabel 1.3 berikut.

Tabel 1.3 Hasil riset *Thunnus albacares* di WPP 714

No	Uraian	Temuan	Sumber
1.	Kegiatan Perikanan Tangkap	Perikanan Pukat Cincin Skala Kecil Tipe Satu dan Dua Kapal Dalam Zona Penangkapan Ikan Terukur di WPP-NRI 714 di Ohoi Wirin (Pulau Kei Kecil bagian barat)	Picaulima et al., 2022
		Penangkapan ikan pada Kawanan Lumba-lumba dan rumpon. Lokasi belakang Pulau Tiga, sekitar bagian atas Tanjung Nusaniwe, sekitar Pulau Din dan dekat Negeri Assilulu. Kelompok nelayan di Negeri Laha mempunyai daerah penangkapan di Buru, Nusa Laut, Laut Banda, Pulau Tujuh. Sedangkan nelayan yang berada di Negeri Latuhalat mempunyai daerah penangkapan di sekitar Perairan Latuhalat hingga Negeri Allang, Nusa Laut dan Negeri Oma (Pulau Haruku).	Tomasila et al., 2020
		Daerah penangkapan ikan: unit penangkapan purse seine dan bagan apung di perairan bagian Timur Sulawesi Tenggara.	Bubun et al., 2014
		Daerah penangkapan ikan pelagis besar di perairan ini terdapat di hampir seluruh WPP Laut Banda terutama di sekitar gugusan pulau-pulau yang ada di Laut Banda seperti Pulau Buru, Pulau Banda, Pulau Yamdena dan sekitar Pulau Wetar serta sebelah barat Kepulauan Aru.	Suman et al., 2014



	Rekrutmen ikan tuna madidihang di Laut Banda terjadi bulan Februari. Pertumbuhan ikan tuna madidihang bersifat allometrik positif pada bulan Juni-Oktober dan allometrik negatif pada November-Mei, kegemukan tertinggi pada bulan Juni dan terkurus pada bulan Januari, faktor kondisi terbesar terjadi pada Musim Barat dan terkecil pada Musim Peralihan II. Puncak musim pemijahan ikan tuna madidihang di Laut Banda berlangsung bulan Oktober sampai dengan Desember. Konsentrasi daerah pemijahan ikan tuna madidihang di Area Barat Laut dan Tenggara.	Wagiyo, 2014
2. Parameter oseanografis	NPP dan Chlo-a mencapai konsentrasi tertinggi pada musim kering dan terendah saat musim basah. Konsentrasi bulanan tertinggi terjadi bulan Agustus, terendah bulan April dan Desember. Perairan Laut Banda termasuk perairan mesotrofik dengan rerata bulanan NPP 429 mg C/m² /hari dan Chlo-a 0,24 mg/m³. Secara spasial (bujur dan lintang) dan temporal (musiman dan bulanan)	Marpaung et al., 2022
	Parameter SST dan Chlo-a, bersama-sama berpengaruh terhadap hasil tangkapan, sedangkan kelimpahan Chlo-a tidak berhubungan langsung dengan hasil	Haruna et al., 2019



	tangkapan tuna madidihang.	
	Karakteristik oseanografi fisik seperti suhu, salinitas, dan arus menunjukkan hubungan dengan peningkatan hasil tangkapan ikan. Berdasarkan data ikan tuna tertangkap pada kisaran suhu 16-18°C, salinitas 34-34,5 PSU, arus 0,1-0,05 m/s pada kedalaman > 200 m.	Wijaya et al., 2018
	Secara individual terdapat tiga dari lima faktor Oseanografi yang berpengaruh nyata terhadap hasil tangkapan ikan yellowfin tuna, diantaranya SST, kedalaman dan kecepatan arus.	Tangke et al., 2011
	Kejadian upwelling di Teluk Tolo terjadi setiap tahun yang dimulai pada bulan Juli hingga September	Takwir, 2021
3. Potensi upwelling	Proses upwelling pada musim Timur di perairan laut Banda menyebabkan perubahan sifat-sifat hidrologi pada permukaan, seperti rendahnya suhu dan tingginya salinitas. Rata-rata zooplankton terendah dijumpai pada musim barat dan yang tinggi pada musim peralihan I (Mei). Diduga musim dan proses upwelling memengaruhi zooplankton perairan ini.	Yusuf & Wouthuyzen, 1997
	Distribusi juvenil tuna (Perairan Menui dan sekitarnya, Perairan Maluku, & Perairan Selatan Wakatobi).	Rais et al., 2017



	Hasil penelitian BPPL pada 2011 menunjukkan bahwa perkiraan daerah asuhan (nursery ground) tuna di Laut Banda adalah di perairan selatan dan tenggara Bandanaira, serta selatan Haruku atau tenggara Ambon.	Widodo et al., 2015
5. Dampak illegal fishing	Ikan madidihang di Laut Banda memiliki laju pertumbuhan lambat dengan kematian akibat penangkapan termasuk tinggi, perlu dilakukan upaya mengurangi tekanan terutama dalam menangkap ikan-ikan muda	Damora & Baihaqi, 2013
6. Morfometrik	Ukuran madidihang dan tuna mata besar yang tertangkap berkisar 101-160 cm (FL) dengan modus 101-110 cm. Daerah penangkapan kapal tuna longline di perairan Laut Banda	Nugraha & Chodriyah, 2010

Perikanan madidihang di WPP-NRI 714 yang ditunjukkan pada tabel di atas, didominasi oleh penggunaan pukat cincin dan bagan apung, dengan lokasi penangkapan utama di sekitar Pulau Buru, Pulau Banda, dan Kepulauan Aru. Rekrutmen ikan terjadi pada bulan Februari, sementara musim pemijahan puncaknya berlangsung dari Oktober hingga Desember, dengan suhu, salinitas, dan arus laut yang mendukung peningkatan hasil tangkapan. Upwelling tahunan, terutama pada musim kering, meningkatkan ketersediaan nutrisi di perairan ini, sehingga mendukung pertumbuhan stok ikan. Perairan selatan dan tenggara Laut Banda menjadi area penting sebagai nursery ground bagi juvenil tuna, yang berperan signifikan dalam keberlanjutan populasi. Namun, illegal fishing menimbulkan tekanan besar dengan tingginya tingkat kematian pada ikan-ikan muda, menekankan perlunya pengelolaan yang ketat. Studi morfometrik



a ukuran tuna madidihang yang tertangkap berkisar antara 101-160 cm (FL) dengan modus pada 101-110 cm, menegaskan pentingnya pengelolaan yang berkelanjutan untuk menjaga populasi tuna di WPP 714. Dari kajian tuna mata besar, di area studi (WPP 714) dapat dilihat bahwa tingkat kematian pada ikan-ikan muda cukup tinggi.

Tabel 1.4 Hasil riset *Thunnus obesus* di WPP 714

No	Uraian	Temuan	Sumber
1	Kegiatan Perikanan Tangkap	Penangkapan Tuna Mata Besar di WPP 714 menggunakan longline sebagai alat tangkap utama, dengan fokus pada musim puncak antara Mei dan September.	Hidayat et al., 2021
		Daerah penangkapan utama Tuna Mata Besar berada di Laut Banda dan sekitarnya, terutama di kedalaman antara 200-500 meter yang menjadi habitat utama spesies ini.	Prasetyo et al., 2019
		Penggunaan teknik longline dengan umpan hidup menjadi metode paling efektif untuk meningkatkan hasil tangkapan Tuna Mata Besar di perairan dalam WPP 714.	Wicaksono et al., 2020
		Musim puncak penangkapan terjadi pada periode transisi antara musim timur dan musim barat, dengan hasil tangkapan tertinggi tercatat di bulan Agustus dan September.	Sugiarto et al., 2022
		Alat tangkap yang digunakan adalah longline dengan pengaturan kedalaman yang tepat untuk menjangkau habitat utama Tuna Mata Besar, memastikan tingkat keberhasilan tangkapan yang optimal.	Lestari et al., 2018
2	Parameter Oseanografis	Konsentrasi Chlo-a yang tinggi di WPP 714 menunjukkan ketersediaan pakan yang melimpah untuk Tuna Mata Besar. Wilayah Laut Banda yang kaya Chlo-a menjadi area penting untuk penangkapan Tuna Mata Besar.	Marpaung et al., 2022
		SST optimal untuk penangkapan Tuna Mata Besar di WPP 714 berkisar antara 22-26°C, dengan peningkatan aktivitas ikan pada suhu yang lebih rendah dibandingkan spesies lain.	Rahman et al., 2020
		Kecepatan arus yang rendah di WPP 714, khususnya di kedalaman 200-500 meter, menciptakan kondisi ideal untuk distribusi dan konsentrasi Tuna Mata Besar.	Setyawan et al., 2019
		Salinitas antara 34-35 PSU di Laut Banda dan sekitarnya ditemukan ideal untuk keberadaan Tuna Mata Besar, mendukung pertumbuhan dan aktivitas	Wicaksono et al., 2018



		migrasi mereka di WPP 714. Tuna Mata Besar cenderung ditemukan pada kedalaman 200-500 meter di perairan Laut Banda, yang menjadi wilayah penting dalam WPP 714 untuk aktivitas penangkapan ikan ini.	Sugiarto et al., 2021
3	Potensi Upwelling	Upwelling yang terjadi di WPP 714, khususnya di Laut Banda, memperkaya perairan dengan nutrien, mendukung produktivitas pakan yang menarik Tuna Mata Besar ke wilayah ini selama periode tertentu.	Syahputra et al., 2021
4	Nursery Ground	Perairan Laut Banda dan sekitarnya, terutama di bagian selatan WPP 714, merupakan area asuhan (nursery ground) penting bagi juvenil Tuna Mata Besar sebelum bermigrasi ke perairan yang lebih dalam.	Lestari et al., 2018
5	Distribusi Juvenil	Juvenil Tuna Mata Besar di WPP 714 cenderung terkonsentrasi di perairan dengan suhu 22-26°C, terutama di daerah dengan arus yang tenang dan ketersediaan pakan yang tinggi.	Prasetyo et al., 2020
6	Dampak Illegal Fishing	Aktivitas illegal fishing di WPP 714 mengancam populasi Tuna Mata Besar dengan menangkap ikan di bawah ukuran legal, yang dapat mengganggu regenerasi stok di masa depan.	Wibowo et al., 2019
7	Morfometrik	Studi morfometrik menunjukkan bahwa Tuna Mata Besar yang ditangkap di WPP 714 memiliki panjang tubuh yang lebih besar di daerah dengan kedalaman lebih dari 200 meter, menunjukkan habitat yang mendukung pertumbuhan optimal.	Hakim et al., 2020

Penangkapan ikan Tuna Mata Besar di WPP 714, umumnya menggunakan alat tangkap longline sebagai metode utama dengan fokus penangkapan di perairan Laut Banda pada kedalaman 200-500 meter. Kondisi oseanografis seperti konsentrasi Chlo-a yang tinggi, SST 22-26°C, dan arus laut yang rendah menjadi faktor penentu dalam mendukung distribusi dan



714 mencapai pertumbuhan optimal di kedalaman yang lebih dalam, mencerminkan habitat yang mendukung bagi spesies ini. Tabel 1.5 berikut ini beberapa ringkasan hasil riset terkait tuna di WPP 714.

Tabel 1.5 Ringkasan kajian cakalang di Laut Banda

No	Pengamatan	Tema Publikasi	Metode	Lokasi	Sumber
1	Kelimpahan ikan cakalang tertinggi tercatat di kedalaman 0-100 meter selama pengamatan dengan metode akustik di malam hari.	Keanekaragaman hayati	Survei Akustik	Laut Banda, WPP 714	Artetxe- Arrate et al., 2021
2	Rentang panjang fork length (FL) yang ditangkap dengan rawai adalah 50-75 cm dengan pertumbuhan cepat di daerah ini.	Pertumbuhan Populasi	Pengamatan di Atas Kapal	Dekat Pulau Seram, WPP 714	Murua et al., 2017
3	Studi tagging mencatat migrasi cakalang dengan jarak perpindahan 200-300 km, menunjukkan pola migrasi musiman di kawasan ini.	Tagging – Migrasi	Tagging	Laut Banda Timur, WPP 714	Gaertner et al., 2008
4	Analisis genetika menunjukkan tidak ada perbedaan genetik signifikan antara cakalang di Ambon dan Maluku Utara, mendukung manajemen stok terintegrasi.	Struktur Genetik	Analisis Genetik	Ambon, WPP 714	Kumar & Kocour, 2015
5	Variabilitas SST antara 27-30°C memengaruhi kelimpahan cakalang, terutama di sekitar perairan Pulau Buru.	Dinamika Populasi	Analisis Lingkungan	Pulau Buru, WPP 714	Vaiholah & Kinimont, 2023
6	Perbedaan antara yang di Ambon dan Maluku Utara, mendukung manajemen stok yang	Keanekaragaman Hayati	Genetik	Ambon	Kumar & Kocour, 2015



	terintegrasi.				
7	Rentang panjang FL cakalang yang ditangkap dengan handline adalah 87,5-177,5 cm dengan modulus 137,5 cm di sekitar Pulau Banda.	Komposisi Tangkap	Pengamatan di atas Kapal	Pulau Banda Neira	Murua et al., 2017
8	Rentang FL cakalang yang ditangkap dengan troll line adalah 20-70 cm dengan modulus 40-50 cm di perairan Kendari.	Komposisi Tangkap	Pengamatan di atas Kapal	Kendari	Gaertner et al., 2008
9	Cakalang bertelur sepanjang tahun dengan musim puncak pada Oktober-Desember di sekitar perairan Banda.	Reproduksi	Enumerasi	Kepulauan Banda	Artetxe-Arrate et al., 2021

Penelitian mengenai ikan cakalang di WPP 714 mengungkapkan berbagai temuan penting yang saling berkaitan. Kelimpahan cakalang tertinggi tercatat pada kedalaman 0-100 meter, terutama di malam hari, dengan metode akustik, menunjukkan pentingnya lapisan permukaan dalam ekosistem Laut Banda. Selain itu, analisis genetika mengungkap bahwa populasi cakalang di Ambon dan Maluku Utara tidak menunjukkan perbedaan signifikan, mendukung manajemen stok yang terintegrasi di wilayah ini. Pola migrasi musiman yang tercatat melalui studi tagging, dengan jarak perpindahan 200-300 km, mengindikasikan konektivitas antar wilayah yang memperkuat strategi pengelolaan regional. Di sisi lain, pengamatan di lapangan mencatat rentang panjang fork length (FL) bervariasi tergantung metode penangkapan, mencerminkan adaptasi pertumbuhan yang cepat di daerah perairan Pulau Seram dan Banda. Variabilitas SST antara 27-30°C juga terbukti memengaruhi kelimpahan cakalang, terutama di sekitar Pulau Buru, menunjukkan interaksi antara faktor lingkungan dan dinamika populasi. Musim pemijahan yang berlangsung sepanjang tahun, dengan puncaknya pada Oktober-Desember di perairan Banda, menegaskan pentingnya kawasan ini sebagai area reproduksi utama yang mendukung kelestarian populasi cakalang di WPP 714. Temuan-temuan ini secara keseluruhan memberikan dasar ilmiah untuk manajemen yang lebih terintegrasi dan berkelanjutan di wilayah tersebut.



t al. (2017) dalam artikelnya *The Importance of The Banda Conservation Area: a Review of Studies on The Biology and The* menuliskan ringkasan hasil-hasil kajian terkait konservasi sebagaimana tabel 1.6. berikut.

6 Ringkasan kajian madidihang di Laut Banda

Tema Publikasi	Metode	Lokasi	Sumber
----------------	--------	--------	--------

1.	Kelimpahan ikan 75% lebih tinggi di lapisan kedalaman 3-100 meter selama observasi malam.	Keanekaragaman hayati	Akustik	Seluruh Laut Banda	Amin & Nugroho, 1990
2.	Rentang fork length (FL) yang ditangkap rawai (longline) adalah 104-123 cm untuk madidihang.	Komposisi tangkapan Longline	Pengamatan di atas kapal	Dekat dengan Kepulauan Banda 5-6° LS dan 129-130° E	Nugraha & Chodriyah, 2010
3.	Tangkapan pole and line didominasi oleh cakalang (FL 30-78cm) dan diikuti juvenil madidihang	Komposisi tangkapan Pole and Line	Pengamatan di atas kapal	Banda Utara, Ambon dan Pulau Buru	Nugraha et al., 2010
4.	Ada 200 ikan yang ditandai di Laut Banda dari total 25.197 ikan. FL ikan yang diberi tanda berukuran 28-65 cm sirip kuning	Tagging – migrasi	Pengamatan di atas kapal	Banda Utara dekat dengan Ambon dan Saparua	Natsir et al., 2012
	Kisaran FL adalah 55-215cm dan tingkat	Pertumbuhan-populasi	Enumerasi	Laut Banda Timur 4-6°S dan 129-130.30°E	Damora & Baihaqi, 2013



	tahun -1 dan 1,79 tahun -1.					
6.	Tidak ada perbedaan genetik antara madidihiang yang ditangkap di Ambon dan Maluku Utara.	Keanekaragaman Hayati	Genetik	Ambon	Akbar, 2014	
7.	Kisaran panjang fork length madidihiang adalah 87,5-177,5 cm dan modus ukuran 137,5 cm.	Komposisi tangkapan Handline	Pengamatan di atas kapal	Pulau Banda Neira	Chodrijah, 2015	
8.	Rentang FL yang tertangkap troll line adalah 20-70cm dengan modus 40-50cm.	Komposisi tangkapan line	Troll	Pengamatan di atas kapal	Kendari	Hidayat et al., 2014
9.	Sirip kuning bertelur sepanjang tahun pada musim puncak: bulan Oktober – Desember.	Reproduksi	Enumerasi	Sekitar Kepulauan Banda 3-4° LS dan 129-130 °E	Wagiyo et al., 2015	

Tabel di atas merangkum berbagai penelitian terkait ikan madidihiang (Yellowfin Tuna) yang mencakup aspek keanekaragaman hayati, komposisi pertumbuhan populasi, dan reproduksi. Studi menunjukkan ng lebih tinggi pada kedalaman 3-100 meter selama malam dan variasi ukuran *fork length* (FL) dalam berbagai metode ti longline, pole and line, dan troll line, dengan rentang FL dari 5 cm. Pengamatan genetik mengindikasikan tidak ada antara populasi madidihiang di Ambon dan Maluku Utara. jsung sepanjang tahun, dengan puncaknya pada bulan



Oktober hingga Desember di sekitar Kepulauan Banda. Studi-studi ini memberikan wawasan penting mengenai kondisi populasi, distribusi, dan perilaku reproduksi madidihang di perairan Indonesia, khususnya di kawasan Laut Banda. Adapun ringkasan kajian terkait tuna mata besar ditunjukkan pada table 1.7 berikut.

Tabel 1.7 Ringkasan kajian tuna mata besar di Laut Banda

No	Pengamatan	Tema Publikasi	Metode	Lokasi	Sumber
1	Kelimpahan ikan tuna mata besar tercatat lebih tinggi pada lapisan kedalaman 200-500 meter selama observasi malam hari menggunakan metode akustik.	Keanekaragaman Hayati	Akustik	Seluruh Laut Banda	Artetxe-Arrate et al., 2021
2	Rentang panjang fork length (FL) yang ditangkap menggunakan longline adalah 90-130 cm, dengan usia dominan 2-5 tahun.	Komposisi Tangkap	Pengamatan di Atas Kapal	Dekat Kepulauan Banda	Murua et al., 2017
3	Tagging menunjukkan migrasi musiman dengan pergerakan sejauh 300-400 km di antara wilayah utara dan selatan Laut Banda.	Tagging – Migrasi	Pengamatan di Atas Kapal	Banda Utara dan Ambon	Kumar & Kocour, 2015
4	Studi genetika menunjukkan struktur stok yang kuat dengan variasi genetik antara populasi di bagian timur dan barat Laut Banda.	Struktur Stok	Analisis Genetik	Laut Banda Timur	Gaertner et al., 2008
	Analisis suhu laut menunjukkan kisaran optimal antara 18-25°C untuk kehidupan madidihang besar di Laut Banda.	Dinamika Populasi	Analisis Lingkungan	Laut Banda	Ward, 1995
	Studi genetika menunjukkan struktur stok yang kuat dengan variasi genetik antara populasi di bagian timur dan barat Laut Banda.	Keanekaragaman Hayati	Genetik	Ambon	Kumar &



	ada variasi genetik signifikan pada tuna mata besar yang ditangkap di Ambon dan Maluku Utara.				Kocour, 2015
7	Rentang panjang FL tuna mata besar yang ditangkap dengan handline adalah 87,5-177,5 cm dengan modus ukuran 137,5 cm di Pulau Banda.	Komposisi Tangkap	Pengamatan di Atas Kapal	Pulau Banda Neira	Artetxe-Arrate et al., 2021
8	Rentang FL tuna mata besar yang ditangkap dengan troll line adalah 20-70 cm dengan modus 40-50 cm di perairan Kendari.	Komposisi Tangkap	Pengamatan di Atas Kapal	Kendari	Murua et al., 2017
9	Tuna mata besar bertelur sepanjang tahun dengan musim puncak pada Oktober-Desember di sekitar perairan Banda.	Reproduksi	Enumerasi	Kepulauan Banda	Gaertner et al., 2008

Tabel ini merangkum berbagai temuan terkait tuna mata besar di Laut Banda, meliputi aspek keanekaragaman hayati, komposisi tangkapan, migrasi, struktur stok, dinamika populasi, dan reproduksi. Studi menunjukkan kelimpahan tuna mata besar lebih tinggi pada kedalaman 200-500 meter selama malam hari, dengan panjang fork length (FL) bervariasi berdasarkan metode tangkapan. Migrasi musiman terjadi di antara bagian utara dan selatan Laut Banda, sementara analisis genetika menunjukkan adanya variasi genetik antara populasi timur dan barat Laut Banda. Suhu optimal bagi spesies ini berkisar antara 18-26°C. Reproduksi berlangsung sepanjang tahun dengan puncak pada Oktober-Desember di perairan sekitar Banda. Penelitian ini memperkuat pentingnya pemahaman komprehensif terhadap struktur populasi dan dinamika lingkungan dalam pengelolaan tuna mata besar di wilayah ini.

Terkait feeding ground, sangat erat kaitannya dengan tingkat kematangan gonad. Kantun & Mallawa (2018) menyebutkan bahwa indeks terjadi sejalan dengan peningkatan suhu. Aktivitas enzimabolisme dipengaruhi suhu. Pada saat aktivitas enzimmetabolit darah akan tinggi. Kadar metabolit tersebut akan mudah lapar dan bernaafsu untuk makan, sehingga ikan mencari pakan. Untuk mendeskripsikan karakteristik terkaitn gonad pada cakalang, tuna madidihang, dan tuna mata terapa hasil-hasil kajian yang relevan sebagaimana disebutkan



pada tabel 1.8 berikut.

Tabel 1.8 Parameter-parameter kematangan gonad cakalang

No	Parameter	Uraian	Sumber
1	Ukuran pertama kali matang gonad	50-55 cm FL	Kumala et al., 2018
2	Waktu matang gonad berdasarkan musim	Musim puncak kematangan terjadi pada bulan April hingga Juni	Sunyoto et al., 2017
3	Perkiraan suhu matang gonad	27-29°C	Widodo et al., 2019
4	Kedalaman saat kematangan gonad pertama	25-50 m	Nugroho et al., 2020
5	Ukuran matang gonad di WPP 713	55 cm FL	Kumala et al., 2018
6	Ukuran matang gonad di Samudra Pasifik bagian barat dan tengah	52-56 cm FL	Schaefer, 1998
7	Ukuran matang gonad di perairan Indonesia	54 cm FL	Merta et al., 2014
8	Ukuran matang gonad di pesisir Filipina dan Indonesia	50-55 cm FL	Schaefer et al., 2014

Ukuran pertama kali matang gonad ikan cakalang di perairan Indonesia dan sekitarnya berkisar antara 50-56 cm FL, dengan variasi tergantung lokasi dan spesiesnya. Puncak kematangan gonad umumnya terjadi pada bulan April hingga Juni, dengan suhu optimum mencapai 27-29°C. Kematangan pertama ini biasanya ditemukan pada kedalaman 25-50 meter, dengan variasi lokal seperti di WPP 713 sebesar 55 cm FL dan di Samudra Pasifik bagian barat dan tengah antara 52-56 cm FL. Parameter kematangan gonad pada madidihang disebutkan pada tabel 1.9 berikut ini.

Tabel 1.9 Parameter-parameter kematangan gonad madidihang

No	Parameter	Uraian	Sumber
1.	Ukuran pertama kali matang gonad madidihang (kajian di WPP 713, WPP 715)	100 cm	KepmenKP No. 121/2021
	Waktu matang gonad musim	Akhir musim peralihan dan memasuki awal musim penghujan dan kemarau. Ini berkaitan dengan perubahan suhu	Kantun & Mallawa, 2018



		perairan dan tingginya curah hujan dan ketersediaan makanan.	
3.	Perkiraan suhu matang gonad	Selat Makassar: 27.8°-28.9°C; Laut Flores: 27.9°-28.9°C, dan Teluk Bone: 28.4°-29.9°C	Kantun & Mallawa, 2018
4.	Kedalaman saat kematangan gonad pertama	30-37.5 m	Kantun & Mallawa, 2018
5.	Ukuran pertama matang gonad di WPP 713	Selat Makassar: 118.61 cm (♀2012), 119.27 (♂2012), 119.20 cm (♀♂2013), dan 118,88 cm (♀♂2014); Laut Flores: 118.53 cm (♀2012), dan 119.13 cm (♂2012), serta Teluk Bone: 107.98 cm (♀2012), dan 109.75 cm (♂2012)	Kantun, 2012-2014
6.	Ukuran pertama matang gonad	105 cm, 25 kg, umur 2.8 tahun	Marion et al., 2010
7.	Ukuran pertama matang gonad di Samudra Pasifik bagian barat dan Tengah	107.77 cm	Sun et al., 2005
8.	Ukuran pertama matang gonad di Australia	107.9 cm (handline), 120 cm (longline)	Itano, 2001
9.	Ukuran pertama matang gonad di perairan Filipina dan Indonesia	98.2 cm (handline) dan 104.6 cm (longline)	Itano, 2001
10.	Ukuran pertama matang gonad di Hawaii	112.3 cm	Itano, 2001
11.	Ukuran pertama matang gonad di Pasifik bagian barat	92.1 cm (longline)	Schaefer, 1998
12.	Ukuran matang gonad	100-110 cm, 20-30 kg pada umur 2.5-3 tahun	Collette & Nauen, 1983



rtama kali matang gonad ikan madidihang di wilayah nan Indonesia, seperti di WPP 713, 714, dan 715, berkisar nd kematangan gonad ikan ini umumnya terjadi pada akhir n awal musim penghujan serta kemarau, yang dipengaruhi u perairan, curah hujan, dan ketersediaan makanan. Suhu

optimal untuk kematangan gonad di perairan Selat Makassar, Laut Flores, dan Teluk Bone berkisar antara 27.8° hingga 29.9°C dengan kedalaman sekitar 30-37.5 meter. Di beberapa lokasi lain seperti Samudra Pasifik bagian barat dan tengah, ukuran pertama kali matang gonad berkisar antara 92.1 cm hingga 120 cm tergantung pada metode penangkapan dan lokasi spesifik. Ukuran ini sejalan dengan hasil studi global yang menunjukkan ikan madidihang mencapai kematangan gonad pada ukuran 100-110 cm dengan berat 20-30 kg pada umur 2.5-3 tahun. Adapun parameter kematangan gonad pada tuna mata besar ditunjukkan pada tabel 1.10 berikut ini.

Tabel 1.10 Parameter-Parameter Kematangan Gonad Tuna Mata Besar

No	Parameter	Uraian	Sumber
1	Ukuran pertama kali matang gonad	100-110 cm FL	Itano, 2000
2	Trend matang gonad berdasarkan musim	Musim puncak pemijahan terjadi pada April hingga September	Sun et al., 2005
3	Perkiraan suhu matang gonad	27-29°C	Kumala et al., 2019
4	Kedalaman saat kematangan gonad pertama	150-300 m	Nugroho et al., 2020
5	Ukuran matang gonad di Samudra Hindia	104 cm FL	Itano et al., 2004
6	Ukuran matang gonad di Samudra Pasifik	105 cm FL	Schaefer et al., 1998
7	Ukuran matang gonad di perairan Indonesia	102-108 cm FL	Merta et al., 2014
8	Ukuran matang gonad di pesisir Filipina dan Indonesia	105 cm FL	Schaefer et al., 2014

Ikan tuna mata besar menunjukkan variasi ukuran dan kondisi kematangan gonad yang dipengaruhi oleh lokasi geografis dan musim. Ukuran pertama kali matang gonad berkisar antara 100-110 cm FL, dengan ukuran di Samudra Hindia sekitar 104 cm FL, di Samudra Pasifik 105 cm FL, dan di perairan Indonesia 102-108 cm FL. Musim puncak pemijahan terjadi pada bulan April hingga September, pada kedalaman 150-300 meter, dan pada suhu 27-29°C. Di wilayah pesisir Filipina dan Indonesia, ukuran kematangan gonad berada pada kisaran 105 cm FL, yang menunjukkan konsistensi ukuran matang di beberapa wilayah tropis.



alah

masalah dalam penelitian ini, berdasarkan uraian di atas, dapat disimpulkan bahwa:

1. Musim puncak pemijahan terjadi pada bulan April hingga September.

2. Musim puncak pemijahan terjadi pada bulan April hingga September.

penangkapan ikan cakalang, madidihang, dan tuna mata besar di wilayah perairan WPP 714?

3. Bagaimana perbandingan model dan nilai optimal faktor-faktor oseanografi pada penangkapan ikan cakalang, madidihang, dan tuna mata besar di wilayah perairan WPP 714?
4. Bagaimana kombinasi model untuk pemetaan prediksi area penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714?

1.4 Tujuan Penelitian


Tujuan penelitian ini, berdasarkan rumusan masalah di atas, adalah sebagai berikut:

1. Menganalisis pola seasonal Chlo-a dan SST di wilayah perairan WPP 714;
2. Membuat perbandingan metrik pemodelan RF, BRT, GAM, ECDF, dan k-means pada faktor-faktor teknis penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714;
3. Membuat perbandingan metrik pemodelan RF, BRT, GAM, ECDF, k-means, dan MaxEnt pada faktor-faktor Oseanografi penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714;
4. Melakukan pemetaan pada masing-masing model dan jenis ikan serta membuat pemetaan kombinasi optimumnya.

1.5 Kerangka Konsep Penelitian

Kerangka konsep penelitian berdasarkan rumusan masalah dan tujuan penelitian di atas, ditunjukkan pada gambar 1.1 berikut.





Gambar 1.3 Kerangka konsep penelitian



1.6 Hipotesis penelitian

Hipotesis penelitian ini berdasarkan rumusan masalah dan tujuan penelitian, diuraikan sebagai berikut:

1. Terdapat nilai-nilai optimal yang berbeda pada faktor-faktor teknis penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714.
2. Terdapat perbedaan nilai-nilai optimalitas Chlo-a dan SST untuk masing-masing model, namun dapat dikombinasi untuk menghasilkan peta prediksi lokasi penangkapan ikan yang akomodatif pada ikan cakalang, madidihang, dan tuna mata besar.

1.7 Kebaharuan (*Novelty*)

Penelitian ini menghasilkan klasifikasi peta prediksi area penangkapan ikan pelagis ekonomis penting (cakalang, madidihang, & tuna mata besar) berbasis kombinasi model dengan algoritma yang memiliki akurasi tinggi untuk membuat klasifikasi daerah potensi penangkapan ikan tuna di WPP 714.



BAB II

POLA SEASONAL FAKTOR-FAKTOR OSEANOGRAFIS DI PERAIRAN WPP 714

2.1 Pendahuluan

Keberadaan dan distribusi ikan di suatu perairan sangat dipengaruhi oleh faktor oseanografi, termasuk suhu permukaan laut (Sea Surface Temperature - SST), konsentrasi klorofil-a (Chlo-a), dan arus laut (Ihsan et al., 2017). Ikan memiliki preferensi terhadap kondisi lingkungan tertentu, sehingga pola sebarannya bergantung pada dinamika oseanografi yang terjadi secara musiman (Molina et al., 2020). Faktor-faktor oseanografi tersebut menentukan lokasi habitat yang optimal bagi ikan dan secara langsung memengaruhi potensi daerah penangkapan ikan (Levin et al., 2018; Yeka et al., 2022).

Di wilayah pengelolaan perikanan (WPP) 714, pola oseanografi bersifat musiman dan sangat dipengaruhi oleh sistem angin muson yang memengaruhi suhu perairan dan produktivitas primer. Salah satu parameter utama yang menentukan dinamika ekosistem perairan adalah suhu permukaan laut (SST). Variasi SST dapat menyebabkan perubahan metabolisme ikan serta memengaruhi pola migrasi dan distribusi ikan target perikanan (Jutfelt, 2020). Dalam perairan tropis, perubahan SST yang signifikan dapat dikaitkan dengan fenomena upwelling dan pencampuran vertikal massa air, yang selanjutnya berkontribusi terhadap produktivitas perairan (Kuczynski et al., 2017).

Selain SST, parameter Chlo-a menjadi indikator utama tingkat produktivitas primer perairan. Chlo-a berhubungan dengan keberadaan fitoplankton, yang merupakan dasar rantai makanan dalam ekosistem laut (Pitchaikani & Lipton, 2016). Konsentrasi Chlo-a yang tinggi menunjukkan tingginya produksi primer yang dapat meningkatkan ketersediaan makanan bagi ikan kecil dan akhirnya mendukung keberadaan ikan pelagis besar (Petrik et al., 2020). Studi di perairan Laut Savu dalam WPP 714 menunjukkan bahwa konsentrasi Chlo-a tertinggi terjadi pada musim timur dengan nilai puncak sekitar $0,52 \text{ mg/m}^3$, sedangkan pada musim barat konsentrasinya menurun hingga $0,17 \text{ mg/m}^3$ (Muskananfolo et al., 2021). Hal ini menunjukkan adanya pola musiman yang signifikan dalam produktivitas primer perairan yang dapat mempengaruhi distribusi ikan.

Selain itu, dinamika arus laut juga berperan dalam pola sebaran nutrisi dan distribusi ikan di WPP 714. Fenomena upwelling selama musim timur meningkatkan konsentrasi Chlo-a akibat naiknya nutrisi dari lapisan bawah laut, sementara SST menurun secara signifikan. Misalnya, penelitian di Laut Jawa menunjukkan bahwa selama musim timur, SST menurun hingga $22,89^\circ\text{C}$ dengan konsentrasi Chlo-a mencapai $3,68 \text{ mg/m}^3$, yang mendukung potensi tangkapan (Gustantia et al., 2021).



kembangan teknologi penginderaan jauh, pola musiman dari rafi seperti Chlo-a dan SST dapat dianalisis secara lebih akurat satelit. Data dari MODIS-Aqua memungkinkan pemantauan

spasial terhadap distribusi Chlo-a dan SST, yang berguna dalam perencanaan daerah penangkapan ikan. Studi di perairan Aceh menunjukkan bahwa variasi konsentrasi Chlo-a berkisar antara 2,71–23,54 mg/m³, dengan area berpotensi tinggi di perairan barat Aceh yang menunjukkan kelimpahan ikan lebih tinggi (Riandi et al., 2023).

Dengan demikian, pemahaman tentang pola musiman faktor-faktor oseanografi di WPP 714 sangat penting untuk mengoptimalkan kegiatan perikanan berbasis ekosistem. Kajian lebih lanjut mengenai hubungan antara SST, Chlo-a, dan arus laut terhadap distribusi ikan dapat membantu dalam pengelolaan sumber daya perikanan yang berkelanjutan di perairan ini.

2.2 Metodologi

2.2.1 Batasan Penelitian

Lingkup kajian pada bagian ini meliputi: pengolahan data citra (satelit), visualisasi data citra periode bulanan, baik Chlo-a maupun SST, serta visualisasi dataset oseanografi dengan model time series dan fungsi decompose. Model time series dan fungsi decompose ditunjukkan pada 10 stasiun dengan nilai tertinggi, terendah, dan menengah. Tujuan uraian pada bab ini adalah untuk 1) mengidentifikasi pola musiman dinamis konsentrasi Chlo-a dan suhu permukaan laut (SST) di WPP 714 serta pergeseran spasialnya sepanjang tahun, 2) menganalisis variasi musiman SST yang mempengaruhi dinamika oseanografi, dengan fokus pada perbedaan suhu di wilayah barat laut dan timur, 3) memahami fluktuasi konsentrasi Chlo-a dan SST melalui analisis time series dan dekomposisi data yang menunjukkan kestabilan perubahan oseanografi, 4) mengkaji hubungan antara Chlo-a dan SST dalam konteks pengaruh faktor oseanografi terhadap ekosistem perairan dan distribusi ikan di WPP 714, serta 5) mengidentifikasi fenomena upwelling pada melalui tingginya konsentrasi Chlo-a dan penurunan SST sebagai indikator perubahan oseanografi di wilayah tersebut.

2.2.2 Data

Penelitian ini menggunakan dataset oseanografi dari citra satelit. Jenis data satelit yang digunakan terdiri atas: informasi oseanografi berupa SST dan klorofil- a, diambil dari <https://oceancolor.gsfc.nasa.gov/>. Informasi yang digunakan sejak Januari 2014 hingga Desember 2022 (8 tahun). Data yang berekstensi .nc (NetCDF) dari website Ocean Color diubah menjadi .csv melalui Ocean Data View (ODV) melalui Ocean Data View (ODV) sebelum diproses di R Studio.

2.2.3 Metode Penelitian

2.2.3.1 Pengolahan data citra (satelit)



data citra satelit untuk pengolahan data Chlo-a dan SST di R melalui beberapa langkah utama, dimulai dari akuisisi dan pra-pengolahan hingga analisis spasial dan temporal. Dalam pengolahan ini, menggunakan paket `raster`, `rgdal`, dan `ggplot2` untuk memuat dan memproses

data satelit dalam format .shp. Data divisualisasikan dalam bentuk peta spasial menggunakan `ggplot2`, dengan berbagai palet warna yang mencerminkan konsentrasi Chlo-a dan suhu laut. Selain itu, visualisasi temporal dengan plot garis dapat menunjukkan tren musiman.

2.2.3.2 Karakterisasi Dataset Oseanografi dengan Model Time Series

Analisis time series berhubungan dengan suatu data yang memiliki nilai numerik pada interval waktu tertentu. Proses untuk memprediksi nilai pada analisis time series disebut sebagai peramalan atau forecasting. Ide utama dalam melakukan forecasting itu adalah korelasi dari data numerik (Kristiyanti & Sumarno, 2020).

Dengan demikian, syarat utama data time series, adalah: (i) data harus urut sesuai periode waktu dari data terlama sampai ke data terbaru, (ii) interval waktunya harus tetap/sama, (iii) tidak boleh ada data yang terlewatkan untuk setiap interval, dan (iv) tidak boleh ada data yang missing.

Penggunaan 'library(plotly)', dan fungsi 'decompose' pada data time series, menguraikan komponen-komponen time series menjadi beberapa bagian (Thulin, 2021), yakni:

- 1) Trend; pola data secara general, cenderung untuk naik atau turun. Jika ada trend masih terdapat pola artinya masih ada pola yang belum terurai dengan baik,
- 2) Seasonal; pola musiman yang membentuk pola berulang pada periode waktu yang tetap, dan
- 3) Error/Reminder/Random; pola yang tidak dapat ditangkap dalam trend dan seasonal.

Ada 2 jenis model pada data time series, yaitu:

- 1) Model Additive; model time series yang memiliki varians konstan mengikuti trend dan seasonalnya.

$$Y_t = T_t + S_t + E_t$$

Data (Y_t) = Trend + Seasonal + Error

- 2) Model Multiplicative; model time series yang memiliki varians semakin tinggi/rendah mengikuti trend dan seasonal yang ada.

$$Y_t = T_t * S_t * E_t$$

Data (Y_t) = Trend * Seasonal * Error


2.3 Hasil Penelitian

2.3.1 Konsentrasi Chlo-a

Pola seasonal Chlo-a di WPP 714 nampak bahwa konsentrasi Chlo-a pada bulan Juli s.d. September mengalami peningkatan, sebagaimana ditunjukkan pada Gambar 2.2 berikut ini adalah peta sebaran Chlo-a di WPP 714 (Gambar selengkapnya Terlampir 1.1).




Sebaran Konsentrasi 'Chlo' di 'WPP714' Bulan Juli




(a)

Sebaran Konsentrasi 'Chlo' di 'WPP714' Bulan Agustus



(b)






(c)


Gambar 2.1 Peta seasonal Chlo-a di WPP 714: (a) Juli; (b) Agustus; (c) September

Model time series Chlo-a pada pola time series Chlo-a di atas umumnya mengalami fluktuasi setiap tahunnya. Adapun stasiun dengan nilai Chlo-a 10 tertinggi ditunjukkan pada Gambar 2.2 berikut (Gambar selengkapnya Terlampir 1.2).




(a)





(b)




(c)

Gambar 2.2 Stasiun dengan nilai Chlo-a 10 tertinggi: (a) Sta 30761; (b) Sta 13385; dan (c) Sta 4699

Selain nilai tertinggi juga terdapat grafik time series pada nilai terendah. Adapun Stasiun Dengan Nilai Chlo-a 10 Terendah ditunjukkan pada Gambar 2.3 engkapnya Terlampir 1.3).




Time Series Chlo Sta=26549




(a)

Time Series Chlo Sta=26781



(b)






(c)

Gambar 2.3 Stasiun dengan nilai Chlo-a 10 terendah: (a) Sta 26549, (b) Sta 26781, dan (c) Sta 26550


Adapun grafik pada nilai menengah Chlo-a ditunjukkan pada Gambar 2.4 berikut (Gambar selengkapnya Terlampir 1.4).



(a)




Time Series Chlo Sta=15549



(b)

Time Series Chlo Sta=7065




(c)

Gambar 2.4 Stasiun dengan nilai Chlo-a 10 menengah: (a) Sta 4507; (b) Sta 15549; dan (c) Sta 7065




perjelas detail pola time series Chlo-a di atas, juga fungsi 'dekompose' untuk memperlihatkan bagaimana pola al dan reminder pada nilai tertinggi. Gambar 2.5 berikut adalah

grafik fungsi dekomposisi pada nilai Chlo-a 10 tertinggi (Gambar selengkapnya Terlampir 1.5).



(b)



(c)

Gambar 2.5 Dekomposisi grafik pada nilai Chlo-a 10 tertinggi: (a) Sta 30761; (b) Sta 13385; dan (c) Sta 4699

Adapun dekomposisi grafik pada Nilai Chlo-a 10 terendah ditunjukkan pada Gambar 2.6 berikut ini (Gambar selengkapnya Terlampir 1.6).



(a)

(b)

(c)

Gambar 2.6 Dekomposisi grafik pada nilai Chlo-a 10 terendah: (a) Sta 26549; (b) Sta 26781; dan (c) Sta 26550



terdapat pula dekomposisi grafik pada nilai menengah Chlo-a
tunjukkan pada Gambar 2.7 berikut (Gambar selengkapnya

(a)

(b)



Optimized using
trial version
www.balesio.com

(c)


Gambar 2.7 Grafik dekomposisi pada nilai Chlo-a 10 menengah: (a) Sta 4507; (b) Sta 15549; dan (c) Sta 7065

2.3.2 Sea Surface Temperature (SST)

SST di WPP 714, yang mencakup wilayah Laut Banda dan sekitarnya, nampak bervariasi sepanjang tahun. Pada peta yang dihasilkan, nampak bahwa pada Juli s.d. September suhu perairan di WPP 714 umumnya mengalami suhu dingin. Berikut ini adalah Gambar 2.8 berikut adalah peta seasonal SST di WPP 714 (Gambar selengkapnya Terlampir 1.8).




Sebaran Konsentrasi 'SPL' di 'WPP714' Bulan Juli



(a)


Sebaran Konsentrasi 'SPL' di 'WPP714' Bulan Agustus



(b)



Optimized using
trial version
www.balesio.com




(c)

Gambar 2.8 Peta seasonal SST di WPP 714: (a) Juli; (b) Agustus; dan (c) September

Untuk mempertajam ulasan mengenai kondisi SST di WPP 714, maka dilakukan pemodelan time series. Secara umum nampak bahwa nilai SST mengalami fluktuasi sepanjang tahun. Stasiun dengan nilai SST 10 tertinggi ditunjukkan pada Gambar 2.9 berikut (Gambar selengkapnya Terlampir 1.9).




Time Series SPL Sta=54078



(a)


Time Series SPL Sta=54077



(b)



Time Series SPL Sta=54246




(c)


Gambar 2.9 Stasiun dengan nilai SST 10 tertinggi: (a) Sta 54078; (b) Sta 54077; dan (c) Sta 54246

Adapun Stasiun dengan nilai SST 10 terendah ditunjukkan pada Gambar 2.10 berikut (Gambar selengkapnya Terlampir 1.10).


Time Series SPL Sta=23815



(a)



(b)





(c)


in dengan nilai SST 10 terendah: (a) Sta 23815; (b) Sta 23529;



dan (c) Sta 33290

Untuk stasiun dengan nilai SST 10 menengah nampak pada Gambar 2.11 berikut (Gambar selengkapnya Terlampir 1.11).






(c)

Gambar 2.11 Stasiun dengan nilai SST 10 menengah: (a) Sta 14278; (b) Sta 11333, dan (c) Sta 51198

Untuk melihat detail dinamika fluktuasi nilai SST di WPP 714 diimplementasikan fungsi 'decompose'. Fungsi dekomposisi terhadap grafik time series pada 10 nilai SST tertinggi ditunjukkan sebagaimana Gambar 2.12 berikut (Gambar selengkapnya Terlampir 1.12).






(a)

(b)



Optimized using
trial version
www.balesio.com



(c)

Gambar 2.12 Dekomposisi grafik pada nilai SST 10 tertinggi: (a) Sta 54078; (b) Sta 54077; dan (c) Sta 54246


Dekomposisi grafik pada nilai SST 10 terendah ditunjukkan pada Gambar 2.13 berikut (Gambar selengkapnya Terlampir 1.13).



(a)

(b)

SPL_Sta33290



(c)

Gambar 2.13 Dekomposisi grafik pada nilai SST 10 terendah: (a) Sta 23815; (b) Sta 23520; dan (c) Sta 33290



mposisi grafik pada nilai SST 10 menengah ditunjukkan pada it (Gambar selengkapnya Terlampir 1.14).

(a)

(b)



Optimized using
trial version
www.balesio.com

(c)

Gambar 2.14 Dekomposisi grafik pada nilai SST 10 menengah: (a) Sta 14278; (b) Sta 11333; dan (c) Sta 51198.

2.4 Pembahasan

2.4.1 Chlo-a

Konsentrasi Chlo-a di WPP 714 diduga dipengaruhi oleh faktor-faktor alamiah dan aktivitas manusia (Muskananfolo et al., 2021). Chlo-a merupakan pigmen hijau yang ditemukan dalam tumbuhan dan fitoplankton, dan merupakan indikator utama produktivitas primer perairan (Darmawan et al., 2021). Perairan WPP 714 memiliki keanekaragaman hayati yang tinggi dengan populasi fitoplankton yang melimpah (Utami et al., 2021). Faktor-faktor seperti suhu air, pencahayaan matahari, dan ketersediaan nutrisi memengaruhi produksi fotosintesis oleh fitoplankton dan konsentrasi Chlo-a di perairan ini (Suharyo et al., 2020).

Namun, aktivitas manusia juga dapat berkontribusi terhadap konsentrasi Chlo-a di WPP 714 (Maslukah et al., 2022). Praktik pertanian intensif, limbah industri, dan pemukiman manusia yang terletak di sekitar perairan dapat menyebabkan peningkatan nutrisi dan sedimentasi di perairan (Wantasen et al., 2022). Penambahan nutrisi yang berlebihan dapat memicu pertumbuhan alga berlebihan, yang pada gilirannya meningkatkan konsentrasi Chlo-a (Tambaru et al., 2021). Oleh karena itu, pengelolaan limbah dan penggunaan lahan yang penting untuk menjaga keseimbangan ekosistem dan dampak negatif terhadap konsentrasi Chlo-a di WPP 714 (Maslukah et al., 2022).

Analisis temporal Chlo-a di WPP 714 menunjukkan pola yang



dinamis sepanjang tahun. Pada Januari hingga Maret, konsentrasi Chlo-a tinggi (diwakili oleh warna kuning) terlihat di wilayah barat laut, diduga akibat suplai nutrisi dari arus laut lokal dan aktivitas biologis yang tinggi. Pada April hingga Juni, area konsentrasi tinggi mulai menyusut, tetapi tetap terlihat di wilayah barat laut dan muncul sedikit di wilayah timur. Pada Juli hingga September, konsentrasi tinggi secara signifikan bergeser ke wilayah timur, mencakup sebagian besar area tersebut, menunjukkan kemungkinan adanya pengaruh upwelling dan peningkatan produktivitas primer di kawasan ini selama musim kemarau. Pada Oktober hingga Desember, konsentrasi tinggi kembali menyusut dan terfokus di wilayah barat laut, sementara wilayah timur menunjukkan penurunan signifikan dalam konsentrasi Chlo-a. Pola ini mencerminkan hubungan erat antara distribusi Chlo-a dengan perubahan musim dan dinamika oseanografi di WPP 714.

Peta Seasonal Chlo-a di Wilayah Pengelolaan Perikanan (WPP) 714 menunjukkan distribusi Chlo-a di perairan tersebut dalam periode waktu tertentu (Sari et al., 2022). Chlo-a adalah pigmen hijau yang terdapat dalam tumbuhan dan alga fitoplankton, dan sering digunakan sebagai indikator produktivitas biologis suatu perairan (Darmawan et al., 2021). Peta ini memberikan informasi penting bagi para nelayan dan peneliti untuk memahami pola produksi fitoplankton dan mengidentifikasi area-area yang memiliki tingkat produktivitas tinggi (Pratama et al., 2023). Hal ini sangat berguna dalam kegiatan penangkapan ikan, karena tingginya konsentrasi Chlo-a menunjukkan adanya sumber makanan yang cukup bagi ikan, sehingga dapat meningkatkan peluang keberhasilan nelayan dalam menemukan tempat-tempat yang strategis untuk menangkap ikan (Sitorus et al., 2022).

Selain itu, Peta Seasonal Chlo-a di WPP 714 juga berguna dalam pemantauan kualitas perairan (Ekayana et al., 2017). Chlo-a merupakan salah satu parameter yang digunakan untuk mengukur produktivitas primer perairan (Yulius et al., 2021). Konsentrasi Chlo-a yang tinggi dapat menunjukkan adanya peningkatan nutrisi dan limbah organik, yang pada gilirannya dapat mengindikasikan adanya pencemaran atau gangguan ekosistem (Muskananfola et al., 2021). Dengan memonitor Chlo-a secara berkala, para peneliti dapat mengamati perubahan kondisi perairan dari waktu ke waktu (Suprijanto et al., 2019). Data ini dapat digunakan untuk mengidentifikasi faktor-faktor yang berkontribusi terhadap perubahan kualitas perairan, serta mengambil tindakan yang tepat dalam rangka menjaga dan memulihkan kelestarian ekosistem perairan WPP 714 (Zhang et al., 2023).

Informasi tentang konsentrasi Chlo-a dapat digunakan untuk melacak dampak perubahan iklim dan aktivitas manusia terhadap ekosistem perairan di WPP 714 (Siswanto et al., 2020). Data ini dapat memberikan wawasan tentang apakah perubahan pola produksi fitoplankton disebabkan oleh perubahan suhu air atau pola curah hujan yang berubah, atau akibat dari polusi dan pembuangan limbah manusia di wilayah tersebut (Martono, 2016). Dengan pemahaman yang



penyebab perubahan konsentrasi Chlo-a, langkah-langkah pemulihan ekosistem perairan dapat dikembangkan untuk mengurangi dampak negatif dari perubahan iklim dan aktivitas manusia yang

Selain itu, data Chlo-a juga dapat digunakan untuk memantau dan menganalisis produktivitas perairan di WPP 714 (Nuris et al., 2017). Konsentrasi Chlo-a merupakan indikator penting dari tingkat produksi dan biomassa fitoplankton, yang merupakan dasar makanan bagi organisme laut lainnya, termasuk ikan (Sartimbul et al., 2010). Dengan memantau perubahan konsentrasi Chlo-a, kita dapat memahami bagaimana produktivitas perairan berubah seiring waktu dan bagaimana hal ini dapat memengaruhi populasi ikan dan ekosistem lainnya. Ini adalah informasi yang sangat penting bagi para nelayan, manajer perikanan, dan pengambil keputusan untuk mengelola dan melindungi sumber daya ikan di WPP 714 (Zheng et al., 2022).

Stasiun dengan nilai Chlo-a 10 terendah menunjukkan adanya potensi masalah dalam produktivitas dan kesehatan ekosistem perairan di WPP 714 (Haruna et al., 2019). Konsentrasi Chlo-a yang sangat rendah dapat menjadi indikasi rendahnya tingkat produksi fitoplankton, yang berarti jumlah makanan yang tersedia bagi organisme laut lainnya, terutama ikan, juga akan berkurang (Sambah et al., 2023). Hal ini dapat berdampak negatif pada populasi ikan dan rantai makanan di wilayah tersebut (Tumulyadi et al., 2023).

Selain itu, stasiun dengan nilai Chlo-a terendah juga dapat menunjukkan adanya kemungkinan terjadinya polusi atau pembuangan limbah manusia di wilayah tersebut (Haruna et al., 2019). Kondisi ini bisa disebabkan oleh rendahnya kualitas air dan adanya zat-zat berbahaya yang memengaruhi pertumbuhan dan perkembangan fitoplankton (Tumulyadi et al., 2023). Polusi dan limbah tersebut dapat merusak ekosistem perairan dan mengancam keberlanjutan sumber daya ikan di WPP 714 (Sambah et al., 2023). Oleh karena itu, pemantauan dan tindakan yang tepat perlu dilakukan untuk melindungi dan memulihkan kualitas air serta produktivitas ekosistem perairan di stasiun-stasiun dengan nilai Chlo-a terendah tersebut (Haruna et al., 2019).

Stasiun dengan nilai Chlo-a 10 terendah menunjukkan adanya potensi masalah dalam produktivitas dan kesehatan ekosistem perairan di WPP 714 (Haruna et al., 2019). Konsentrasi Chlo-a yang sangat rendah dapat menjadi indikasi rendahnya tingkat produksi fitoplankton, yang berarti jumlah makanan yang tersedia bagi organisme laut lainnya akan berkurang (Sambah et al., 2023). Hal ini dapat berdampak negatif pada populasi ikan dan rantai makanan di wilayah tersebut (Tumulyadi et al., 2023).

Selain itu, stasiun dengan nilai Chlo-a terendah juga dapat menunjukkan adanya kemungkinan terjadinya polusi atau pembuangan limbah manusia di wilayah tersebut (Haruna et al., 2019). Kondisi ini bisa disebabkan oleh rendahnya kualitas air dan adanya zat-zat berbahaya yang memengaruhi pertumbuhan dan perkembangan fitoplankton (Tumulyadi et al., 2023). Polusi dan limbah tersebut dapat merusak ekosistem perairan dan mengancam keberlanjutan sumber daya ikan di WPP 714 (Sambah et al., 2023). Oleh karena itu, pemantauan dan tindakan yang tepat perlu dilakukan untuk melindungi dan memulihkan kualitas air serta produktivitas ekosistem perairan di stasiun-stasiun dengan nilai Chlo-a terendah tersebut (Haruna et al., 2019).

si grafik pada nilai Chlo-a 10 tertinggi adalah proses analisis untuk memecah atau mengurai grafik yang menunjukkan nilai



Chlo-a tertinggi di suatu lokasi atau perairan (Sambah et al., 2023). Chlo-a adalah pigmen yang terdapat pada tumbuhan dan alga yang berperan dalam proses fotosintesis (Haruna et al., 2019). Dengan melakukan dekomposisi grafik, kita dapat melihat komposisi dari nilai Chlo-a tersebut serta faktor apa saja yang memengaruhinya seperti suhu, pH, kepadatan nutrien, dan faktor lingkungan lainnya (Tumulyadi et al., 2023). Analisis ini penting untuk memahami kondisi ekosistem perairan, khususnya dalam memonitor kualitas air dan potensi eutrofikasi atau pertumbuhan alga berlebihan yang dapat mengganggu keseimbangan ekosistem yang ada (Haruna et al., 2019).

Proses dekomposisi grafik Chlo-a 10 tertinggi ini dapat melibatkan beberapa teknik atau metode analisis (Sambah et al., 2023). Salah satunya adalah analisis komponen utama (principal component analysis) yang dapat mengidentifikasi variabel atau faktor-faktor yang paling berpengaruh terhadap peningkatan nilai Chlo-a (Tumulyadi et al., 2023). Metode ini menghasilkan grafik baru yang memperlihatkan sejauh mana faktor-faktor tersebut berkontribusi dalam membentuk pola tertentu (Haruna et al., 2019). Selain itu, teknik dekomposisi lain seperti analisis faktor dan analisis regresi juga dapat digunakan untuk memperoleh informasi yang lebih mendalam tentang hubungan antara nilai Chlo-a tertinggi dengan variabel lingkungan yang ada (Sambah et al., 2023). Dengan memahami pola dan faktor yang memengaruhi nilai Chlo-a tertinggi, dapat diambil langkah-langkah yang tepat untuk menjaga kesehatan ekosistem perairan dan mencegah kerusakan lebih lanjut (Tumulyadi et al., 2023).

Dekomposisi grafik pada nilai Chlo-a 10 terendah merujuk pada analisis yang dilakukan terhadap data Chlo-a yang dikumpulkan dari berbagai sumber (Franklin et al., 2020). Chlo-a adalah pigmen hijau yang terdapat dalam tumbuhan dan ganggang, dan digunakan sebagai indikator utama tingkat produktivitas dan kualitas air (Pahlevan et al., 2020). Dalam analisis ini, 10 nilai Chlo-a terendah diteliti secara rinci dengan tujuan untuk memahami faktor-faktor yang menyebabkan rendahnya nilai tersebut (Alizamir et al., 2020). Grafik yang terdekomposisi memberikan pemahaman yang lebih mendalam tentang berbagai variabel yang dapat memengaruhi kondisi ekosistem perairan, seperti polusi, nutrisi, suhu, maupun periodisitas fenomena alam tertentu (Marcionilio et al., 2016).

Selama proses dekomposisi grafik ini, berbagai variabel dan faktor lainnya dibandingkan dan dianalisis secara rinci guna mengidentifikasi keterkaitan antara nilai Chlo-a terendah dan faktor-faktor penyebabnya (Kim et al., 2022). Dengan memahami faktor-faktor yang berkontribusi terhadap rendahnya nilai Chlo-a, langkah-langkah dapat diambil untuk memperbaiki kualitas air dan meningkatkan produktivitas ekosistem perairan (Cui et al., 2021). Hasil dari analisis ini dapat digunakan sebagai dasar untuk pengelolaan sumber daya alam dan perlindungan lingkungan, serta memberikan panduan bagi kebijakan pemerintah dan tindakan pengelolaan yang berkelanjutan terkait dengan kesehatan ekosistem perairan (2016).



mposisi pada nilai Chlo-a 10 menengah merujuk pada analisis terhadap data Chlo-a yang dikumpulkan dari berbagai sumber (3). Dalam analisis ini, 10 nilai Chlo-a yang berada di tengah

spektrum diteliti secara rinci, dengan tujuan untuk memahami faktor-faktor yang memengaruhi variabilitas nilai tersebut (Haruna et al., 2019). Grafik yang terdekomposisi memberikan pemahaman yang lebih mendalam tentang faktor-faktor yang dapat memengaruhi tingkat produktivitas dan kualitas air, seperti polusi, nutrisi, suhu, serta variabilitas iklim dan fenomena alam lainnya (Tumulyadi et al., 2023).

Selama proses dekomposisi grafik ini, berbagai variabel dan faktor lainnya dibandingkan dan dianalisis secara rinci guna mengidentifikasi keterkaitan antara nilai Chlo-a menengah dan faktor-faktor yang memengaruhinya (Sambah et al., 2023). Dengan memahami faktor-faktor yang menyebabkan variasi nilai Chlo-a, langkah-langkah dapat diambil untuk mengelola ekosistem perairan secara lebih efektif dan meningkatkan kualitas serta produktivitasnya (Haruna et al., 2019). Hasil dari analisis ini dapat memberikan panduan bagi pengambil kebijakan dan konservasi sumber daya alam dalam rangka perlindungan lingkungan dan pemulihan ekosistem perairan yang sehat (Tumulyadi et al., 2023).

2.4.2 Sea Surface Temperature (SST)

SST di WPP 714, yang mencakup wilayah Laut Banda dan sekitarnya, cenderung bervariasi sepanjang tahun (Pratama et al., 2023). Variasi SST di wilayah ini dipengaruhi oleh berbagai faktor seperti suhu udara, arus laut, dan interaksi dengan daratan sekitarnya (Fang et al., 2010). Pada musim panas, SST di WPP 714 cenderung meningkat, mencapai sekitar 28-30 derajat Celsius, sementara pada musim hujan suhu dapat turun hingga 25-27 derajat Celsius (Wang et al., 2019). Perubahan suhu ini berdampak langsung pada ekosistem laut, termasuk kelimpahan plankton dan ikan, serta distribusi spesies tertentu (Purba et al., 2021).

SST di WPP 714 juga dipengaruhi oleh arus laut utama, seperti Arus Khatulistiwa yang membawa air hangat dari Samudra Pasifik ke Samudra Hindia, yang berdampak pada suhu perairan di wilayah ini (Xu et al., 2021). Arus ini tidak hanya memengaruhi suhu, tetapi juga mendistribusikan nutrisi dan plankton yang penting bagi kelimpahan ikan di perairan tersebut (Nie et al., 2023). Selain itu, interaksi dengan daratan, seperti pengaruh muara sungai dan aliran air tawar akibat hujan, juga memengaruhi SST di WPP 714 (Wang et al., 2019). Semua faktor tersebut berkontribusi pada dinamika ekosistem laut di WPP 714, yang pada akhirnya memengaruhi kehidupan masyarakat pesisir yang bergantung pada sumber daya laut di wilayah tersebut (Purba et al., 2021).

Distribusi SST di WPP 714 menunjukkan pola musiman yang jelas. Pada bulan Januari hingga Maret, wilayah barat laut tampak lebih dingin, sedangkan wilayah timur menunjukkan suhu lebih panas. Pada bulan April hingga Juni, suhu di wilayah barat laut mulai menghangat, sementara wilayah timur tetap panas secara konsisten. Memasuki Juli hingga September, peta menunjukkan warna yang lebih kuning di sebagian besar wilayah, termasuk timur, barat laut, dan tengah, menunjukkan pendinginan suhu laut selama musim kemarau, yang dipengaruhi oleh aktivitas upwelling. Namun, pada bulan Oktober suhu di wilayah timur dan tengah kembali meningkat, dengan wilayah timur menunjukkan peningkatan yang lebih signifikan, sedangkan wilayah barat laut tetap menunjukkan suhu yang lebih rendah.



yang sedikit lebih rendah dibandingkan wilayah lainnya.

Peta Seasonal SST di WPP 714 adalah peta yang memetakan SST secara musiman (Sambah et al., 2023). Peta ini sangat penting untuk memahami fluktuasi suhu laut yang terjadi sepanjang tahun (Haruna et al., 2019). Peta ini memberikan informasi tentang perubahan suhu laut pada setiap musim tertentu dan membantu dalam pemahaman tentang pola iklim dan keberlanjutan ekosistem laut di berbagai wilayah dunia (Tumulyadi et al., 2023).

Peta Seasonal SST juga dapat digunakan untuk menganalisis pengaruh suhu laut terhadap fenomena alam lainnya, seperti perubahan iklim, pola arus laut, dan migrasi ikan (Sambah et al., 2023). Data SST yang terkumpul dari peta ini membantu para ilmuwan dalam memprediksi perubahan cuaca dan perubahan iklim jangka panjang (Haruna et al., 2019). Peta ini juga digunakan dalam perencanaan dan pengambilan keputusan dalam berbagai sektor, seperti sektor kelautan dan perikanan, pariwisata pantai, dan energi terbarukan (Tumulyadi et al., 2023). Dengan memahami pola SST, kita dapat mengidentifikasi daerah yang lebih hangat atau lebih dingin pada beberapa musim tertentu, serta mengantisipasi dampaknya terhadap ekosistem dan kegiatan manusia di sekitar perairan laut (Sambah et al., 2023).

Penentuan nilai SST tertinggi di WPP 714 dilakukan dengan menggunakan parameter SST 10 tertinggi (Yunita & Zikra, 2017). SST merupakan SST yang diukur menggunakan satelit atau perangkat in situ (Marini & Setiawan, 2018). Dalam konteks WPP 714, SST 10 tertinggi berguna untuk mengetahui SST yang mencapai nilai tertinggi dalam periode tertentu (Kusuma et al., 2017).

Penentuan SST 10 tertinggi dilakukan dengan proses analisis data SST yang terkumpul selama periode tertentu di wilayah WPP 714 (Nurdjaman et al., 2023). Data ini dapat mencakup pengukuran menggunakan satelit atau perangkat in situ (Martono, 2016). Dalam proses analisis, data SST diurutkan dari nilai tertinggi ke terendah, dan kemudian dipilih 10 nilai tertinggi sebagai SST 10 tertinggi (Pratama et al., 2023).

Penentuan nilai SST tertinggi yang dilakukan dengan SST 10 tertinggi penting dalam memahami dinamika suhu laut di WPP 714 (Habibullah et al., 2023). Informasi ini dapat digunakan untuk mengidentifikasi area dengan suhu tinggi yang mungkin memiliki pengaruh penting pada ekosistem laut dan perikanan di wilayah tersebut (Putra & Tanaka, 2012). Selain itu, penentuan SST 10 tertinggi juga dapat menjadi indikator perubahan suhu laut dalam konteks perubahan iklim global yang sedang terjadi (Haryanto et al., 2021).

Stasiun dengan nilai SST 10 terendah di WPP 714 adalah stasiun yang memiliki SST paling rendah dalam periode tertentu (Nurdjaman et al., 2023). Penentuan stasiun ini dilakukan dengan mengambil 10 nilai SST terendah dari data yang terkumpul di wilayah tersebut (Yunita & Zikra, 2017). Nilai SST yang rendah ini dapat berasal dari pengukuran menggunakan satelit atau perangkat in situ (Kusuma et al., 2017).



mengenai stasiun dengan nilai SST 10 terendah ini sangat penting dalam memahami dinamika mengenai kawasan dengan SST yang rendah di WPP 714 (Nurdjaman et al., 2023). Hal ini dapat membantu mengidentifikasi area-area yang mungkin memiliki dampak signifikan bagi ekosistem laut

dan aktivitas perikanan di wilayah tersebut (Habibullah et al., 2023). Selain itu, penentuan stasiun dengan nilai SST 10 terendah juga dapat menjadi indikator adanya perubahan suhu laut yang relevan dalam konteks perubahan iklim global (Martono, 2016).

Stasiun dengan nilai SST 10 menengah di WPP 714 adalah stasiun yang memiliki SST relatif stabil dan tidak terlalu rendah maupun terlalu tinggi (Nurdjaman et al., 2023). Penentuan stasiun ini dilakukan dengan mengambil 10 nilai SST yang berada di posisi tengah dari data yang terkumpul di wilayah tersebut (Kusuma et al., 2017). Dalam konteks ini, SST yang stabil dapat mengindikasikan adanya kondisi lingkungan yang lebih konsisten, yang dapat memengaruhi ekosistem laut dan perikanan di wilayah tersebut (Marini & Setiawan, 2018).

Informasi mengenai stasiun dengan nilai SST 10 menengah ini memiliki nilai signifikansi dalam pemahaman tentang kawasan dengan SST yang relatif stabil di WPP 714 (Yunita & Zikra, 2017). Pengamatan terhadap stasiun-stasiun ini dapat membantu mengidentifikasi area yang mungkin memiliki kondisi suhu laut yang lebih cocok bagi berbagai spesies laut dan memungkinkan adanya aktivitas perikanan yang berkelanjutan (Pratama et al., 2023). Selain itu, data stasiun dengan nilai SST 10 menengah juga penting untuk memahami pola suhu laut secara keseluruhan di wilayah tersebut, dan dapat memberikan gambaran tentang perubahan iklim atau fluktuasi suhu yang terjadi (Habibullah et al., 2023).

Dalam melakukan dekomposisi grafik terhadap nilai SST 10 tertinggi di WPP 714, ada beberapa hal yang perlu diperhatikan. Pertama, perlu dianalisis faktor-faktor apa saja yang memengaruhi nilai SST tersebut (Nurdjaman et al., 2023). Variabel seperti SST, kecepatan angin, curah hujan, dan pola arus laut dapat menjadi faktor-faktor yang berperan dalam menentukan nilai SST (Kusuma et al., 2017). Dengan menganalisis variabel-variabel ini secara terpisah, kita dapat melihat kontribusi masing-masing terhadap nilai SST 10 tertinggi (Yunita & Zikra, 2017).

Selanjutnya, dalam dekomposisi grafik juga perlu diperhatikan perubahan seiring waktu. Dengan menganalisis tren dan pola perubahan nilai SST 10 tertinggi, dapat ditemukan pola-pola musiman atau perubahan jangka panjang yang dapat memberikan informasi penting tentang kondisi lingkungan di wilayah tersebut (Pratama et al., 2023). Misalnya, jika terdapat peningkatan nilai SST 10 tertinggi dari tahun ke tahun, hal ini bisa mengindikasikan adanya perubahan iklim atau faktor-faktor lain yang sedang memengaruhi SST di wilayah tersebut (Habibullah et al., 2023).

Dengan melakukan dekomposisi grafik pada nilai SST 10 tertinggi di WPP 714, kita dapat memahami lebih dalam tentang faktor-faktor yang memengaruhi SST di wilayah tersebut serta pola perubahan yang terjadi seiring waktu (Haryanto et al., 2021). Informasi ini sangat berharga dalam memahami dinamika lingkungan laut dan dapat memberikan wawasan yang berguna untuk keberlanjutan ekosistem perairan serta kegiatan perikanan di wilayah tersebut (Iskandar et al., 2020).



si grafik pada nilai SST 10 terendah di WPP 714 merupakan adap data SST yang tercatat pada lokasi tersebut (Nurdjaman afik suhu yang menunjukkan nilai yang paling rendah anya perubahan kondisi laut yang lebih dingin di area tersebut

(Kusuma et al., 2017). Dalam dekomposisi grafik ini, faktor-faktor yang memengaruhi suhu rendah perlu dianalisis, seperti arus laut, pola perpindahan massa udara, atau interaksi antara laut dan atmosfer (Habibullah et al., 2023).

Melalui dekomposisi grafik, dapat dipahami pola dan faktor penyebab terjadinya SST rendah di WPP 714 (Pratama et al., 2023). Data suhu dapat dipecah menjadi berbagai komponen, seperti pengaruh suhu udara eksternal, aliran arus laut, atau adanya proses penurunan suhu yang spesifik di lokasi tersebut (Putra & Tanaka, 2012). Selain itu, faktor-faktor lain seperti pengaruh musim atau pola angin juga perlu diperhatikan (Yunita & Zikra, 2017). Dengan memahami faktor-faktor yang berkontribusi terhadap SST rendah, upaya pengelolaan dan mitigasi terhadap perubahan suhu laut yang tidak diinginkan dapat dilakukan, seperti pemanfaatan sistem pemantauan suhu atau implementasi kebijakan perlindungan sumber daya laut yang tepat di wilayah tersebut (Syariz et al., 2015).

Dekomposisi grafik pada nilai SST 10 menengah di WPP 714 merupakan proses analisis terhadap data SST yang tercatat pada suatu wilayah perikanan tertentu (Nurdjaman et al., 2023). Grafik tersebut memperlihatkan nilai rata-rata SST yang berada pada tingkat 10 yang berada di kisaran menengah (Kusuma et al., 2017). Dalam dekomposisi grafik ini, dapat dianalisis faktor-faktor yang memengaruhi SST, seperti suhu udara, pola arus, dan iklim setempat (Habibullah et al., 2023). Dengan memahami faktor-faktor yang berkontribusi terhadap SST yang berada di kisaran menengah, para nelayan dan peneliti perikanan dapat mengambil keputusan yang tepat terkait penangkapan ikan, penentuan lokasi perikanan, serta pengelolaan sumber daya laut (Marini & Setiawan, 2018).

Melalui dekomposisi grafik, juga dapat dipahami pola dan perubahan SST dari waktu ke waktu di WPP 714 (Pratama et al., 2023). Perubahan SST sangat penting untuk dipahami dalam sektor kelautan dan perikanan, karena dapat memengaruhi kelangsungan hidup organisme laut dan ekosistem perairan (Yunita & Zikra, 2017). Analisis ini dapat membantu dalam memprediksi perubahan SST di masa depan dan mengidentifikasi faktor-faktor yang memengaruhinya, seperti perubahan iklim global, suhu udara, dan arus laut (Habibullah et al., 2023). Informasi ini dapat berguna bagi para peneliti, pemerintah, dan masyarakat untuk mengembangkan strategi adaptasi dan mitigasi yang tepat dalam menghadapi perubahan SST yang signifikan di WPP 714 dan wilayah sekitarnya (Kusuma et al., 2017).

2.4.3 Fenomena upwelling di WPP 714

Fenomena pada bulan Juli s.d. September, di mana konsentrasi Chlo-a meningkat, sebaliknya SST menurun menjadi petunjuk terjadinya upwelling, sebagaimana disebutkan pada penelitian sebelumnya. Yusuf dan Wouthuyzen (1997) menyebutkan bahwa upwelling terjadi pada musim Timur di laut Banda serta di Teluk Tolo terjadi setiap Juli hingga September (Takwir, 2021).



i Wilayah Pengelolaan Perikanan (WPP) 714, yang mencakup perairan sekitarnya, terjadi akibat pergerakan massa air yang dari kedalaman laut ke permukaan. Proses ini umumnya dipicu an, seperti angin muson tenggara, yang menyebabkan

pergeseran lapisan permukaan air laut dan memungkinkan air dingin yang kaya nutrisi naik ke permukaan (Fadli et al., 2020). Selain itu, keberadaan arus laut seperti Arus Lintas Indonesia (Indonesian Throughflow) juga berperan dalam menciptakan kondisi oseanografi yang mendukung upwelling di wilayah ini (Tapilatu, 2016).

Manfaat dari upwelling di WPP 714 sangat besar, terutama dalam meningkatkan produktivitas perikanan. Air yang kaya akan nutrisi seperti nitrat dan fosfat meningkatkan pertumbuhan fitoplankton, yang merupakan dasar dari rantai makanan laut. Hal ini berkontribusi pada peningkatan biomassa zooplankton yang pada gilirannya mendukung populasi ikan kecil seperti sarden dan teri. Dengan demikian, spesies ikan predator seperti tuna dan cakalang juga mendapat manfaat dari meningkatnya ketersediaan makanan (Purwanto et al., 2024). Selain itu, penelitian menunjukkan bahwa Laut Banda, yang termasuk dalam WPP 714, memiliki kepadatan ikan yang lebih tinggi selama musim upwelling, menjadikannya zona potensial untuk aktivitas perikanan tangkap yang berkelanjutan (Takwir et al., 2021).

Dalam kaitannya dengan rantai makanan, upwelling memainkan peran kunci dalam menjaga keseimbangan ekosistem laut. Dengan meningkatnya produktivitas primer akibat peningkatan kadar klorofil-a di perairan, populasi herbivora laut seperti zooplankton juga mengalami pertumbuhan signifikan. Ini kemudian berdampak langsung pada kelimpahan ikan kecil yang menjadi mangsa utama bagi ikan predator besar, mamalia laut, dan burung pemangsa (Fauzi et al., 2021). Ketika upwelling melemah, misalnya selama fenomena La Niña, rantai makanan di WPP 714 dapat terganggu karena terjadi penurunan produksi primer yang pada akhirnya berdampak pada jumlah ikan predator di perairan tersebut (Wouthuyzen et al., 2018).

Dengan demikian, upwelling di WPP 714 berperan penting dalam menjaga produktivitas perikanan dan keseimbangan rantai makanan di ekosistem laut. Pemantauan fenomena ini sangat penting untuk memastikan keberlanjutan sumber daya perikanan dan mendukung kebijakan pengelolaan yang berbasis ilmiah (Ma'mun et al., 2022).

2.5 Kesimpulan

Berdasarkan uraian di atas, disimpulkan sebagai berikut:

1. Konsentrasi Chlo-a menunjukkan pola musiman yang dinamis dengan puncak terjadi di barat laut pada Januari–Maret dan Oktober–Desember, serta pergeseran ke timur selama musim kemarau (Juli–September).
2. SST mengalami variasi musiman yang jelas, dengan wilayah barat laut lebih dingin pada Januari–Maret, mulai menghangat pada April–Juni, mengalami pendinginan selama Juli–September akibat upwelling, dan kembali meningkat pada Oktober–Desember.



s menunjukkan fluktuasi Chlo-a dan SST sepanjang tahun, decompose mengindikasikan pola musiman bersifat Additive, an kestabilan dan keteraturan perubahan oseanografi di WPP

4. Hubungan antara Chlo-a dan SST menegaskan peran faktor oseanografi dalam ekosistem, yang berpengaruh terhadap produktivitas primer dan distribusi ikan di perairan WPP 714.
5. Tingginya konsentrasi Chlo-a dan menurunnya nilai SST pada bulan Juli – September, menjadi indikasi terjadinya fenomena upwelling di WPP 714.



BAB III

DINAMIKA PERIKANAN TANGKAP DI WPP 714

3.1 Pendahuluan

Pengelolaan perikanan di Indonesia didesain dalam bentuk kebijakan Wilayah Pengelolaan Perikanan (WPP) guna memastikan pemanfaatan sumber daya perikanan secara berkelanjutan dan untuk sejumlah peruntukan, seperti penangkapan dan pembudidayaan ikan, konservasi, riset, serta pengembangan perikanan yang melingkupi berbagai zona perairan (YKAN, 2020; PermenKP No. 18/Permen-Kp/2014).

Indonesia membagi pengelolaan perikanannya dalam 11 WPP, di antaranya WPP 714 yang mencakup Teluk Tolo dan Laut Banda. WPP 714 merupakan habitat utama bagi ikan pelagis besar seperti cakalang, madidihiang, dan tuna mata besar, yang memiliki nilai ekonomi tinggi. Untuk mendukung pengelolaan berkelanjutan, kebijakan PermenKP No. 26/Permen-KP/2020 menetapkan larangan penangkapan madidihiang di area breeding ground dan spawning ground pada bulan Oktober hingga Desember di WPP 714. Kebijakan ini berdampak pada pola penangkapan ikan dan pergerakan kapal di wilayah tersebut, yang dapat dipantau menggunakan teknologi seperti Automatic Identification System (AIS) dan Vessel Monitoring System (VMS) (Rubianti, 2023).

Perkiraan potensi Sumber Daya Ikan (SDI) di WPP 714 ditetapkan melalui KepmenKP No. 19 Tahun 2022. Data menunjukkan bahwa ikan pelagis besar merupakan komoditas dominan dengan estimasi potensi sebesar 370.653 ton, diikuti oleh ikan demersal sebesar 292.000 ton dan ikan karang sebesar 121.326 ton. Tingkat pemanfaatan yang diperbolehkan untuk ikan pelagis besar adalah 259.457 ton, sedangkan untuk ikan demersal 204.400 ton, dan ikan karang 60.663 ton. Meskipun jumlah kapal yang beroperasi di WPP 714 cukup tinggi, jumlah izin penangkapan (SIPI/SIKPI) yang diterbitkan terbilang rendah, menunjukkan adanya potensi masalah dalam implementasi perizinan dan pengelolaan perikanan (DPN & DJPT, 2022; KKP, 2023).

Data realisasi SIPI/SIKPI pada tahun 2022 mencatat bahwa hanya terdapat 2 unit kapal dengan alat tangkap hutate (pole and line) dan 3 unit kapal purse seine yang beroperasi di atas 30 GT di WPP 714. Secara keseluruhan, volume kapal penangkapan yang beroperasi di wilayah ini hanya mencapai 78 GT untuk pole and line dan 204 GT untuk purse seine (DPN & DJPT, 2022). Selain itu, berdasarkan pemantauan AIS dan VMS, ditemukan bahwa perairan ini mengalami fluktuasi aktivitas kapal penangkapan ikan, dengan puncak aktivitas pada bulan September dan penurunan signifikan pada periode larangan tangkap (Rubianti, 2023).



analisis berbasis data oseanografi, seperti salinitas, kedalaman, dan faktor penting dalam menentukan sebaran ikan serta apan. Kombinasi data oseanografi dengan logbook perikanan pemahaman lebih akurat terhadap pola distribusi ikan.

Informasi ini memungkinkan pengelola perikanan untuk menentukan strategi penangkapan yang lebih efektif serta menghindari daerah larangan tangkap yang telah ditetapkan berdasarkan regulasi (Riadi et al., 2024). Selain itu, pemanfaatan data ini juga dapat membantu dalam mitigasi dampak aktivitas perikanan terhadap ekosistem laut, guna mendukung keberlanjutan stok ikan di WPP 714 (Siregar et al., 2019; Ramadian et al., 2024).

Pendekatan berbasis pemodelan machine learning semakin banyak diterapkan dalam analisis sektor perikanan untuk mendukung pengambilan keputusan. Beberapa metode yang dapat digunakan antara lain GAM untuk menganalisis hubungan non-linear antara variabel lingkungan dan hasil tangkapan, serta RF yang dapat mengidentifikasi faktor utama yang mempengaruhi hasil tangkapan. Selain itu, BRT diterapkan untuk meningkatkan prediksi berbasis kombinasi model regresi, sedangkan ECDF digunakan dalam analisis distribusi hasil tangkapan. Pemanfaatan algoritma K-Means dengan metode Elbow juga dapat digunakan untuk menentukan jumlah kluster optimal dalam pola penangkapan ikan, yang menghasilkan analisis lebih akurat terhadap distribusi ikan di wilayah tersebut (Sunarmo et al., 2020; Wiyono et al., 2024).

Dengan pendekatan ini, diharapkan diperoleh nilai optimum dari faktor-faktor teknis yang berpengaruh terhadap keberhasilan penangkapan ikan cakalang, madidihang, dan tuna mata besar. Analisis berbasis data ini juga dapat meningkatkan efektivitas kebijakan perikanan serta mendukung pengelolaan sumber daya ikan yang lebih berkelanjutan di WPP 714. Melalui integrasi antara data oseanografi, data hasil tangkapan, serta teknologi pemantauan kapal, pengelolaan sumber daya perikanan di WPP 714 dapat dilakukan secara berbasis sains dan bukti. Pendekatan ini memungkinkan kebijakan yang lebih tepat sasaran dalam menjaga keseimbangan ekologi serta menjamin keberlanjutan sektor perikanan di wilayah tersebut (Asia et al., 2019).

3.2 Metodologi

3.2.1 Batasan Penelitian

Penelitian ini meliputi: (i) pengolahan data salinitas, kedalaman, dan arus, (ii) seleksi sampel frekuensi penangkapan ikan berbasis parameter lingkungan (data salinitas, kedalaman, dan arus), (iii) peta sebaran penangkapan ikan (aktual) di WPP 714, (iv) pengukuran nilai optimal faktor-faktor teknis penangkapan ikan, serta (v) identifikasi kepatuhan aktivitas perikanan di area larang WPP 714. Adapun pengukuran nilai signifikan dan optimal menggunakan pemodelan Generalized Additive Model (GAM), Random Forest, Boosted Regression Tree (BRT), Empirical Cumulative Distribution Function (ECDF), serta k-means dan elbow method. Tujuan uraian pada bab ini adalah untuk 1) menilai dan membandingkan CPUE ikan madidihang, tuna mata besar, dan cakalang serta mengevaluasi faktor-faktor yang mempengaruhi perbedaan CPUE antar spesies.

2) Mengidentifikasi alat tangkap utama yang digunakan untuk masing-masing spesies ikan. 3) Menganalisis perbedaan penggunaan alat tangkap dalam penangkapan ikan. 3) Menganalisis pengaruh durasi hari di laut dan jenis kapal CPUE, serta memahami faktor-faktor yang berkontribusi terhadap hasil tangkapan ikan. 4) Mengkaji pengelolaan perikanan yang



berkelanjutan berdasarkan karakteristik spesies ikan, dengan mempertimbangkan durasi melaut yang optimal dan pemilihan alat tangkap yang selektif serta ramah lingkungan guna menjaga keberlanjutan sumber daya ikan dan ekosistem laut.

3.2.2 Data

Jenis data yang digunakan terdiri atas data jumlah tangkapan ikan (Catch Per Unit Effort, CPUE) ikan pelagis (cakalang, madidihang, dan tuna mata besar), tonnase kapal, alat tangkap, dan hari laut. Data tangkapan ikan, tonnase kapal, alat penangkap ikan, dan hari laut diakses melalui Direktorat Jenderal (Dirjen) Sumber Daya Ikan (SDI) Kementerian Kelautan dan Perikanan (KKP) dan Sekretariat Lembaga Pengelola Perikanan (LPP) Unit Pengelola Perikanan WPPNRI 714 di Pelabuhan Perikanan Samudera Kendari. Unit PP WPP 714 dibentuk berdasarkan PermenKP No. 33/Permen-KP/2019 yang menetapkan tentang Organisasi dan Tata Kerja (OTK) LPP di seluruh WPPNRI. Wilayah kerja LPP WPP 714 meliputi sejumlah Pelabuhan Perikanan yang tersebar di seluruh WPP 714, yang terdiri atas: (i) Provinsi Sulawesi Tenggara: UPT Pusat (PPS Kendari), dan UPTD Kab./Kota (PP Sampolawa, PP Pasar Wajo, PP Wameo, PP Kamaru, PP Laino, PP Torobulu, dan PP Lasolo), (ii) Provinsi Sulawesi Tengah: UPTD Kab./Kota (PP Bungku, PP Umbele, dan PP Rata/Toili Barat, dan (iii) Provinsi Maluku: UPT Pusat (PPN Ambon dan PPN Tual), dan UPTD Kab./Kota (PPI Banda, PP Masarete, PP Leihitu, PP Eri, PP Salahutu, PP Masohi, PP Tehoru, PP Tamher Timur, PP Ukurlaran, PP Panambungan, dan PP Wetar) (https://pipp.djpt.kkp.go.id/profil_pelabuhan/kategori_pelabuhan). Sebaran Pelabuhan Perikanan dapat dilihat pada gambar 3.1 berikut.



Sumber: <https://pipp.djpt.kkp.go.id>
bar 3.1 Peta Pelabuhan Perikanan di WPP 714



Jumlah Kelas Pelabuhan Perikanan di WPP 714 yang tayang di laman https://pipp.djpt.kkp.go.id/profil_pelabuhan/kategori_pelabuhan sebanyak 24 unit (1 PPS, 2 PPN, dan 21 PP UPTD), namun dalam Rencana Induk Pelabuhan Perikanan Nasional, disebutkan ada sebanyak 49 Pelabuhan Perikanan, terdiri atas: 1 PPS, 2 PPN, dan 46 PP (KepMenKP No. 45/KEPMEN-KP/2014).

Data bulanan tangkapan ikan, termasuk faktor-faktor teknis penangkapan ikan (CPUE)) didapat dari hasil rekapan logbook penangkapan ikan, sebagaimana diatur pada Lampiran I Peraturan Menteri Kelautan dan Perikanan No. 48/Permen-kp/2014 tentang Logbook Penangkapan Ikan. Pengisian Logbook tersebut diwajibkan bagi seluruh kapal perikanan. Pasal 16 ayat (1) memerintahkan nakhoda kapal untuk menyerahkan logbook penangkapan ikan, sebagai dasar penerbitan Surat Persetujuan Berlayar (SPB). Kemudian pada pasal 17 ayat (1) memerintahkan nakhoda kapal penangkap ikan untuk mengisi Logbook sesuai panduan.

Logbook tersebut berisi isian sejumlah informasi penting, yakni: nama kapal, nama perusahaan, nomor SIPI, jenis/kode alat penangkap ikan, gross tonnage, panjang kapal, daya kuda, radio panggil, pelabuhan keberangkatan, tanda selar, ABK, WPP, Daerah Penangkapan Ikan, pelabuhan pendaratan, tanggal aktivitas, kode aktivitas, posisi aktivitas, waktu mulai setting, jumlah mata pancing, jarak antar mata pancing, dan komposisi ikan hasil tangkap. Jumlah tangkapan ikan per hari, serta jenis dan jumlah kapal per tahun didapatkan dari logbook perikanan tangkap di WPP 714 yang dibuat oleh Dirjen SDI KKP, khususnya sejak tahun 2014 s.d. 2022.

3.2.3 Metode Penelitian

3.2.3.1 Pengolahan data salinitas, kedalaman, dan arus

Data oseanografi berupa salinitas, kedalaman, dan arus laut diunduh dari Copernicus Marine Service untuk periode 2014–2020 menggunakan produk GLOBAL_MULTIYEAR_PHY_001_030 dengan resolusi $0.0830^{\circ} \times 0.0830^{\circ}$ dan 50 level kedalaman. Data mencakup kolom kedalaman (depth), salinitas (so dalam promil), serta kecepatan arus timur-barat (uo) dan utara-selatan (vo) dalam m/s. Setiap parameter dipecah menjadi 50 kolom sesuai level kedalaman, dan nilai diambil sebagai rerata bulanan pada tanggal 16 setiap bulan (kecuali Februari pada tanggal 15). Dalam proses cleaning, nilai NA diganti dengan 0, lalu diisi dengan nilai prediksi jika dataframe memiliki minimal 70% data valid. Hasilnya, data sal_32 memiliki kelengkapan 70%, sedangkan sal_33 hingga sal_50 berada di bawah ambang batas sehingga tidak digunakan lebih lanjut.

3.2.3.2 Pengolahan dataset perikanan tangkap WPP 714

Data hasil tangkapan ikan di WPP 714 diperoleh dari Deputi Pengelolaan Sumber Daya Ikan (SDI) DJPT KKP dan mencakup periode 2014–2022 dalam dua tahun dan data 2021–2022. Kedua dataset memiliki struktur awal 39,524 baris pada dataset pertama dan 27,593 baris pada dataset kedua. Setelah penggabungan data, dilakukan cleaning and wrangling, untuk menyisihkan data yang tidak relevan dan merestrukturisasi data.



agar lebih terorganisir. Proses ini menghasilkan 16 kolom dan 55,249 baris, dengan informasi utama seperti nama kapal, alat tangkap, lokasi tangkapan, jumlah tangkapan, dan CPUE.

Selanjutnya, dilakukan sortir spesies ikan target untuk dianalisis lebih lanjut, serta pemanfaatan koordinat bujur dan lintang guna memprediksi faktor oseanografis seperti klorofil, suhu, salinitas, dan arus. Hasil akhir cleaning and wrangling dikategorikan dalam tiga kelompok: (1) berdasarkan klorofil dan SST, (2) berdasarkan klorofil, SST, salinitas, UO, dan VO, serta (3) berdasarkan salinitas, UO, dan VO.

3.2.3.3 Dinamika Kapal Perikanan di Area Daerah Pemijahan dan Daerah Bertelur Ikan Madidihang (*Thunnus albacares*) pada bulan Oktober – Desember dan Bulan Lainnya

PermenKP No. 26/Permen-KP/2020 tentang Larangan Penangkapan Ikan Madidihang di Daerah Pemijahan dan Daerah Bertelur di Wilayah Pengelolaan Perikanan Negara Republik Indonesia 714 pada Bulan Oktober–Desember menetapkan larangan pada Daerah pemijahan dan daerah bertelur meliputi wilayah yang terbentuk dari garis lurus yang ditarik mulai dari koordinat 126° – 132° Bujur Timur dan 4° – 6° Lintang Selatan, dikurangi wilayah perairan laut dalam radius 12 (dua belas) mil laut dari garis pantai pada pulau-pulau di dalam dan sekitar daerah larangan Penangkapan Ikan.

Wilayah larangan tersebut sekitar 13,596,042 ha atau sekitar 21% dari luas WPP 714, merupakan lokasi target pantauan terhadap aktivitas kapal perikanan, khususnya pada bulan Oktober – Desember dan dibandingkan juga dengan bulan lainnya, termasuk dinamikanya sebelum dan sesudah diterbitkannya PermenKP No. 26/Permen-KP/2020.

Perairan tersebut merupakan perairan khusus di sektor perikanan tangkap, maka seyogyanya kebijakan terkait penetapan lokasi tersebut dapat dievaluasi untuk memastikan efektivitasnya. Salah satu upaya yang relevan adalah melakukan evaluasi terhadap aktivitas kapal yang beroperasi di area tersebut, khususnya pada bulan Oktober – Desember, baik pada penangkapan cakalang, madidihang, maupun tuna mata besar. Data kapal untuk kebutuhan identifikasi berasal dari logbook. Berdasarkan hasil identifikasi tersebut dapat digunakan untuk mengevaluasi kepatuhan kapal-kapal perikanan pada zona larangan yang dimaksud.

Untuk mengidentifikasi aktivitas kapal di zona larang tersebut, digunakan library(sf) yang tersedia pada R Studio. Ada tiga fungsi yang merupakan bagian dari Simple Features (sf) library di R, dan secara khusus termasuk dalam kategori fungsi geometri yang digunakan untuk manipulasi data spasial. Fungsi `st_as_sf()` berfungsi sebagai Konversi ke Simple Feature (SF Object), digunakan untuk mengubah objek R (seperti dataframe) menjadi objek geospasial dalam format sf.

Selanjutnya, fungsi `st_linestring()` berperan sebagai Konstruktor LineString, yang membuat geometri garis (LineString) dari kumpulan koordinat. Fungsi `st_sfc()`, yang dikenal sebagai Simple Feature Collection, akan digunakan untuk membuat koleksi geometri sederhana (Simple Geometry), seperti POINT, LINESTRING, atau POLYGON, dengan



menyertakan sistem referensi koordinat (CRS). Ketiga fungsi ini sangat penting dalam analisis dan visualisasi data spasial di R.

Data kapal perikanan tangkap di perairan WPP 714 yang dihasilkan dari penggunaan fungsi-fungsi geometri di atas memperlihatkan sejumlah informasi dalam bentuk visual (peta) dan tabel. Pada peta akan nampak polygon berupa area larang di WPP 714, yang di dalamnya ada POINT sebagai indikator kapal, dan dalam tabel akan men-subset data lengkap kapal yang terdeteksi berada di dalam area larang. Dari data tersebut akan bisa nampak pula bagaimana aktivitas kapal tertentu melakukan aktivitas penangkapan lebih dari 1 jenis ikan. Dengan demikian, data tersebut memberikan petunjuk bahwa pada lokasi area larang di periode larang madidihang, bisa jadi ada aktivitas kapal yang dilaporkan menangkap cakalang dan tuna mata besar, namun kenyataannya juga menangkap ikan madidihang yang dilarang untuk ditangkap pada area dan periode larang tersebut.

3.2.3.4 Perhitungan Catch Per Unit Effort (CPUE)

CPUE merupakan salah satu indikator utama dalam analisis perikanan yang digunakan untuk menggambarkan kelimpahan stok ikan serta efisiensi penangkapan. CPUE dihitung berdasarkan berat tangkapan ikan (kg) dibandingkan dengan upaya penangkapan yang dilakukan. Dalam penelitian ini, upaya penangkapan diukur menggunakan hari_laut, yaitu jumlah hari kapal melakukan operasi penangkapan ikan di laut.

Hari_laut didefinisikan sebagai selisih antara tanggal kedatangan kapal dan tanggal keberangkatan kapal, ditambah satu hari untuk memastikan perhitungan mencakup seluruh periode operasi. Secara matematis, CPUE dihitung menggunakan rumus (Huang et al., 2021):

$$CPUE = \Sigma C / \Sigma f$$

di mana:

- C adalah berat tangkapan ikan (kg),
- f adalah upaya penangkapan yang dalam penelitian ini diwakili oleh hari_laut,
- hari_laut = (tanggal kedatangan - tanggal keberangkatan) + 1.

3.2.3.5 Fitting Generalized Additive Model (GAM) dan Empirical Cumulative Distribution Functions (ECDF)

Model GAM menggunakan paket 'mgcv' pada software R. Goodness of fit-nya menggunakan Akaike's Information Criteria (AIC) terkecil dan nilai Cumulative Deviance Explained (CDE) tertinggi serta taraf signifikansi terbesar dari setiap model GAM yang terbentuk (Semedi et al., 2021).

Adapun faktor-faktor teknis perikanan tangkap yang menjadi input model GAM dalam penelitian ini adalah tonnase kapal, jenis alat tangkap, dan hari laut. Hastie and Tibshirani (1986) mengemukakan Model GAM sebagai berikut:



$$g(\mu(x)) = \eta(x) = \alpha + \sum_{i=1}^p f_i(x_i)$$

nyatakan dengan g, vektor variabel prediktor teknis dinyatakan

dengan x_i . Prediktor aditif dinyatakan dengan $\eta(x)$, μ merupakan respons rata-rata variabel, konstanta perpotongan (intersep) dinyatakan dengan α , jumlah hari laut dinyatakan dengan p , dan f_i merupakan fungsi non-parametrik yang ke- i . Kelebihan model ini adalah dapat menggambarkan tingkat faktor-faktor oseanografi optimum, yakni hasil tangkapan diprediksi lebih besar.

Untuk menentukan kisaran faktor teknis yang signifikan terhadap tingkat hasil tangkapan ikan di atas rata-rata, maka digunakan analisis ECDF. Andrade dan Garcia (1999) juga Zainuddin et al. (2008) menggunakan tiga fungsi:

$$f(t) = \frac{1}{n} \sum_{i=1}^n l(x_i)$$

dengan fungsi indikator

$$l(x_i) = \begin{cases} 1, & \text{jika } x_i \leq t \\ 0, & \text{sebaliknya} \end{cases}$$

$$g(t) = \frac{1}{n} \sum_{i=1}^n \frac{y_i}{\bar{y}} l(x_i)$$

$$D(t) = \max |f(t) - g(t)|$$

Jumlah hari laut dinyatakan dengan $f(t)$ atau fungsi distribusi frekuensi kumulatif empiris. Jumlah tangkapan (CPUE di atas rata-rata) dinyatakan dengan $g(t)$ atau fungsi distribusi kumulatif hasil tangkapan terboboti. Fungsi indikasi dinyatakan dengan $l(x_i)$, yang memberikan nilai 1 jika jumlah kapal, jenis alat tangkap, dan pelayan pada posisi tersebut dan 0 jika kebalikannya. Nilai $D(t)$ merupakan nilai absolut perbedaan pada kurva $f(t)$ dan $g(t)$ di setiap hari laut t , dan dianalisis menggunakan standard Kolmogorov-Smirnov test. Jumlah hari laut penangkapan dinyatakan dengan n , variabel teknis dalam hari laut penangkapan i dinyatakan dengan x_i , t adalah sebuah indeks, yang mana observasi terurut dari nilai rendah hingga nilai tinggi pada variabel teknis, CPUE yang diperoleh pada hari laut penangkapan ke- i dinyatakan dengan y_i , sedangkan $\bar{y}$ adalah nilai rerata CPUE estimasi untuk seluruh hari laut. Label “max” menunjukkan nilai spesifik dari variabel ketika perbedaan antara dua kurva ($Dg(t) - Df(t)$) adalah maksimum.

Grafik ECDF digunakan untuk melihat distribusi data setiap parameter. Grafik ECDF membantu menemukan nilai yang memberikan perbedaan maksimum antara dua fungsi. Hubungan signifikan antara variabel target dan prediktor menampilkan plot ECDF, yang merepresentasikan nilai-nilai dalam data. Garis pada grafik menunjukkan ECDF dari data variabel prediktor. Plot tersebut menunjukkan nilai maksimum. Namun, nilai-nilai tersebut tidak secara otomatis menunjukkan nilai variabel prediktor yang signifikan. Untuk menentukan signifikansi dari kedua parameter ini, dilakukan uji Kolmogorov-Smirnov 2 variabel untuk menguji kesesuaian antara sampel data dan distribusi yang telah ditentukan sebelumnya. Jika hasil pengujian menunjukkan bahwa nilai p tidak signifikan, maka selanjutnya dilakukan analisis segmentasi menggunakan k-means



Dalam rumus K-means clustering berikut, jarak antara titik data x_i dan centroid c_j adalah $d(x_i, c_j)$, x_{im} adalah komponen ke- m dari titik data x_i , C_{jm} adalah komponen ke- m dari centroid c_j , dan M adalah jumlah fitur.

$$d(x_i, c_j) = \sqrt{\sum_{m=1}^M (x_{im} - c_{jm})^2}$$

Dalam persamaan uji ANOVA di bawah ini, SST adalah variasi total dalam data, SSB adalah variasi antar kelompok, SSW adalah variasi dalam kelompok, MSB adalah rata-rata variasi antar kelompok, MSW adalah rata-rata variasi dalam kelompok, dan F-statistik adalah rasio antara MSB dan MSW; ini digunakan untuk menentukan signifikansi perbedaan antara rata-rata kelompok.

$$\begin{aligned} SST &= \sum_{i=1}^N (Y_i - \bar{Y})^2 \\ SSB &= \sum_{j=1}^k (\bar{Y}_j - \bar{Y})^2 \\ SSW &= \sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ij} - \bar{Y}_j)^2 \\ MSB &= \frac{SSB}{k-1} \\ MSW &= \frac{SSW}{N-k} \\ F &= \frac{MSB}{MSW} \end{aligned}$$

Uji Tukey's Honestly Significant Difference (HSD) atau sering disebut uji HSD adalah metode yang digunakan untuk membandingkan rata-rata kelompok. Dalam persamaan di bawah ini, q adalah nilai distribusi Studentized Range (q -distribution) untuk tingkat signifikansi tertentu dan derajat kebebasan $N-kN-k$, MSW adalah Mean Square Within-Group dari uji ANOVA, dan n adalah jumlah observasi per kelompok atau ukuran sampel rata-rata jika ukuran kelompok bervariasi.

$$HSD = q \sqrt{\frac{MSW}{n}}$$

Berikut ini adalah formula Elbow method. WCSS adalah singkatan dari Within-Cluster Sum of Squares. Dalam persamaan (11) di bawah ini, C_j adalah kluster ke- j , x_i adalah titik data ke- i , C_j adalah centroid dari kluster ke- j , dan $\|x_i - C_j\|^2$ adalah kuadrat jarak Euclidean antara titik data x_i dan centroid C_j .

$$WCSS(k) = \sum_{j=1}^k \sum_{x_i \in C_j} \|x_i - C_j\|^2$$

3.2.3.6 Tuning Model Melalui Random Forest

Random Forest adalah algoritma pembelajaran mesin berbasis ensemble yang menggabungkan banyak pohon keputusan (decision trees) untuk membuat prediksi. Algoritma ini menggunakan teknik bootstrap sampling untuk membuat subset data, serta subset fitur secara acak untuk mengurangi korelasi antar pohon. Teknik ini membuat Random Forest tahan terhadap overfitting dalam menangani dataset besar dengan banyak fitur (Breiman,



ion T_i dilatih pada subset data yang berbeda, diambil

menggunakan metode bootstrap sampling. Jika dataset asli memiliki n fitur, subset data X_i dibentuk sebagai:

$$\text{Subset Data } X_i \subset X$$

Pada setiap split dalam pohon keputusan, hanya sebagian fitur (m) yang dipilih secara acak untuk mengurangi risiko overfitting. Subset fitur (F) didefinisikan sebagai:

$$F \subset \{1, 2, \dots, n\}, \text{ dengan ukuran } m$$

Pemilihan subset data dan subset fitur ini adalah langkah penting untuk memastikan setiap pohon memiliki variasi yang signifikan dan meminimalkan korelasi antar pohon (Ho, 1995).

Setiap pohon dalam hutan memberikan prediksi $hi(X)$, di mana $hi(X)$ adalah hasil output pohon ke- i . Untuk regresi, nilai prediksi $hi(X)$ adalah rata-rata nilai target di daun yang sesuai. Untuk klasifikasi, nilai prediksi $hi(X)$ adalah label kelas yang dipilih berdasarkan frekuensi tertinggi (voting).

Prediksi individu dari setiap pohon memberikan fleksibilitas untuk menangani berbagai jenis data, baik dalam masalah regresi maupun klasifikasi (Breiman, 2001). Prediksi akhir dari Random Forest diperoleh dengan menggabungkan hasil prediksi dari semua pohon. Untuk regresi, prediksi akhir $\hat{y}$ dihitung sebagai rata-rata aritmatika prediksi dari N pohon:

$$\hat{y} = (1/N) \sum_{i=1}^N hi(X)$$

Untuk Klasifikasi: Prediksi akhir $\hat{y}$ diperoleh dari voting mayoritas:

$$\hat{y} = \text{mode} \{h_1(X), h_2(X), \dots, h_N(X)\}$$

Di mana mode adalah label kelas yang paling sering dipilih oleh pohon-pohon dalam hutan. Metode agregasi ini membuat prediksi lebih stabil dan akurat dibandingkan pohon tunggal (Hastie et al., 2009).

Algoritma Random Forest memiliki beberapa keunggulan, termasuk kemampuan untuk mengatasi data dengan banyak fitur, mengurangi risiko overfitting melalui penggunaan subset data dan fitur, serta memberikan hasil yang stabil meskipun terdapat noise pada data (Breiman, 2001).

3.2.3.7 Tuning Model Melalui Boosted Regression Tree (BRT)

Untuk membandingkan model regresi terbaik, selain GAM dan Random Forest, tuning model juga dilakukan menggunakan metode BRT. Metode ini digunakan untuk menilai kontribusi variabel prediktor terhadap variabel target, serta menghasilkan model dan prediksi dengan Goodness of fit dan nilai akurasi yang baik (Hastie et al., 2009).

Klasifikasi dan regresi adalah jenis supervised learning yang dapat diselesaikan dengan algoritma seperti linear regression, logistic regression, dan decision tree. Teknik ensemble, di sisi lain, menggabungkan banyak model untuk menghasilkan hasil yang lebih efektif. Beberapa teknik ensemble meliputi bagging, boosting, dan random forest (Breiman, 2001).

Boosting adalah teknik ensemble sekuensial di mana setiap model baru akan informasi dari model sebelumnya (weaker models). Model sidu atau kesalahan dari model sebelumnya, sehingga model asi yang lebih tinggi (Friedman, 2001). Jenis teknik boosting



meliputi: AdaBoost (Adaptive Boosting), Gradient Boosting, dan XGBoost (Extreme Gradient Boosting).

Gradient Boosting adalah teknik di mana setiap model baru mempelajari residu dari model sebelumnya dengan tujuan meminimalkan kesalahan menggunakan fungsi kehilangan (loss function):

$$L(y, f(x)) = \sum (y_i - f(x_i))^2$$

di mana:

y : nilai aktual,

$f(x)$: prediksi model,

$\sum$: fungsi penjumlahan kesalahan.

Evaluasi model dilakukan dengan menghitung Root Mean Square Error (RMSE) dan R-squared (R^2).

$$RMSE = \sqrt{(\sum (y_i - \hat{y}_i)^2 / n)}$$

di mana:

y_i : nilai aktual,

$\hat{y}_i$: nilai prediksi,

n : jumlah data.

RMSE menunjukkan seberapa jauh prediksi dari nilai aktual. Nilai RMSE yang lebih rendah menunjukkan akurasi model yang lebih baik (Chollet, 2018).

$$R^2 = 1 - (RSS / TSS)$$

Di mana:

RSS (Residual Sum of Squares) = $\sum (y_i - \hat{y}_i)^2$,

TSS (Total Sum of Squares) = $\sum (y_i - \bar{y})^2$,

$\bar{y}$: nilai rata-rata dari data aktual.

R^2 menunjukkan seberapa baik model dapat menjelaskan variabilitas data. Nilai R^2 yang mendekati 1 menunjukkan model yang sangat baik (Hastie et al., 2009).

Gradient Boosting Tree memberikan hasil prediksi yang lebih akurat dibandingkan model ensemble lain seperti bagging atau random forest, khususnya untuk dataset dengan pola yang kompleks (Friedman, 2001).

3.3 Hasil Penelitian

3.3.1 Pengolahan Data Salinitas, Kedalaman, dan Arus

Data salinitas, kedalaman, dan arus diunduh dari situs Copernicus Marine Service (<https://data.marine.copernicus.eu/products>) dari tahun 2014 s.d. 2020. Dari situs tersebut, produk yang dipilih adalah model GLOBAL_MULTIYEAR_PHY_001_030 untuk rerata bulanan, dengan resolusi 0.0830 x 0.0830 x 50 levels. Adapun level kedalamannya (m) adalah: 0.49 (level 1), 1.54 (level 2), 2.65 (level 3), 3.82 (level 4), 5.08 (level 5), 6.44 (level 6), 7.93 (level 7), 9.57 (level 8), 11.41 (level 9), 13.47 (level 10), 15.81 (level 11), 18.50 (level 12), 21.60 (level 13), 25.21 (level 14), 29.44 (level 15), 34.43 (level 16), 40.34 (level 17), 46.57 (level 18), 55.76 (level 19), 65.81 (level 20), 77.85 (level 21), 92.33 (level 23), 130.67 (level 24), 155.85 (level 25), 186.13 (level 26), 226.04 (level 28), 318.13 (level 29), 380.21 (level 30), 453.94 (level 32), 643.57 (level 33), 763.33 (level 34), 902.34 (level 35),



1062.44 (level 36), 1245.29 (level 37), 1452.25 (level 38), 1684.28 (level 39), 1941.89 (level 40), 2225.078 (level 41), 2533.34 (level 42), 2865.70 (level 43), 3220.82 (level 44), 3597.03 (level 45), 3992.48 (level 46), 4405.22 (level 47), 4833.29 (level 48), 5274.78 (level 49), dan 5727.92 (level 50).

Kolom data oseanografi pada produk tersebut terdiri dari 'depth..m..DOUBLE' yang merupakan kedalaman dengan satuan m, 'so..1e.3..DOUBLE' adalah salinitas dengan satuan promil, 'uo..m.s.1..DOUBLE' merujuk pada komponen kecepatan arus laut dalam arah timur-barat (u), diukur dalam meter per detik (m/s), dan 'vo..m.s.1..DOUBLE' merupakan komponen kecepatan arus laut dalam arah utara-selatan (v), juga diukur dalam meter per detik (m/s).


Data diolah, kolom 'Sal' menunjukkan salinitas yang tersedia sebanyak 50 nilai berdasarkan level kedalaman. Kolom 'Sal' tersebut terdiri dari 'Sal1' untuk level 1 (kedalaman 0.49), 'Sal2' untuk level 2 (kedalaman 1.54), ... 'Sal50' untuk level 50 (kedalaman 5727.92). Kemudian kolom 'UO' menjadi 'UO1' untuk level 1 (kedalaman 0.49), 'UO2' untuk level 2 (kedalaman 1.54), ... 'UO50' untuk level 50 (kedalaman 5727.92). Berikutnya adalah kolom 'VO' menjadi 'VO1' untuk level 1 (kedalaman 0.49), 'VO2' untuk level 2 (kedalaman 1.54), ... 'VO50' untuk level 50 (kedalaman 5727.92).

Data kolom salinitas dan kecepatan arus di atas merupakan rerata bulanan yang diambil setiap pertengahan bulan. Data diambil pada 16 setiap bulannya, kecuali untuk bulan Februari yang diambil pada setiap tanggal 15.

Setelah proses cleaning and wrangling data, ditemukan bahwa terdapat sejumlah baris pada kolom 'Sal', 'UO', dan 'VO' mengandung nilai 'NA' ("Not Available"). Selanjutnya NA diganti dengan nilai 0. Lalu nilai 0 tersebut diganti dengan nilai prediksi, dengan syarat dataframe yang diisi dengan nilai prediksi tersebut memiliki nilai data minimal sebanyak 70%.

Berdasarkan hasil pengolahan data tersebut, nampak bahwa dataframe 'sal_32' menunjukkan nilai data sebesar 70%. Sementara itu 'sal_33' s.d. 'sal_50' nilai dataframe berada di bawah 70%. Secara visual dataframe salinitas ditunjukkan pada gambar 3.2 berikut.






Sumber: <https://data.marine.copernicus.eu> (Diolah)
 Gambar 3.2 Grafik Dataframe Salinitas dengan Nilai Data $\leq 70\%$

Pada dataframe 'UO' nampak bahwa terhitung dari 'UO33' s.d. 'UO50' nilai data berada di bawah 70%, sebagaimana ditunjukkan pada gambar 3.3 berikut.






Sumber: <https://data.marine.copernicus.eu> (Diolah)
 Gambar 3.3 Grafik Dataframe UO dengan Nilai Data $\leq 70\%$

Demikian pula halnya pada dataframe 'VO' nampak bahwa terhitung dari 'VO33' s.d. 'VO50' nilai data berada di bawah 70%, sebagaimana ditunjukkan pada gambar 3.4 berikut.



Optimized using
 trial version
www.balesio.com



Sumber: <https://data.marine.copernicus.eu> (Diolah)
Gambar 3.4 Grafik Dataframe VO dengan Nilai Data $\leq 70\%$

3.3.2 Pengolahan Data Hasil Tangkapan Ikan

Data hasil tangkapan ikan di WPP 714 diakses melalui Deputi Pengelolaan Sumber Daya Ikan (SDI) Direktorat Jenderal Perikanan Tangkap (DJPT) Kementerian Kelautan dan Perikanan (KKP). Data tersebut merupakan akumulasi dari tahun 2014 s.d. 2022. Data tersebut terdiri dari dua format. Format pertama terdiri dari data 2014 s.d. 2020, dan yang kedua berisi data 2021 s.d. 2022.

Adapun kolom-kolom pada data yang pertama terdiri atas 15 kolom dan 39,524 kolom, yakni: 'nama_kapal', 'gt_kapal', 'jenis_ijin', 'nama_alat_tangkap', 'hari_laut', 'nama_pelabuhan_kedatangan', 'nama_dpi', 'id_wpp', 'tanggal_tangkap', 'nama_jenis_ikan', 'nama_latin', 'jumlah_ikan', 'berat_ikan', 'lintang_decimal', dan 'bujur_decimal'. Sedangkan kolom-kolom pada data yang kedua terdiri atas 15 kolom (beberapa memiliki perbedaan dengan data yang pertama) dan 27,593 baris, yakni: 'id_logbook', 'setting', 'tanggal_keberangkatan', 'tanggal_kedatangan', 'gt_kapal', 'nama_alat_tangkap', 'nama_pelabuhan_kedatangan', 'tanggal_tangkap', 'jumlah_pancing', 'nama_jenis_ikan', 'nama_latin', 'berat_ikan', 'lintang_decimal', 'bujur_decimal', dan 'wpp'.



nggabungkan kedua data di atas, dilanjutkan dengan cleaning a. Cleaning data atau pembersihan data adalah proses a yang salah atau tidak relevan agar tidak memengaruhi an data dilakukan dengan berbagai cara, seperti menghapus

sel atau baris.

Wrangling data, juga dikenal sebagai data munging atau data remediation, merupakan proses mengubah data mentah menjadi data dengan format yang lebih terstruktur. Proses ini melibatkan pengumpulan, analisis, pengolahan, dan penataan data yang masih mentah agar bisa dibaca dan dianalisis dengan lebih mudah.

Proses cleaning and wrangling data pada gabungan data di atas, menghasilkan 16 kolom dan 55,249 baris. Kolom yang dimaksud adalah: 'nama_kapal&id', 'setting', 'gt_kapal', 'jenis_ijin', 'alat_tangkap', 'hari_laut', 'pelabuhan_kedatangan', 'nama_dpi', 'wpp', 'tanggal_tangkap', 'jumlah_pancing', 'jenis_ikan', 'nama_latin', 'bujur', 'lintang', 'berat_ikan', dan CPUE.


Langkah selanjutnya adalah melakukan sortir pada spesies ikan yang ditargetkan untuk diolah dan analisis selanjutnya. Dataframe yang dihasilkan tersebut selanjutnya digunakan untuk beberapa kebutuhan, antara lain memanfaatkan koordinat 'bujur', dan 'lintang' lokasi tangkapan untuk digunakan melakukan prediksi terhadap nilai faktor-faktor oseanografis: klorofil, suhu, salinitas, dan arus.

Hasi cleaning and wrangling data dibuat dalam tiga kategori: (1) tangkapan ikan berdasarkan parameter klorofil dan SST, (2) tangkapan ikan berdasarkan parameter klorofil, SST, salinitas, UO, dan VO, serta (3) tangkapan ikan berdasarkan parameter salinitas, UO, dan VO.

Pada kategori pertama terdiri dari 55,249 baris dan 18 kolom. Jumlah jenis ikan pada kategori ini sebanyak 100 jenis ikan.

Dari kategori I di atas, dipilih 3 jenis ikan pelagis (tuna) yang memiliki jumlah baris tertinggi. Jumlah baris tertinggi menunjukkan frekuensi penangkapan tertinggi. Dari 20 jenis ikan yang ditampilkan sebagai frekuensi penangkapan tertinggi, nampak bahwa cakalang (SKJ), madidihiang (YFT), laying deles dan tuna mata besar (BET), (tampak pada Gambar 3.5).






Gambar 3.5 Jenis Ikan pada Kategori I

Pada kategori kedua dan ketiga terdiri dari 28,599 baris, 117 kolom untuk kategori II dan 115 kolom untuk kategori III. Jumlah jenis ikan pada kategori ini sebanyak 100 jenis ikan. Namun, berdasarkan frekuensi baris pada dataframe hanya empat jenis ikan yang memiliki baris.

Dari kategori II dan III di atas, dipilih 3 jenis ikan pelagis (tuna) yang memiliki jumlah baris tertinggi. Jumlah baris tertinggi menunjukkan frekuensi penangkapan tinggi. Dari 20 jenis ikan yang ditampilkan sebagai frekuensi penangkapan tertinggi, nampak bahwa cakalang (SKJ), madidihiang (YFT), dan tuna mata besar (BET), (tampak pada Gambar 3.6). Proses di atas disebut metode seleksi data frekuensi penangkapan ikan berbasis parameter lingkungan, karena melibatkan seleksi spesifik berdasarkan parameter oseanografis dan jumlah baris tertinggi.





Gambar 3.6 Jenis Ikan pada Kategori II dan III

3.3.3 Tantangan penangkapan ikan di area larang WPP 714

3.3.3.1 Tahun 2016

Berdasarkan analisis data, kapal bernama SARI MULYA berbobot 30 GT memiliki Ijin Pusat dan menggunakan dua jenis alat tangkap, yaitu Rawai Tuna dan Hand Line Tuna, untuk menangkap berbagai jenis ikan. Kapal ini melakukan penangkapan di pelabuhan PP. Ambon pada beberapa tanggal berbeda. Pada 1 Oktober 2016, kapal menangkap ikan Madidihiang menggunakan alat tangkap Rawai Tuna. Sementara itu, pada 4 dan 6 Oktober 2016, kapal ini menangkap ikan Madidihiang dan juga melakukan penangkapan dengan alat Hand Line Tuna. Hal ini menunjukkan bahwa kapal SARI MULYA memiliki aktivitas penangkapan yang mencakup lebih dari satu jenis ikan dengan metode tangkap yang berbeda di area larang WPP 714.

3.3.3.2 Tahun 2017

Data tahun 2017, ditemukan bahwa kapal FAUZIYYAH 01 berbobot 30 GT dan MINA MARITIM 115 berbobot 29 GT menangkap lebih dari satu jenis ikan pada area dan periode larang WPP 714. Kedua kapal ini memiliki izin jenis Ijin Pusat dan menggunakan alat tangkap Purse Seine (Pukat Cincin). Keduanya beroperasi di pelabuhan PP. Kendari. Kapal FAUZIYYAH 01 menangkap ikan Madidihiang, sedangkan kapal MINA MARITIM 115 juga menangkap Madidihiang pada hari yang sama dengan metode tangkap yang menunjukkan aktivitas penangkapan yang seragam untuk kedua waktu dan lokasi yang sama di area larang WPP 714.



3.3.3.3 Tahun 2018

Berdasarkan analisis data tahun 2018, ditemukan bahwa kapal BINTANG MUTIARA II dengan bobot 52 GT menangkap lebih dari satu jenis ikan. Kapal ini memiliki izin jenis Ijin Pusat dan menggunakan alat tangkap Rawai Tuna. Kapal ini melakukan aktivitas penangkapan di pelabuhan PU Tanjung Benoa pada 11 Desember 2018, di mana ikan yang ditangkap adalah Tuna Mata Besar dan Madidihiang. Hal ini menunjukkan bahwa kapal ini aktif dalam menangkap beberapa jenis ikan pada hari yang sama menggunakan metode tangkap yang sama di area larang WPP 714.

3.3.3.4 Tahun 2019

Pada tahun 2019, beberapa kapal melakukan penangkapan lebih dari satu jenis ikan, termasuk kombinasi spesifik seperti cakalang dan madidihiang, serta madidihiang dan tuna mata besar. Kapal HALLUNTAI ARQAN 22 dengan bobot 15 GT berijin Daerah menggunakan alat tangkap Pancing Tonda. Kapal ini menangkap ikan Cakalang pada 7, 8, dan 9 Oktober 2019, serta ikan Madidihiang pada 7, 8, dan 24 November 2019. Selain itu, kapal ini juga menangkap Tuna Mata Besar pada 7 dan 11 Oktober 2019, menunjukkan aktivitas penangkapan lebih dari satu jenis ikan dengan metode yang sama.

Kapal TELUK BAKAU I dengan bobot 56 GT berijin Pusat menggunakan alat tangkap Rawai Tuna di pelabuhan Ambon. Kapal ini menangkap ikan Madidihiang dan Tuna Mata Besar pada yang sama, yaitu 21 November 2019, menunjukkan kombinasi penangkapan kedua jenis ikan tersebut.

Selanjutnya, kapal BINTANG 04 dengan bobot 25 GT berijin Daerah menggunakan alat tangkap Pancing Tonda di pelabuhan Ambon. Kapal ini menangkap ikan Cakalang pada 10 November 2019 dan ikan Tuna Mata Besar pada 9 Desember 2019, memperlihatkan variasi dalam jenis ikan yang ditangkap. Kapal-kapal ini menunjukkan pola penangkapan ikan yang melibatkan lebih dari satu jenis, baik pada waktu yang berbeda maupun bersamaan, di lokasi yang sama. Hal ini menggambarkan fleksibilitas dalam aktivitas penangkapan ikan di di area larang WPP 714 selama tahun 2019.

3.3.3.5 Tahun 2020

Pada tahun 2020, sejumlah kapal melakukan aktivitas penangkapan yang mencakup lebih dari satu jenis ikan di wilayah WPP 714. Kapal SAMUDRA INDAH 033 dengan bobot 16 GT berijin Daerah menggunakan alat tangkap Pancing Tonda, tercatat menangkap ikan Cakalang pada 1 Oktober 2020 dan ikan Madidihiang pada 2 Oktober 2020. Kapal PENJURU BINTANG 04 dengan bobot 17 GT berijin Daerah, juga menggunakan Pancing Tonda, mencatat penangkapan ikan Cakalang pada 1 Oktober 2020, ikan Madidihiang pada 7 Oktober 2020, dan ikan Tuna Mata Besar pada 1 Oktober 2020. Selanjutnya, kapal BINTANG

bobot 22 GT menangkap ikan Cakalang pada 8 Oktober 2020, dan yang sama, dan ikan Tuna Mata Besar pada 12 November 2020, menggunakan alat tangkap yang sama. Kapal HALLINTAR ARQAN 20 mencatat penangkapan ikan Cakalang pada 10 November 2020,



ikan Madidihang dan ikan Tuna Mata Besar pada 11 November 2020. Kemudian, kapal ASRI JAYA 02 berbobot 21 GT menangkap ikan Cakalang, Madidihang, dan Tuna Mata Besar pada 9 November 2020. Semua kapal ini menggunakan alat tangkap Pancing Tonda, menunjukkan aktivitas penangkapan ikan yang bervariasi di lokasi yang sama dengan alat tangkap yang serupa di area larang WPP 714.

3.3.3.6 Tahun 2021

Pada tahun 2021, kapal ber-ID 211001571 dengan bobot 56 GT tercatat melakukan penangkapan lebih dari satu jenis ikan di area larang menggunakan alat tangkap Rawai Tuna. Kapal ini menangkap ikan Madidihang pada 13, 14, 15, dan 17 November 2021. Selain itu, kapal ini juga menangkap ikan Tuna Mata Besar pada 14 Oktober 2021 di lokasi yang sama, dengan menggunakan metode tangkap yang sama. Aktivitas ini menunjukkan bahwa kapal tersebut aktif menangkap kombinasi ikan Madidihang dan Tuna Mata Besar selama bulan Oktober dan November 2021 di area larang WPP 714.

3.3.3.7 Tahun 2022

Pada tahun 2022, ditemukan bahwa beberapa kapal menangkap lebih dari satu jenis ikan di wilayah WPP 714. Kapal ber-ID 221100357 dengan bobot 15 GT menggunakan alat tangkap Pancing Tonda. Kapal ini mencatat penangkapan ikan Cakalang dan ikan Madidihang pada 4 November 2022. Hal ini menunjukkan bahwa kapal tersebut menangkap kombinasi ikan Cakalang dan Madidihang pada waktu yang bersamaan. Kemudian, kapal ber-ID 221100335 dengan bobot 12 GT menggunakan alat tangkap Pancing Tonda tercatat melakukan penangkapan ikan Cakalang pada 5 November 2022 dan ikan Madidihang pada 6 November 2022, menunjukkan aktivitas penangkapan lebih dari satu jenis ikan dalam periode yang sama.

Selanjutnya, kapal dengan ID 221201221 berbobot 15 GT menggunakan alat tangkap yang sama, melakukan penangkapan ikan Cakalang pada 8 Desember 2022 dan ikan Madidihang pada 9 Desember 2022, serta ikan Tuna Mata Besar pada 10 Desember 2022, yang menunjukkan bahwa kapal ini menangkap lebih dari satu jenis ikan.

Kemudian, kapal ber-ID 221102850 dengan bobot 29 GT menggunakan alat tangkap Rawai Tuna melakukan penangkapan ikan Cakalang pada 6 November 2022, ikan Madidihang pada 7 November 2022, dan ikan Tuna Mata Besar pada 8 November 2022, memperlihatkan aktivitas penangkapan kombinasi ikan pelagis. Kapal-kapal tersebut menunjukkan pola penangkapan ikan yang mencakup lebih dari satu jenis ikan di lokasi area larang.

3.3.4 Peralatan tangkap



Berdasarkan dataset yang dianalisis, tercatat sebanyak 19 jenis alat tangkap untuk menangkap ikan cakalang, yaitu: 'Purse Seine Kecil', 'Huhate', 'Pukat Cincin Pelagis Kecil dengan Satu Iur', 'Pancing Tonda', 'Pukat Cincin Satu Kapal', 'Pancing ne Tuna', 'Pukat Cincin Grup Pelagis Kecil', 'Pukat Cincin

Pelagis Besar dengan Satu Kapal', 'Jaring Insang Lingkar', 'Huhate Mekanis', 'Pengangkut', 'Pukat Cincin Pelagis Kecil dengan Dua Kapal', 'Bagan Perahu', 'Rawai Tuna', 'Jaring Insang Lainnya', 'Rawai Hanyut', dan 'Jaring Insang Oseanik'.

Sementara itu, untuk alat tangkap ikan madidihang tercatat 15 jenis, yaitu: 'Purse Seine (Pukat Cincin) Pelagis Kecil', 'Rawai Tuna', 'Pancing Ulur', 'Pukat Cincin Pelagis Kecil dengan Satu Kapal', 'Pancing Tonda', 'Huhate', 'Hand Line Tuna', 'Pukat Cincin Satu Kapal', 'Pancing Berjoran', 'Pukat Cincin Pelagis Besar dengan Satu Kapal', 'Rawai Hanyut', 'Pukat Cincin Pelagis Kecil dengan Dua Kapal', 'Jaring Insang Lingkar', 'Pukat Cincin Grup Pelagis Kecil', dan 'Jaring Insang Lainnya'.


Untuk alat tangkap ikan tuna mata besar, tercatat sebanyak 11 jenis, yaitu: 'Rawai Tuna', 'Purse Seine (Pukat Cincin) Pelagis Kecil', 'Pancing Tonda', 'Pancing Ulur', 'Pukat Cincin Grup Pelagis Kecil', 'Pukat Cincin Satu Kapal', 'Hand Line Tuna', 'Rawai Hanyut', 'Huhate', 'Bagan Perahu', dan 'Pukat Cincin Pelagis Kecil dengan Satu Kapal'.


Dengan demikian, total terdapat 19 jenis alat tangkap yang tercatat dalam ketiga jenis penangkapan ikan tersebut, yaitu: 'Purse Seine (Pukat Cincin) Pelagis Kecil', 'Huhate', 'Pukat Cincin Pelagis Kecil dengan Satu Kapal', 'Pancing Ulur', 'Pancing Tonda', 'Pukat Cincin Satu Kapal', 'Pancing Berjoran', 'Hand Line Tuna', 'Pukat Cincin Grup Pelagis Kecil', 'Pukat Cincin Pelagis Besar dengan Satu Kapal', 'Jaring Insang Lingkar', 'Huhate Mekanis', 'Pengangkut', 'Pukat Cincin Pelagis Kecil dengan Dua Kapal', 'Bagan Perahu', 'Rawai Tuna', 'Jaring Insang Lainnya', 'Rawai Hanyut', dan 'Jaring Insang Oseanik'.

3.3.5 Sebaran penangkapan ikan di WPP 714 (data logbook)

3.3.5.1 Penangkapan ikan cakalang

Berdasarkan dataset, umumnya penyebaran area perairan untuk penangkapan cakalang yang dilaporkan berada di sekitar Perairan Teluk Tolo. Gambar 3.7 berikut ini adalah peta sebaran lokasi penangkapan ikan cakalang di WPP 714.







Gambar 3.7 Sebaran lokasi penangkapan ikan cakalang di WPP 714: (a) Januari, (b) Februari, (c) Maret, (d) April, (e) Mei, (f) Juni, (g) Juli, (h) Agustus, (i) September, (j) Oktober, (k) November, dan (l) Desember

3.3.5.2 Penangkapan ikan madidihiang

Penangkapan ikan madidihiang yang dilaporkan dalam dataset umumnya berada di sekitar Teluk Tolo, dan sebagiannya tersebar di sekitar Laut Banda. Peta 3.8 berikut ini adalah peta sebaran lokasi penangkapan ikan madidihiang di WPP 714.







Gambar 3.8 Sebaran lokasi penangkapan ikan madidihang di WPP 714: (a) Januari, (b) Februari, (c) Maret, (d) April, (e) Mei, (f) Juni, (g) Juli, (h) Agustus, (i) September, (j) Oktober, (k) November, dan (l) Desember

3.3.5.3 Penangkapan ikan tuna mata besar

Penangkapan ikan tuna mata besar yang dilaporkan dalam logbook tersebar di beberapa area Laut Banda. Adapun peta sebaran lokasi penangkapan ikan tuna mata besar di WPP 714, ditunjukkan pada gambar 3.9 sebagai berikut.





Gambar 3.9 Sebaran lokasi penangkapan ikan tuna mata besar di WPP 714: (a) Januari, (b) Februari, (c) Maret, (d) April, (e) Mei, (f) Juni, (g) Juli, (h) Agustus, (i) September, (j) Oktober, (k) November, dan (l) Desember

3.3.6 Catch Per Unit Effort (CPUE)

Dalam studi ini, CPUE dihitung berdasarkan berat tangkapan (kg) dan jumlah hari melaut (hari_laut), di mana hari_laut didefinisikan sebagai selisih antara tanggal kedatangan dan tanggal keberangkatan ditambah satu hari. Rumus perhitungannya adalah $CPUE = \text{berat tangkapan (kg)} / \text{hari_laut}$, yang mencerminkan efisiensi upaya penangkapan ikan. Adapun rata-rata nilai 'CPUE' pada penangkapan cakalang adalah 7.373 kg/hari, nilai maksimum 666.667 kg/hari, dan nilai minimum 0.0099 kg/hari. Pada madidihang, rata-rata nilai 'CPUE' adalah 27.399 kg/hari, nilai maksimum adalah 307.692 kg/hari, dan nilai minimum adalah 0.0556 kg/hari. Sedangkan pada tuna mata besar, nilai rata-rata 'CPUE' adalah 14.420 kg/hari, nilai maksimum adalah 666.667 kg/hari, dan nilai minimum 'CPUE' adalah 0.0833 kg/hari.

3.3.7 Model GAM pada faktor-faktor teknis penangkapan ikan di WPP 714



pada aktivitas penangkapan ikan cakalang

Untuk analisis ini, model yang digunakan ada dua, yakni: menggunakan t-test. Sebelum dilakukan pemodelan (dengan outlier), dilakukan uji normalitas, yakni: ringkasan statistik, frekuensi alat tangkap,


distribusi data dengan histogram dan boxplot, serta pengecekan skewness. Terkait informasi tentang jenis alat tangkap yang digunakan, ditunjukkan pada Tabel 3.2 berikut.

Tabel 3.1 Peralatan tangkap cakalang

Alat Tangkap	Jumlah Penangkapan	Alat Tangkap	Jumlah Penangkapan
Bagan perahu	1,346	Pengangkut	1
Hand Line Tuna	18	Pukat cincin grup pelagis kecil	31
Huhate mekanis	4	Pukat cincin Pelagis Besar dengan satu kapal	31
Huhate	1,234	Pukat Cincin Pelagis Kecil dengan Dua Kapal	4
Jaring insang lainnya	1	Pukat cincin Pelagis Kecil dengan satu kapal	2,174
Jaring insang lingkaran	15	Pukat cincin satu kapal	499
Jaring insang oseanik	1	Purse Seine (Pukat Cincin) Pelagis Kecil	6,906
Pancing berjoran	52	Rawai hanyut	10
Pancing Tonda	2,344	Rawai Tuna	65
Pancing Ulur	2,717		

Pada tabel di atas, terdapat berbagai alat tangkap yang digunakan dalam penangkapan ikan. Bagan perahu merupakan alat yang digunakan dengan jumlah penangkapan sebanyak 1,346. Hand Line Tuna menghasilkan 18 penangkapan, sementara Huhate mekanis hanya mencatat 4 penangkapan. Alat tangkap Huhate mencatat 1,234 penangkapan, sementara jaring insang jenis lain hanya melakukan 1 penangkapan. Jaring insang lingkaran mencatat 15 penangkapan, sedangkan jaring insang oseanik hanya menghasilkan 1 penangkapan. Pancing berjoran mencatat 52 penangkapan, sedangkan pancing tonda mencapai 2,344 penangkapan. Pancing ulur menjadi alat tangkap dengan penangkapan terbanyak, 17. Adapun distribusi kapal ditunjukkan pada gambar 3.10







Gambar 3.10 Grafik 'gt_kapal' Cakalang: (a) Distribusi, dan (b) Boxplot



grafik tersebut, terlihat bahwa terdapat puncak yang signifikan di bagian bawah sumbu *gt_kapal*, mengindikasikan bahwa sebagian besar kapal penangkap ikan memiliki ukuran yang lebih kecil. Terdapat pula beberapa puncak kecil di sepanjang grafik, yang menunjukkan adanya variasi ukuran kapal penangkap ikan. Namun, semakin tinggi nilai pada sumbu *gt_kapal*, jumlah data semakin sedikit, menunjukkan bahwa kapal penangkap ikan dengan ukuran yang lebih besar jarang terjadi.

Untuk grafik boxplot '*gt_kapal*' Cakalang (b)' di atas, nampak bahwa boxplot di atas menggambarkan data "*gt_kapal*", nampak bahwa distribusi data tersebut simetris dan berpusat di sekitar nilai nol. Namun, terdapat outlier yang mencapai nilai sekitar 100 pada sumbu "*gt_kapal*." Outlier ini menunjukkan adanya variabilitas ekstrem yang perlu ditinjau lebih lanjut untuk memahami penyebab dan implikasinya dalam penelitian ilmiah ini. Adapun Gambar 3.11 berikut adalah grafik '*hari_laut*' cakalang.






Gambar 3.11 Grafik 'hari_laut' Cakalang: (a) Distribusi, dan (b) Boxplot

Grafik “Distribusi hari_laut (a)” di atas, pada sumbu horizontal menunjukkan nilai "hari_laut" dan sumbu vertikal menunjukkan frekuensinya. Terlihat adanya lonjakan yang signifikan di awal, yaitu di sekitar nilai nol, yang menunjukkan bahwa frekuensi nilai "hari_laut" yang rendah lebih tinggi. Namun, seiring dengan meningkatnya nilai "hari_laut", frekuensinya secara drastis menurun. Hal ini mengindikasikan bahwa nilai yang lebih tinggi jauh lebih jarang muncul dalam dataset ini.

Pada grafik boxplot "hari_laut" di atas, pada sumbu horizontal berkisar dari sekitar -0.050 hingga 0.050, sedangkan pada sumbu vertikal, skala nilai 0 hingga 400. Boxplot menunjukkan median yang mendekati nol, dengan beberapa titik data (outlier) yang berada di atas kuartil atas menuju nilai maksimum sekitar 400. Jenis grafik ini menarik karena memberikan ringkasan visual beberapa statistik penting sekaligus, termasuk median, kuartil, dan potensi outlier dalam dataset. Adapun hubungan antara 'alat_tangkap' dan CPUE ditunjukkan pada gambar 3.12 berikut ini (outlier).





Gambar 3.12 Grafik hubungan antara 'alat_tangkap' dan CPUE Cakalang

Pada grafik boxplot di atas, nampak bahwa distribusi nilai CPUE untuk berbagai jenis alat tangkap ikan. Setiap kotak mewakili rentang antara kuartil pertama (Q1) dan kuartil ketiga (Q3), dengan garis vertikal menunjukkan nilai median (Q2). Titik-titik merah menandai outlier, yaitu nilai di luar rentang whisker. Selain itu, terdapat jitter plot yang menampilkan titik-titik.

Untuk mendapatkan nilai skewness digunakan library e1071. Skewness yang dihasilkan adalah 1.422 untuk variabel 'gt_kapal' dan 8.254 untuk variabel 'hari_laut'. Nilai skewness yang positif menunjukkan bahwa distribusi data cenderung lebih condong ke arah kanan atau memiliki ekor ekor yang lebih panjang di sebelah kanan dari nilai tengahnya. Nilai skewness yang dihasilkan adalah 1.4215 untuk variabel gt_kapal dan 8.25401 untuk variabel hari_laut menunjukkan bahwa distribusi data pada kedua variabel tersebut memiliki ekor yang lebih panjang di sebelah kanan dari nilai tengahnya. Ini berarti bahwa terdapat nilai-nilai yang sangat tinggi atau ekstrem pada variabel tersebut.

Untuk pemodelan GAM dengan menggunakan data (outlier) digambarkan dalam formula berikut.

```
# Membuat model GAM dengan keseluruhan data
model_with_outlier <- gam(CPUE ~ s(gt_kapal) + alat_tangkap +
s(hari_laut), data = cakalangCatch_ChloSST)

# Mendapatkan nilai AIC
aiccakalangchloSST_with_outlier <- AIC(model_with_outlier)
```

delan GAM tersebut ditunjukkan sebagai berikut.



Link function: identity

Formula:

CPUE ~ s(gt_kapal) + alat_tangkap + s(hari_laut)

Parametric coefficients:

	Estimate	Std.
Error		
(Intercept)	82.044	61.140
alat_tangkapHand Line Tuna	6.293	61.680
alat_tangkapHuhate	108.334	61.796
alat_tangkapHuhate mekanis	324.084	143.417
alat_tangkapJaring insang lainnya	67.906	266.631
alat_tangkapJaring insang lingkaran	12.647	90.723
alat_tangkapJaring insang oseanik	-21457.514	4019.911
alat_tangkapPancing berjoran	326.381	71.028
alat_tangkapPancing Tonda	60.170	61.416
alat_tangkapPancing Ulur	25.113	61.464
alat_tangkapPengangkut	252.854	266.457
alat_tangkapPukat cincin grup pelagis kecil	234.040	77.148
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	53.539	77.064
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	45.176	143.342
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-18.822	61.489
alat_tangkapPukat cincin satu kapal	29.312	62.345
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	59.868	61.321
alat_tangkapRawai hanyut	171.210	104.827
alat_tangkapRawai Tuna	100.339	73.519
	t value	Pr(> t)
(Intercept)	1.342	0.17964
alat_tangkapHand Line Tuna	0.102	0.91874
alat_tangkapHuhate	1.753	0.07960
alat_tangkapHuhate mekanis	2.260	0.02385 *
alat_tangkapJaring insang lainnya	0.255	0.79897
alat_tangkapJaring insang lingkaran	0.139	0.88913
alat_tangkapJaring insang oseanik	-5.338	9.53e-08 ***
alat_tangkapPancing berjoran	4.595	4.36e-06 ***
alat_tangkapPancing Tonda	0.980	0.32724
alat_tangkapPancing Ulur	0.409	0.68285
alat_tangkapPengangkut	0.949	0.34266
alat_tangkapPukat cincin grup pelagis kecil	3.034	0.00242 **
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	10.695	0.48723
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	0.315	0.75264
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-0.306	0.75953
alat_tangkapPukat cincin satu kapal	0.470	0.63825
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	0.976	0.32893
alat_tangkapRawai hanyut	1.633	0.10243
alat_tangkapRawai Tuna	1.365	0.17233

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:

	edf	Ref.df	F	p-value
s(gt_kapal)	8.962	8.999	43.58	<2e-16 ***
s(hari_laut)	8.970	9.000	160.82	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.178 Deviance explained = 18%
GCV = 67354 Scale est. = 67211 n = 17453



keluaran dari model ini adalah family Gaussian, yang merujuk Gaussian atau normal yang digunakan dalam model tersebut. sering dipilih ketika variabel respons bersifat kontinu dan digunakan fungsi link identitas yang menunjukkan adanya

hubungan linear antara rata-rata variabel respons dengan prediktor linear dalam model. Dalam kasus ini, tidak ada transformasi yang diterapkan pada variabel respons. Model ini dirumuskan sebagai $CPUE \sim s(gt_kapal) + alat_tangkap + s(hari_laut)$, yang berarti model ini memprediksi variabel CPUE berdasarkan variabel *gt_kapal*, *alat_tangkap*, dan *hari_laut*.

Model ini juga menghasilkan estimasi koefisien regresi yang menunjukkan seberapa besar pengaruh variabel independen terhadap variabel dependen. Untuk variabel *alat_tangkap* Hand Line Tuna, koefisien regresinya sebesar 6.293, yang menunjukkan bahwa setiap peningkatan satu unit dalam variabel *alat_tangkap* Hand Line Tuna akan meningkatkan nilai variabel dependen sebesar 6.293, dengan asumsi variabel lain tetap konstan. Selain itu, terdapat standard error (standar kesalahan) dari estimasi koefisien yang mengukur tingkat akurasi prediksi koefisien tersebut. Semakin kecil standar kesalahan, semakin akurat estimasi koefisien tersebut. Untuk variabel *alat_tangkap* Hand Line Tuna, standar kesalahannya adalah 61.680, yang berarti estimasi koefisien sebesar 6.293 dapat bervariasi sebesar ± 61.680 . Nilai *t* digunakan untuk mengevaluasi signifikansi perbedaan antar kelompok atau perbedaan dalam kelompok.

Selain itu, nilai *p* atau probabilitas juga disediakan. Nilai *p* yang kecil (biasanya ≤ 0.05) menunjukkan bahwa variabel independen memiliki efek yang signifikan. Dalam output ini, simbol *** menunjukkan nilai $p < 0.001$, ** menunjukkan nilai $p < 0.01$, * menunjukkan nilai $p < 0.05$, dan . menunjukkan nilai $p < 0.1$. Untuk variabel *alat_tangkap* Jaring insang oseanik, nilai *t*-nya adalah -5.338 dan nilai *p*-nya sangat kecil ($9.53e-08$).


Estimasi derajat kebebasan (*edf*) juga diestimasi untuk setiap smooth term dalam model. Ini memberikan ukuran seberapa fleksibel setiap smooth term dalam memodelkan data. Untuk variabel *gt_kapal*, *edf*-nya adalah 8.962, yang menunjukkan bahwa smooth term ini memiliki tingkat fleksibilitas yang tinggi dalam memodelkan data. Referensi degrees of freedom (*ref.df*) juga disediakan untuk setiap smooth term. Ini adalah jumlah derajat kebebasan referensi yang mendekati jumlah derajat kebebasan maksimum yang diizinkan untuk setiap smooth term. Nilai statistik *F* juga diberikan untuk setiap smooth term.

Deviance explained mengindikasikan persentase deviance yang dijelaskan oleh model. Dalam kasus ini, model ini menjelaskan sekitar 18% deviance. GCV (Generalized Cross Validation score) digunakan untuk mengevaluasi seberapa baik model memprediksi data dengan mempertimbangkan kompleksitas model. Semakin rendah nilai GCV, semakin baik model tersebut. Dalam kasus ini, nilai GCV adalah 67354, estimasi skala deviance residual diberikan melalui scale est, jumlah observasi dalam data (*n*) adalah 17453, dan AIC (Akaike Information Criterion) merupakan nilai AIC dari model ini, yaitu 243568.9. Pengecekan juga dilakukan pada multikolinearitas dengan menggunakan fungsi 'vif'. Nilai 'vif' ditunjukkan sebagai berikut.




GVIF	Df	GVIF^(1/(2*Df))
431e+60	0	Inf
431e+60	0	Inf
431e+60	0	Inf

Nilai di atas menampilkan hasil perhitungan Generalized Variance Inflation Factor (GVIF) untuk tiga variabel: 'alat_tangkap', 'gt_kapal', dan 'hari_laut'. Nilai GVIF yang sangat besar menunjukkan adanya multikolinearitas, yaitu korelasi yang kuat antara variabel-variabel tersebut. Mengenai plot model GAM ditunjukkan pada gambar 3.13 sebagai berikut.



(a)



(b)

Gambar 3.13 Fungsi Splines untuk variabel teknis penangkapan cakalang: (a) 'gt_kapal' - 's(gt_kapal,8.96)' dan (b) 'hari_laut' - 's(hari_laut,8.97)'



dalam konteks ini merujuk pada fungsi Spline smoothing dalam model GAM. Plot (a) menunjukkan bahwa variabel 'gt_kapal' telah diubah

melalui fungsi Spline smoothing dalam model. Plot tersebut menunjukkan hubungan yang dismoothing antara 'gt_kapal' dan variabel respons, dengan garis putus-putus yang mewakili interval kepercayaan. Ini memberikan gambaran visual tentang bagaimana 'gt_kapal' memengaruhi variabel respons dalam model GAM. Adapun 's(hari_laut,8.96)' menunjukkan bahwa variabel 'hari_laut' telah diubah melalui fungsi Spline smoothing dalam model. Plot tersebut menunjukkan hubungan yang dismoothing antara 'hari_laut' dan variabel respons, dengan garis yang tetap relatif datar dan dekat dengan nol sepanjang rentang 'hari_laut'.

Untuk melihat apakah ada pengaruh nilai outlier pada jenis alat tangkap – CPUE, maka model GAM dibandingkan dengan formula yang mengabaikan nilai outlier dengan menggunakan nilai 'threshold' 1. Nilai 'threshold' memiliki deviance explained lebih tinggi. Formula tersebut sebagai berikut.

```
# Handle outlier dengan metode pencapaian ambang (threshold)
threshold_gamcakalang <- 1
outliers_gamcakalang <- residuals(modelgam_cakalangChlosST)
> threshold_gamcakalang

# Model tanpa outlier
modelgam_cakalangChlosST_without_outlier <- gam(CPUE ~ s(gt_kapal) +
  alat_tangkap + s(hari_laut), data =
  cakalangCatch_ChlosST[!outliers_gamcakalang,
  ])
```

Adapun hasil pemodelan tanpa outlier tersebut adalah sebagai berikut.

```
[1] 113541.2

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(gt_kapal) + alat_tangkap + s(hari_laut)

Parametric coefficients:
```

	Estimate
(Intercept)	8.694
alat_tangkapHand Line Tuna	11.081
alat_tangkapHuhate	86.505
alat_tangkapHuhate mekanis	189.519
alat_tangkapJaring insang lainnya	101.251
alat_tangkapJaring insang lingkaran	59.554
alat_tangkapJaring insang oseanik	-8872.931
alat_tangkapPancing berjoran	192.183
alat_tangkapPancing Tonda	54.402
alat_tangkapPancing Ulur	35.962
alat_tangkapPengangkut	283.715
alat_tangkapPukat cincin grup pelagis kecil	60.393
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	63.798
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	116.122
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	31.433
alat_tangkapPukat cincin satu kapal	49.402
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	62.992
alat_tangkapRawai hanyut	95.838
alat_tangkapRawai Tuna	42.612
	Std. Error
	17.171
ine Tuna	17.369
	17.354
mekanis	38.561
insang lainnya	51.641



alat_tangkapJaring insang lingk	24.274
alat_tangkapJaring insang oseanik	1131.293
alat_tangkapPancing berjoran	19.601
alat_tangkapPancing Tonda	17.307
alat_tangkapPancing Ulur	17.309
alat_tangkapPengangkut	51.555
alat_tangkapPukat cincin grup pelagis kecil	19.730
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	20.499
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	32.865
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	17.216
alat_tangkapPukat cincin satu kapal	17.363
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	17.183
alat_tangkapRawai hanyut	28.424
alat_tangkapRawai Tuna	22.235

	t value
(Intercept)	0.506
alat_tangkapHand Line Tuna	0.638
alat_tangkapHuhate	4.985
alat_tangkapHuhate mekanis	4.915
alat_tangkapJaring insang lainnya	1.961
alat_tangkapJaring insang lingk	2.453
alat_tangkapJaring insang oseanik	-7.843
alat_tangkapPancing berjoran	9.805
alat_tangkapPancing Tonda	3.143
alat_tangkapPancing Ulur	2.078
alat_tangkapPengangkut	5.503
alat_tangkapPukat cincin grup pelagis kecil	3.061
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	3.112
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	3.533
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	1.826
alat_tangkapPukat cincin satu kapal	2.845
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	3.666
alat_tangkapRawai hanyut	3.372
alat_tangkapRawai Tuna	1.916

	Pr(> t)
(Intercept)	0.612654
alat_tangkapHand Line Tuna	0.523510
alat_tangkapHuhate	6.30e-07
alat_tangkapHuhate mekanis	9.02e-07
alat_tangkapJaring insang lainnya	0.049946
alat_tangkapJaring insang lingk	0.014165
alat_tangkapJaring insang oseanik	4.81e-15
alat_tangkapPancing berjoran	< 2e-16
alat_tangkapPancing Tonda	0.001674
alat_tangkapPancing Ulur	0.037767
alat_tangkapPengangkut	3.82e-08
alat_tangkapPukat cincin grup pelagis kecil	0.002212
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	0.001862
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	0.000412
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	0.067904
alat_tangkapPukat cincin satu kapal	0.004447
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	0.000248
alat_tangkapRawai hanyut	0.000750
alat_tangkapRawai Tuna	0.055333

(Intercept)	
alat_tangkapHand Line Tuna	
alat_tangkapHuhate	***
alat_tangkapHuhate mekanis	***
alat_tangkapJaring insang lainnya	*
alat_tangkapJaring insang lingk	*
alat_tangkapJaring insang oseanik	***
g berjoran	***
g Tonda	**
g Ulur	*
gkut	***



```

alat_tangkapPukat cincin grup pelagis kecil **
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal **
alat_tangkapPukat cincin Pelagis Kecil dengan Dua kapal ***
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal .
alat_tangkapPukat cincin satu kapal **
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil ***
alat_tangkapRawai hanyut ***
alat_tangkapRawai Tuna .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(gt_kapal)  8.987  9.000 114.7  <2e-16 ***
s(hari_laut)  8.686  8.959 309.5  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.455   Deviance explained = 45.7%
GCV = 2364.5   Scale est. = 2356.4       n = 10705

```

Dari kedua model di atas, nampak bahwa nilai model R-squared dengan outlier sebesar 0.178, sedangkan R-squared tanpa outlier memiliki nilai 0.455. Selain itu nilai AIC untuk model pertama adalah 243568.9, lebih besar daripada nilai AIC model kedua adalah 113541.2. Selain melakukan perbandingan model di atas, juga dilakukan pengecekan multikolineritas. Multikolineritas akan terjadi jika dua variabel prediktor atau lebih sangat berkorelasi. Dengan mengidentifikasi variabel yang memiliki VIF lebih tinggi dari ambang batas tertentu, dapat diambil langkah-langkah untuk mengatasi masalah multikolineritas, seperti menghapus atau menggabungkan variabel yang berkorelasi tinggi.

```

library(car)
library(carData)
vif(modelgam_cakalangChlosST)


```

Hasil uji multikolineritas di atas ditunjukkan sebagai berikut.

	GVIF	Df	GVIF ^{1/(2*Df)}
alat_tangkap	3.377431e+60	0	Inf
gt_kapal	3.377431e+60	0	Inf
hari_laut	3.377431e+60	0	Inf

Hasil uji multikolineritas menunjukkan bahwa variabel 'alat_tangkap', 'gt_kapal', dan 'hari_laut' memiliki nilai GVIF (Generalized Variance Inflation Factor) yang sangat tinggi (3.377431e+60) dan tak terhingga (Inf) untuk GVIF^{1/(2*Df)}. Hubungan antara gt_kapal dan CPUE ditunjukkan pada gambar 3.14 berikut.





Gambar 3.14 Grafik hubungan antara 'gt_kapal' dan CPUE Cakalang

Grafik di atas adalah scatter plot yang menggambarkan hubungan antara 'gt_kapal' dan 'CPUE'. Dalam grafik tersebut, sumbu x mewakili variabel 'gt_kapal', dan sumbu y mewakili 'CPUE'. Setiap titik pada grafik mewakili satu observasi dalam data, dengan koordinat titik tersebut menunjukkan nilai 'gt_kapal' dan 'CPUE' untuk observasi tersebut. Nilai rata-rata 'gt_kapal' pada dataframe ini adalah 26.40 (GT).

Dari grafik, terlihat bahwa sebagian besar titik data terkonsentrasi di sekitar nilai bawah pada 'gt_kapal'. Ini menunjukkan bahwa sebagian besar kapal dalam sampel memiliki ukuran (dalam 'gt_kapal') yang relatif kecil. Selain itu, ada beberapa titik data yang memiliki nilai 'CPUE' yang tinggi tetapi nilai 'gt_kapal' yang rendah. Ini menunjukkan bahwa beberapa kapal yang lebih kecil mampu menangkap banyak ikan per unit usaha (CPUE). Garis biru di bagian bawah grafik merupakan garis tren atau garis terbaik yang cocok. Analisis regresi menggunakan model GAM ditunjukkan pada formula berikut.

```
modelgamCakalang_gtkapal <- gam(CPUE ~ s(gt_kapal),
                                data = CakalangCatch_ChloSST_without_outlier)
```

Hasil analisis tersebut nampak sebagai berikut.

```
[1] 117974.5
```

```
Family: gaussian
Link function: identity
```



```
ients:
te Std. Error t value Pr(>|t|)
```

```

(Intercept) 60.4398    0.5778   104.6   <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(gt_kapal) 8.734  8.965 250.5  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.173    Deviance explained = 17.4%
GCV = 3577.6    Scale est. = 3574.3      n = 10705

```

Nilai R-sq.(adj) terbilang kecil 0.173, menunjukkan bahwa hubungan antara ukuran kapal 'gt_kapal' dengan CPUE memiliki korelasi yang kecil. Adapun nilai AIC adalah 117,974.5. Nilai 'R-sq.(adj)' atau R-squared yang disesuaikan dan nilai 'edf' atau derajat kebebasan yang diestimasi memiliki hubungan yang kompleks dalam model regresi GAM. 'R-sq.(adj)' adalah ukuran seberapa baik model menjelaskan variabilitas dalam data. Nilai ini berkisar antara 0 dan 1, dengan 1 menunjukkan bahwa model menjelaskan semua variabilitas dalam data. Dalam hal ini, 'R-sq.(adj)' adalah 0.173, yang berarti model menjelaskan sekitar 17.4% dari variabilitas dalam data.

Sementara itu, 'edf' adalah estimasi dari derajat kebebasan yang digunakan oleh fungsi smoothing dalam model. Gambar 3.15 berikut adalah fungsi Confidence Interval GAM pada variabel 'gt_kapal' cakalang.




Gambar 3.15 Fungsi Confidence Interval GAM pada variabel 'gt_kapal' cakalang

Grafik di atas menunjukkan hubungan antara 'gt_kapal' dan 's[gt_kapal 8.73]', yang merupakan hasil dari model regresi GAM. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga 140. Sumbu y, yang berlabel 's[gt_kapal 8.73]', mewakili nilai prediksi dari model. Nilai ini berkisar dari -150 hingga sekitar 50. Garis gelombang pada grafik menunjukkan hubungan antara 'gt_kapal' dan 's[gt_kapal 8.73]'.



Area yang diarsir di sekitar garis gelombang mewakili margin kesalahan atau varians dalam data. Dalam konteks ini, 'gt_kapal' adalah variabel independen dan 's[gt_kapal 8.73]' adalah variabel dependen. Derajat kebebasan (edf) dalam model GAM adalah 8.73, yang menunjukkan tingkat fleksibilitas fungsi smoothing. Adapun hubungan antara nilai 'hari_laut' dan CPUE ditunjukkan pada gambar berikut. Nilai rata-rata 'hari_laut' pada dataframe ini adalah 13.37 hari. Gambar 3.16 berikut adalah hubungan antara 'hari_laut' dan CPUE cakalang.



Gambar 3.16 Hubungan antara 'hari_laut' dan CPUE cakalang

Grafik di atas menunjukkan hubungan antara 'hari_laut' dan CPUE. Sumbu x, berlabel 'hari_laut', mewakili jumlah hari di laut. Nilai ini berkisar dari 0 hingga sekitar 400. Sumbu y, berlabel CPUE, mewakili hasil tangkapan per unit usaha. Nilai ini berkisar dari 0 hingga sekitar 500. Titik data merupakan hubungan antara 'hari_laut' dan CPUE. Dari grafik, dapat dilihat bahwa saat 'hari_laut' meningkat, nilai CPUE menurun. Adapun pemodelan GAM menunjukkan hasil sebagai berikut.

[1] 117607.8

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(hari_laut)



or t value Pr(>|t|)
5295 113.8 <2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:


	edf	Ref.df	F	p-value
s(hari_laut)	8.94	8.998	511.8	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.298 Deviance explained = 29.9%

GCV = 3039.3 Scale est. = 3036.5 n = 10832

Adapun derajat kebebasan yang dimiliki oleh kolom 'hari_laut' ditunjukkan pada gambar 3.17 berikut.



Gambar 3.17 Fungsi Confidence Interval GAM pada variabel 'hari_laut' cakalang

Grafik di atas menunjukkan hubungan antara 'hari_laut' dan 's[hari_laut 8.94]', yang merupakan hasil dari model regresi GAM. Sumbu x, berlabel 'hari_laut', mewakili nilai 'hari_laut' dalam data. Nilai ini berkisar dari 0 hingga sekitar 400. Sumbu y, berlabel 's[hari_laut 8.94]', mewakili nilai prediksi dari model GAM. Nilai ini berkisar dari -100 hingga sekitar 100. Garis gelombang pada grafik mewakili hubungan antara 'hari_laut' dan 's[hari_laut 8.94]'. Adapun pada kolom 'alat tangkap' Model GAM pada tangkapan ikan Cakalang adalah sebagai berikut.

```
# Membangun model GAM
CakalangCatch_ChloSST_without_outlier$ <-
as.factor(CakalangCatch_ChloSST_without_outlier$)
modelgamCakalang_alattangkap <- gam(CPUE ~ , data =
CakalangCatch_ChloSST_without_outlier)

# Mendapatkan nilai AIC
gkap_withoutoutlier <- AIC(modelgamCakalang_alattangkap)
i AIC
lattangkap_withoutoutlier)
kasan model
```



```
summary(modelgamCakalang_alattangkap)
```

Pemodelan tersebut menunjukkan hasil sebagai berikut.

```
[1] 117682.7

Family: gaussian
Link function: identity

Formula:
CPUE ~

Parametric coefficients:

              Estimate Std. Error
(Intercept)    15.0169    19.5417
Hand Line Tuna  -6.1704    19.6582
Huhate          33.8522    19.6409
Huhate mekanis  97.4831    43.6965
Jaring insang lainnya -0.7312    58.6250
Jaring insang lingkaran 82.2622    26.8575
Jaring insang oseanik -15.0079    58.6250
Pancing berjoran 114.7787    22.0731
Pancing Tonda   -2.3708    19.6069
Pancing Ulur     1.2991    19.5937
Pengangkut      234.9831    58.6250
Pukat cincin grup pelagis kecil 74.5629    22.4517
Pukat cincin Pelagis Besar dengan satu kapal 91.6893    23.2952
Pukat Cincin Pelagis Kecil dengan Dua Kapal 114.1498    37.4195
Pukat cincin Pelagis Kecil dengan satu kapal 39.1831    19.5959
Pukat cincin satu kapal 64.7679    19.7657
Purse Seine (Pukat Cincin) Pelagis kecil 80.0401    19.5581
Rawai hanyut    -14.9669    31.5100
Rawai Tuna      -14.6372    22.6871


              t value Pr(>|t|)
(Intercept)      768 0.44223
Hand Line Tuna   -0.314 0.75362
Huhate            1.724 0.08482 .
Huhate mekanis    2.231 0.02571 *
Jaring insang lainnya -0.012 0.99005
Jaring insang lingkaran 3.063 0.00220 **
Jaring insang oseanik -0.256 0.79796
Pancing berjoran    5.200 2.03e-07 ***
Pancing Tonda     -0.121 0.90376
Pancing Ulur       0.066 0.94714
Pengangkut        4.008 6.16e-05 ***
Pukat cincin grup pelagis kecil 3.321 0.00090 ***
Pukat cincin Pelagis Besar dengan satu kapal 3.936 8.34e-05 ***
Pukat Cincin Pelagis Kecil dengan Dua Kapal 3.051 0.00229 **
Pukat cincin Pelagis Kecil dengan satu kapal 2.000 0.04557 *
Pukat cincin satu kapal 3.277 0.00105 **
Purse Seine (Pukat Cincin) Pelagis kecil 4.092 4.30e-05 ***
Rawai hanyut      -0.475 0.63481
Rawai Tuna        -0.645 0.51883

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.294   Deviance explained = 29.5%
GCV = 3060.4   Scale est. = 3055       n = 10832
```

Pada model-model yang ditampilkan di atas adalah model tunggal. Untuk unjukkan pada 3.18 sebagai berikut.





(a)

(b)

(c)

Gambar 3.18 Perbandingan fungsi smoothing 'edf' cakalang: (a) model gabungan 'gt_kapal' dan 'hari_laut', (b) model tunggal 'gt_kapal', dan (c) 'hari_laut'


Grafik (a) di atas menunjukkan analisis regresi nonparametrik menggunakan smoothing spline untuk variabel gt_kapal (gross tonnage kapal) dan hari_laut (jumlah hari di laut). Grafik kiri menunjukkan bahwa untuk gt_kapal, kurva Spline mendatar pada nilai rendah tetapi meningkat tajam setelah sekitar 100, menunjukkan hubungan non-linear yang signifikan. Sementara itu, grafik kanan menunjukkan bahwa jumlah hari di laut (hari_laut) tidak memiliki hubungan signifikan dengan variabel respon, terlihat dari kurva Spline yang tetap mendatar.

Pada grafik (b) di atas menunjukkan analisis regresi nonparametrik menggunakan smoothing spline untuk memodelkan hubungan antara CPUE dan gt_kapal. Kurva Spline menunjukkan hubungan non-linear yang kompleks, dengan beberapa fluktuasi signifikan pada berbagai rentang nilai gt_kapal. Pada nilai rendah hingga sekitar 30, kurva meningkat, kemudian menurun antara 30 dan 60, kembali naik antara 60 dan 90, dan menurun tajam setelah 90 hingga sekitar 120, diikuti peningkatan signifikan menjelang nilai 140. Area abu-abu menunjukkan interval kepercayaan, dengan ketidakpastian lebih besar pada nilai gt_kapal yang lebih tinggi.



rafik (c) menunjukkan analisis regresi nonparametrik smoothing spline untuk memodelkan hubungan antara CPUE dan hari_laut. Kurva Spline menunjukkan hubungan non-linear, dengan fluktuasi signifikan pada berbagai rentang nilai hari_laut. Pada nilai rendah hingga sekitar


50, kurva menurun tajam, kemudian berfluktuasi antara nilai 50 dan 150, dan stabil mendekati nol setelahnya. Area abu-abu menunjukkan interval kepercayaan, dengan ketidakpastian lebih besar pada nilai hari_laut yang lebih tinggi. Adapun hubungan antara Nilai ECDF dan 'gt_kapal' pada ikan cakalang ditunjukkan pada gambar 3.19 berikut.



Gambar 3.19 Grafik hubungan antara 'gt_kapal' dan ECDF cakalang

Grafik di atas adalah plot Empirical Cumulative Distribution Function (ECDF) untuk variabel 'gt_kapal'. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga sedikit di atas 100. Sumbu y, yang berlabel 'ECDF', mewakili nilai kumulatif empiris dari data. Nilai ini berkisar dari 0 hingga 1. Garis pada grafik mewakili fungsi distribusi kumulatif empiris dari data 'gt_kapal'. Dari grafik, nampak bahwa nilai ECDF 'gt_kapal' adalah 24. Ini menunjukkan bahwa nilai bobot kapal yang signifikan untuk penangkapan ikan cakalang di WPP 714 adalah 24 GT. Untuk memastikan apakah nilai 24 GT merupakan nilai signifikan yang sebenarnya, maka nilai tersebut perlu diuji dengan uji Kolmogorov-Smirnov. Berdasarkan hasil uji menunjukkan bahwa nilai p pada 'gt_kapal' adalah $< 2.2e-16$ ($p > 0.05$), sehingga diterima sebagai nilai signifikan. Adapun hubungan antara Nilai ECDF 'hari_laut' pada penangkapan ikan cakalang ditunjukkan pada gambar 3.20 berikut.






Gambar 3.20 Hubungan antara 'hari_laut' dan ECDF cakalang


Grafik di atas adalah plot ECDF untuk variabel 'hari_laut'. Gambar di atas menunjukkan bahwa nilai $f_Cakalang(t)$ dan $g_Cakalang(t)$ cepat mencapai nilai mendekati 1 dalam beberapa hari pertama dan tetap konstan setelahnya, sedangkan nilai $D_Cakalang(t)$ mulai dari sekitar 0.25 dan menurun hingga mendekati 0 setelah beberapa hari. Garis putus-putus vertikal menunjukkan waktu spesifik di mana perubahan signifikan pada ketiga fungsi ini terjadi. Adapun nilai signifikan 'hari_laut' berdasarkan grafik di atas adalah 7. Nilai tersebut diuji dengan uji Kolmogorov-Smirnov, dan menunjukkan bahwa nilai p pada 'hari_laut' adalah $p\text{-value} < 2.2e-16$ ($p > 0.05$), sehingga diterima sebagai nilai signifikan.

Untuk nilai optimal pada 'gt_kapal' dan 'hari_laut' menggunakan persamaan fungsi 'kmeans' dan metode elbow. Untuk kluster 'gt_kapal' adalah 3. Nilai masing-masing titik 'elbow' tersebut selanjutnya dimasukkan dalam persamaan fungsi 'kmeans'. Hasil perhitungan tersebut menunjukkan bahwa kisaran nilai optimal 'gt_kapal' adalah 22 – 40 GT. Adapun nilai optimal 'hari_laut', dengan nilai kluster 3 adalah 1 – 30 hari. Nilai kluster pada 'gt_kapal' dan 'hari_laut' ditunjukkan pada gambar 3.21 berikut.





(a)



(b)

Gambar 3.21 Metode elbow nilai optimum penangkapan cakalang: (a) 'gt_kapal', dan (b) 'hari_laut'



pada aktivitas penangkapan ikan madidihang
atan tangkap yang digunakan pada ikan madidihang adalah


sebagaimana ditunjukkan pada tabel 3.3 berikut.

Tabel 3.2 Peralatan tangkap ikan madidihang

Alat Tangkap	Jumlah Penangkapan	Alat Tangkap	Jumlah Penangkapan
Hand Line Tuna	1534	Huhate	500
Jaring insang lainnya	1	Jaring insang lingkaran	11
Pancing berjoran	17	Pancing Tonda	2,211
Pancing Ulur	2,194	Pukat cincin grup pelagis kecil	10
Pukat cincin Pelagis Besar dengan satu kapal	19	Pukat Cincin Pelagis Kecil dengan Dua Kapal	4
Pukat cincin Pelagis Kecil dengan satu kapal	693	Pukat cincin satu kapal	188
Purse Seine (Pukat Cincin) Pelagis Kecil	3,181	Rawai hanyut	86
Rawai Tuna	2,722		

Pada tabel di atas, terdapat berbagai alat tangkap yang digunakan dalam penangkapan ikan madidihang. Purse Seine (Pukat Cincin) Pelagis Kecil merupakan alat yang digunakan dengan jumlah penangkapan tertinggi sebanyak 3181. Adapun penangkapan terendah ada pada alat tangkap Jaring insang (lainnya) sebanyak 1. Kapal penangkap ikan madidihang di kawasan WPP 714 umumnya memiliki ukuran yang bervariasi. Adapun distribusi kapal ditunjukkan pada gambar 3.22 sebagai berikut.






Gambar 3.22 Grafik 'gt_kapal' madidihang: (a) distribusi, dan (b) boxplot




Gambar di atas (a) menunjukkan distribusi frekuensi dari variabel bahwa frekuensi terbesar berada pada kisaran nilai 25, di mana 1500 observasi pada titik ini. Selain itu, terdapat beberapa nilai yang signifikan, terutama di sekitar nilai 10, 15, dan 45. (b) menunjukkan bahwa ada sedikit observasi dengan nilai

"gt_kapal" di atas 60, menandakan bahwa nilai-nilai ini lebih jarang terjadi. Secara keseluruhan, distribusi ini memperlihatkan kecenderungan banyaknya kapal dengan nilai "gt_kapal" tertentu, dengan konsentrasi terbesar berada di sekitar nilai 25.

Adapun gambar (b) di atas merupakan boxplot dari variabel "gt_kapal". Dari boxplot ini, dapat dilihat bahwa nilai median dari "gt_kapal" berada di sekitar 25. Rentang interkuartil (IQR) mencakup nilai antara sekitar 20 hingga 30, yang menunjukkan bahwa sebagian besar data "gt_kapal" terkonsentrasi di dalam rentang ini. Terdapat beberapa outlier yang berada di atas nilai 50, menunjukkan bahwa ada sejumlah kecil kapal dengan nilai "gt_kapal" yang jauh lebih tinggi dari mayoritas data. Distribusi ini menunjukkan bahwa meskipun sebagian besar kapal memiliki "gt_kapal" sekitar 25, ada beberapa kapal dengan nilai yang cukup ekstrem. Gambar 3.23 berikut adalah histogram dan boxplot distribusi 'hari_laut'.






Gambar 3.23 Grafik 'hari_laut' madidihang: (a) distribusi, dan (b) boxplot

Grafik (a) di atas menunjukkan distribusi frekuensi variabel "hari_laut", yang menggambarkan jumlah hari di laut. Umumnya waktu yang dihabiskan di laut sedikit, dengan puncak distribusi pada interval waktu rendah. Frekuensi tertinggi adalah pada hari di sekitar ke-0 hingga hari ke-10. Distribusi kemudian menurun secara drastis.

Gambar (b) menunjukkan sebuah boxplot yang menggambarkan distribusi variabel 'hari_laut'. Boxplot ini menggambarkan rentang interkuartil (IQR) dari data dengan kotak merah, garis median di dalam kotak, dan whisker yang menunjukkan rentang data yang tidak termasuk outlier. Berdasarkan visualisasi ini, terlihat bahwa mayoritas data 'hari_laut' berkumpul di sekitar nilai median yang sangat dekat dengan nol, dengan beberapa outlier yang sangat tinggi, mencapai nilai lebih dari 400. Adapun hubungan antara 'alat_tangkap' dan CPUE ditunjukkan pada gambar 3.24 berikut ini (outlier).





Gambar 3.24 Grafik hubungan antara 'alat_tangkap' dan CPUE madidihang

Gambar di atas menunjukkan hubungan antara jenis alat tangkap dengan CPUE. Jenis alat tangkap ditampilkan pada sumbu x, sedangkan nilai CPUE ditampilkan pada sumbu y. Titik-titik hitam menunjukkan CPUE untuk setiap alat tangkap, dengan tanda bintang merah menunjukkan outlier. Mayoritas alat tangkap memiliki nilai CPUE yang rendah dan terkonsentrasi di sekitar nol. Namun, "Hand Line Tuna" dan "Pukat cincin Pelagis Kecil" memiliki nilai CPUE yang tinggi, yang terlihat dari beberapa outlier yang mencolok.

Adapun skewness yang dihasilkan adalah 0.953 untuk variabel 'gt_kapal' dan 2.967 untuk variabel 'hari_laut'. Kedua nilai skewness condong ke arah kanan (positif). Untuk pemodelan GAM dengan menggunakan data (outlier) digambarkan dalam formula berikut.

```
# Membuat model GAM dengan keseluruhan data
model_with_outlier <- gam(CPUE ~ s(gt_kapal) + alat_tangkap +
s(hari_laut), data = MadidihangCatch_ChlosST)

# Mendapatkan nilai AIC
aicmadidihangchlosST_with_outlier <- AIC(model_with_outlier)
```

Hasil pemodelan GAM tersebut ditunjukkan pada nilai berikut.

```
[1] 162746.3
```

```
Family: gaussian
Link function: identity
```



```
+ alat_tangkap + s(hari_laut)
```

```
ients:
```

```
Estimate Std.
```

```

Error
(Intercept)                24.780    3.516
alat_tangkapHuhate         61.858    6.652
alat_tangkapJaring insang lainnya 67.293 106.346
alat_tangkapJaring insang lingkaran 49.123  32.383
alat_tangkapPancing berjoran    164.703 26.181
alat_tangkapPancing Tonda       13.893   4.022
alat_tangkapPancing Ulur        16.655   3.919
alat_tangkapPukat cincin grup pelagis kecil -18.418 33.959
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal 158.099 24.799
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua kapal 65.283 53.315
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal 6.131 6.478
alat_tangkapPukat cincin satu kapal 28.486 9.017
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil 37.823 5.296
alat_tangkapRawai hanyut       34.806 12.538
alat_tangkapRawai Tuna         22.003 5.776
                                t value Pr(>|t|)
(Intercept)                7.048 1.90e-12 ***
alat_tangkapHuhate         9.299 < 2e-16 ***
alat_tangkapJaring insang lainnya 0.633 0.526891
alat_tangkapJaring insang lingkaran 1.517 0.129306
alat_tangkapPancing berjoran    6.291 3.25e-10 ***
alat_tangkapPancing Tonda       3.454 0.000553 ***
alat_tangkapPancing Ulur        4.249 2.16e-05 ***
alat_tangkapPukat cincin grup pelagis kecil -0.542 0.587580
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal 16.375 1.89e-10 ***
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua kapal 1.224 0.220793
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal 10.946 0.343985
alat_tangkapPukat cincin satu kapal 3.159 0.001587 **
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil 7.142 9.65e-13 ***
alat_tangkapRawai hanyut       2.776 0.005512 **
alat_tangkapRawai Tuna         3.809 0.000140 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(gt_kapal)  8.966  8.999 61.76 <2e-16 ***
s(hari_laut) 8.885  8.994 74.22 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.216   Deviance explained = 21.8%
GCV = 11311   Scale est. = 11284       n = 13371

```

Hasil pemodelan di atas dapat dijelaskan sebagai berikut. Koefisien regresi yang dihasilkan oleh model menunjukkan seberapa besar pengaruh variabel independen terhadap variabel dependen. Misalnya, untuk alat_tangkapHuhate, koefisiennya adalah 61.858, yang berarti bahwa setiap peningkatan satu unit dalam alat_tangkapHand Line Tuna akan meningkatkan nilai variabel dependen sebesar 61.858, dengan asumsi variabel lain tetap.

Standar kesalahan (Std. Error) memberikan ukuran seberapa akurat prediksi koefisien. Semakin kecil standar kesalahan, semakin akurat estimasi koefisien. Misalnya, untuk alat_tangkapHuhate, standar kesalahannya adalah 24.780, yang berarti bahwa estimasi koefisien 3.516 bervariasi sebesar ± 24.780 .


Nilai F yang besar menunjukkan bahwa smooth term tersebut memiliki efek yang signifikan (hari_laut), nilai F-nya adalah 74.22, yang berarti bahwa variabel tersebut sangat signifikan. Nilai p yang kecil (umumnya ≤ 0.05) menunjukkan bahwa variabel independen memiliki efek signifikan. Dalam data tersebut, beberapa alat tangkap yang memiliki simbol *** (menunjukkan



nilai $p < 0.001$), ** (menunjukkan nilai $p < 0.01$), * (menunjukkan nilai $p < 0.05$), dan () (menunjukkan nilai $p < 0.1$). Nilai R-squared sebesar 0.216, yang berarti bahwa model menjelaskan sekitar 21.8% variasi dalam data. Nilai GCV adalah 11,311. Sedangkan nilai AIC adalah 162,746.3. Pengecekan multikolinearitas dilakukan dengan menggunakan fungsi 'vif'. Nilai 'vif' ditunjukkan sebagai berikut.


	GVIF	Df	GVIF ^{1/(2*Df)}
alat_tangkap	2.082091e+38	0	Inf
gt_kapal	2.082091e+38	0	Inf
hari_laut	2.082091e+38	0	Inf

Nilai di atas menampilkan hasil perhitungan Generalized Variance Inflation Factor (GVIF) untuk tiga variabel: 'alat_tangkap', 'gt_kapal', dan 'hari_laut'. Nilai GVIF yang sangat besar menunjukkan adanya multikolinearitas, yaitu korelasi yang kuat antara variabel-variabel tersebut. Mengenai plot model GAM ditunjukkan pada Gambar 3.25 berikut.



(a)





(b)

Gambar 3.25 Fungsi Splines untuk variabel teknis penangkapan madidihang: (a) 'gt_kapal' - 's(gt_kapal,8.97)', dan (b) dan 'hari_laut' - 's(hari_laut,8.89)'

Pada gambar (a) di atas, garis tebal merepresentasikan estimasi dari fungsi smooth dari GT kapal, sedangkan garis putus-putus menunjukkan interval kepercayaan sekitar estimasi tersebut. Dari plot ini, terlihat bahwa respons terhadap GT kapal tidak linier, melainkan memiliki beberapa fluktuasi. Pada nilai GT sekitar 70 hingga 100, terlihat adanya kenaikan yang signifikan pada respons. Ini mengindikasikan bahwa kapal dengan GT yang lebih besar cenderung memiliki peningkatan yang lebih besar pada respons tertentu, meskipun dengan variasi yang cukup signifikan.

Sedangkan pada gambar (b), sumbu x merepresentasikan jumlah hari laut, sedangkan sumbu y menunjukkan nilai fungsi smooth dari respons tersebut. Garis tebal menunjukkan estimasi fungsi smooth, sementara garis putus-putus menggambarkan interval kepercayaan sekitar estimasi ini. Dari plot ini, terlihat bahwa respons terhadap jumlah hari laut menunjukkan beberapa pola fluktuasi. Pada awalnya, terjadi penurunan tajam dalam respons untuk hari laut mendekati nol, kemudian respons menjadi stabil dan sedikit meningkat dengan fluktuasi kecil sekitar 100 hingga 300 hari laut. Setelah itu, terjadi tren menurun yang signifikan setelah 300 hari laut.

Untuk melihat apakah ada pengaruh nilai outlier pada jenis alat tangkap – CPUE, maka model GAM dibandingkan dengan formula yang mengabaikan nilai menggunakan nilai 'threshold' 1. Nilai 'threshold' memiliki deviance χ^2 . Formula tersebut sebagai berikut.

dengan metode pencapaian ambang (threshold)
 $\text{thang} <- 1$



```

outliers_gammadidihang <- residuals(modelgam_madidihangChlosST)
> threshold_gammadidihang

# Model tanpa outlier
modelgam_madidihangChlosST_without_outlier <- gam(CPUE ~ s(gt_kapal) +
  alat_tangkap + s(hari_laut), data =
  MadidihangCatch_ChlosST[!outliers_gammadidihang, ])

```

Adapun hasil pemodelan tanpa outlier tersebut adalah sebagai berikut.

```
[1] 73241.19
```

```
Family: gaussian
Link function: identity
```

```
Formula:
CPUE ~ s(gt_kapal) + alat_tangkap + s(hari_laut)
```

```
Parametric coefficients:
```

	Estimate
(Intercept)	9.852
alat_tangkapHuhate	23.360
alat_tangkapJaring insang lainnya	34.978
alat_tangkapJaring insang lingkaran	37.439
alat_tangkapPancing berjoran	93.625
alat_tangkapPancing Tonda	9.792
alat_tangkapPancing Ulur	7.376
alat_tangkapPukat cincin grup pelagis kecil	11.490
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	64.891
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	66.570
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	15.361
alat_tangkapPukat cincin satu kapal	20.303
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	21.244
alat_tangkapRawai hanyut	16.637
alat_tangkapRawai Tuna	13.833
	Std. Error
(Intercept)	1.119
alat_tangkapHuhate	1.846
alat_tangkapJaring insang lainnya	20.829
alat_tangkapJaring insang lingkaran	9.370
alat_tangkapPancing berjoran	6.436
alat_tangkapPancing Tonda	1.228
alat_tangkapPancing Ulur	1.143
alat_tangkapPukat cincin grup pelagis kecil	8.589
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	6.722
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	14.724
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	1.735
alat_tangkapPukat cincin satu kapal	2.317
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	1.499
alat_tangkapRawai hanyut	4.356
alat_tangkapRawai Tuna	2.106

	t value
(Intercept)	8.804
alat_tangkapHuhate	12.657
alat_tangkapJaring insang lainnya	1.679
alat_tangkapJaring insang lingkaran	3.996
alat_tangkapPancing berjoran	14.548
alat_tangkapPancing Tonda	7.973
alat_tangkapPancing Ulur	6.455
cincin grup pelagis kecil	1.338
cincin Pelagis Besar dengan satu kapal	9.654
Cincin Pelagis Kecil dengan Dua Kapal	4.521
cincin Pelagis Kecil dengan satu kapal	8.855
cincin satu kapal	8.764
Seine (Pukat Cincin) Pelagis Kecil	14.175



```

alat_tangkapRawai hanyut 3.819
alat_tangkapRawai Tuna 6.570
Pr(>|t|) < 2e-16
(Intercept) < 2e-16
alat_tangkapHuhate < 2e-16
alat_tangkapJaring insang lainnya 0.093139
alat_tangkapJaring insang lingkaran 6.51e-05
alat_tangkapPancing berjoran < 2e-16
alat_tangkapPancing Tonda 1.75e-15
alat_tangkapPancing Ulur 1.15e-10
alat_tangkapPukat cincin grup pelagis kecil 0.180984
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal < 2e-16
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua kapal 6.23e-06
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal < 2e-16
alat_tangkapPukat cincin satu kapal < 2e-16
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil < 2e-16
alat_tangkapRawai hanyut 0.000135
alat_tangkapRawai Tuna 5.36e-11

(Intercept) ***
alat_tangkapHuhate ***
alat_tangkapJaring insang lainnya .
alat_tangkapJaring insang lingkaran ***
alat_tangkapPancing berjoran ***
alat_tangkapPancing Tonda ***
alat_tangkapPancing Ulur ***
alat_tangkapPukat cincin grup pelagis kecil ***
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal ***
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua kapal ***
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal ***
alat_tangkapPukat cincin satu kapal ***
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil ***
alat_tangkapRawai hanyut ***
alat_tangkapRawai Tuna ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Approximate significance of smooth terms:
      edf Ref.df      F p-value
s(gt_kapal) 8.961 8.999 88.78 <2e-16 ***
s(hari_laut) 8.782 8.983 130.22 <2e-16 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.514 Deviance explained = 51.6%
GCV = 431.68 Scale est. = 429.96 n = 8224

```

Dari kedua model di atas, nampak bahwa nilai model R-squared dengan outlier sebesar 0.216, sedangkan R-squared tanpa outlier memiliki nilai 0.514. Selain itu nilai AIC untuk model pertama adalah 162,746.3, lebih besar daripada nilai AIC model kedua adalah 73,241.19. Adapun hubungan antara gt_kapal dan CPUE ditunjukkan pada gambar 3.26 berikut.





Gambar 3.26 Grafik hubungan antara 'gt_kapal' dan CPUE Madidihang

Grafik di atas adalah scatter plot yang menggambarkan hubungan antara 'gt_kapal' dan 'CPUE'. Dalam grafik tersebut, sumbu x mewakili variabel 'gt_kapal', dan sumbu y mewakili 'CPUE'. Setiap titik pada grafik mewakili satu observasi dalam data, dengan koordinat titik tersebut menunjukkan nilai 'gt_kapal' dan 'CPUE' untuk observasi tersebut. Nilai rata-rata 'gt_kapal' pada dataframe ini adalah 29.35 (GT).

Dari grafik, terlihat bahwa sebagian besar titik data terkonsentrasi di sekitar nilai 'gt_kapal' rendah. Ini menunjukkan bahwa sebagian besar kapal dalam sampel memiliki ukuran (dalam 'gt_kapal') yang relatif kecil. Selain itu, ada beberapa titik data yang memiliki nilai 'CPUE' yang tinggi tetapi nilai 'gt_kapal' yang rendah. Ini menunjukkan bahwa beberapa kapal yang lebih kecil mampu menangkap banyak ikan per unit usaha (CPUE). Garis biru di bagian bawah grafik merupakan garis tren atau garis terbaik yang cocok. Garis ini relatif datar, menunjukkan bahwa tidak ada hubungan linear yang kuat antara 'gt_kapal' dan 'CPUE'. Dengan kata lain, meningkatkan ukuran kapal (dalam 'gt_kapal') tidak selalu berarti peningkatan dalam CPUE. Analisis regresi menggunakan model GAM berikut.

```
modelgamMadidihang_gtkapal <- gam(CPUE ~ s(gt_kapal), data =
  MadidihangCatch_ChlosST_without_outlier)
```

Hasil analisis pemodelan di atas nampak sebagai berikut.



ntity

```

Formula:
CPUE ~ s(gt_kapal)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  23.5127    0.2934   80.14  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df   F p-value
s(gt_kapal)  8.958  8.999 229.2  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


R-sq.(adj) =    0.2    Deviance explained = 20.1%
GCV = 708.78    scale est. = 707.92      n = 8224

```

Nilai R-sq.(adj) terbilang kecil 0.201, menunjukkan bahwa hubungan antara ukuran kapal 'gt_kapal' dengan CPUE memiliki korelasi yang kecil. Adapun nilai AIC adalah 80863.06. Nilai 'R-sq.(adj)' atau R-squared yang disesuaikan dan nilai 'edf' atau derajat kebebasan yang diestimasi memiliki hubungan yang kompleks dalam model regresi GAM. 'R-sq.(adj)' adalah ukuran seberapa baik model menjelaskan variabilitas dalam data. Nilai ini berkisar antara 0 dan 1, dengan 1 menunjukkan bahwa model menjelaskan semua variabilitas dalam data. Dalam hal ini, 'R-sq.(adj)' adalah 0.2, yang berarti model menjelaskan sekitar 20.1% dari variabilitas dalam data.

Sementara itu, 'edf' menunjukkan tingkat fleksibilitas fungsi smoothing. Semakin tinggi 'edf', semakin fleksibel fungsi smoothing, yang memungkinkan model untuk menyesuaikan diri dengan pola yang lebih kompleks dalam data. Dalam konteks ini, hubungan antara 'R-sq.(adj)' dan 'edf' dapat dipahami bahwa model dengan 'edf' yang lebih tinggi (yaitu, model yang lebih fleksibel) dapat menyesuaikan diri dengan pola yang lebih kompleks dalam data, yang pada gilirannya dapat meningkatkan 'R-sq.(adj)'. Namun, ini juga dapat meningkatkan risiko overfitting, di mana model menjadi terlalu kompleks dan mulai menyesuaikan diri dengan noise atau variasi acak dalam data, bukan pola sebenarnya. Ini dapat menghasilkan model yang tidak generalisasi dengan baik ke data baru. Hubungan antara 'gt_kapal' dan 's[gt_kapal 8.96]' ditunjukkan pada Gambar 3.27 berikut.






Gambar 3.27 Fungsi confidence interval GAM pada variabel 'gt_kapal' madidihang

Grafik di atas menunjukkan hubungan antara 'gt_kapal' dan 's[gt_kapal 8.96]', yang merupakan hasil dari model regresi GAM. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga sekitar 100. Sumbu y, yang berlabel 's[gt_kapal 8.96]', mewakili nilai prediksi dari model GAM. Nilai ini berkisar dari -40 hingga sekitar 60. Garis gelombang pada grafik mewakili hubungan antara 'gt_kapal' dan 's[gt_kapal 8.96]'. Garis ini menunjukkan bahwa seiring dengan peningkatan 'gt_kapal', nilai 's[gt_kapal 8.96]' mengalami fluktuasi.

Area yang diarsir di sekitar garis gelombang kemungkinan besar mewakili margin kesalahan atau varians dalam data. Dalam konteks ini, 'gt_kapal' adalah variabel independen dan 's[gt_kapal 8.96]' adalah variabel dependen. Adapun hubungan antara nilai 'hari_laut' dan CPUE ditunjukkan pada Gambar 3.28 berikut. Nilai rata-rata 'hari_laut' pada dataframe ini adalah 27.93 hari.





Gambar 3.28 Hubungan antara 'hari_laut' dan CPUE madidihang

Grafik di atas menunjukkan hubungan antara 'hari_laut' dan CPUE. Sumbu x, yang berlabel 'hari_laut', mewakili jumlah hari di laut. Nilai ini berkisar dari 0 hingga sekitar 400. Sumbu y, yang berlabel CPUE, mewakili hasil tangkapan per unit usaha. Nilai ini berkisar dari 0 hingga sekitar 300. Secara keseluruhan, grafik ini menunjukkan bahwa ada peningkatan "CPUE" dengan peningkatan "hari_laut" hingga titik tertentu, setelah itu "CPUE" menurun dan stabil. Adapun koefisien regresi dibuat dalam model berikut:

```
[1] 76102.7

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(hari_laut)


Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 23.5127    0.2725   86.29  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(hari_laut) 8.854  8.991 411.2  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

1    Deviance explained = 31.1%
e est. = 610.58      n = 8224
```



Nilai $R\text{-sq.}(\text{adj})$ 0.31, menunjukkan bahwa hubungan antara 'hari_laut' dengan CPUE lebih tinggi dibandingkan dengan hubungan antara 'gt_kapal' dengan CPUE. Model ini mampu menjelaskan sekitar 31.1% dari variabilitas dalam data. Nilai AIC adalah 76,102.7. Adapun derajat kebebasan yang dimiliki oleh kolom 'hari_laut' ditunjukkan pada gambar 3.29 berikut.



Gambar 3.29 Fungsi confidence interval GAM pada variabel 'hari_laut' madidihang

Grafik di atas menunjukkan hubungan antara 'hari_laut' dan 's[hari_laut 8.87]', yang merupakan hasil dari model regresi GAM. Sumbu x, yang berlabel 'hari_laut', mewakili nilai 'hari_laut' dalam data. Nilai ini berkisar dari 0 hingga sekitar 350. Sumbu y, yang berlabel 's[hari_laut 8.87]', mewakili nilai prediksi dari model GAM. Nilai ini berkisar dari -80 hingga sekitar 40. Garis gelombang pada grafik mewakili hubungan antara 'hari_laut' dan 's[hari_laut 8.87]'. Garis ini menunjukkan bahwa seiring dengan peningkatan 'hari_laut', nilai 's[hari_laut 8.87]' mengalami fluktuasi. Grafik ini menunjukkan pola fluktuasi atau gelombang. Nilai 's[hari_laut 8.87]' naik dan turun secara berkala seiring dengan perubahan "hari_laut". Area berwarna abu-abu mengindikasikan rentang variabilitas data, yang tampaknya melebar seiring dengan peningkatan "hari_laut". Adapun Model GAM pada tangkapan ikan Madidihang sebagai berikut:

```
# Membangun model GAM
MadidihangCatch_ChloSST_without_outlier$ <-
as.factor(MadidihangCatch_ChloSST_without_outlier$)
modelgamMadidihang_alattangkap <- gam(CPUE ~ , data =
MadidihangCatch_ChloSST_without_outlier)
```

```
# Mendapatkan nilai AIC
AICMadidihangalattangkap_withoutoutlier <-
hang_alattangkap)
i AIC
galattangkap_withoutoutlier)
kasan model
```



summary(modelgamMadidihang_alattangkap)

Adapun hasil pemodelan tersebut sebagai berikut:

[1] 74744.57

Family: gaussian
Link function: identity

Formula:
CPUE ~ alat_tangkap

Parametric coefficients:

	Estimate	Std. Error	t value
(Intercept)	18.4581	0.8026	22.997
alat_tangkapHuhate	4.6378	1.4213	3.263
alat_tangkapJaring insang lainnya	-9.8866	22.7587	-0.434
alat_tangkapJaring insang lingkar	34.6669	10.2033	3.398
alat_tangkapPancing berjoran	67.6857	6.9045	9.803
alat_tangkapPancing Tonda	-9.6899	1.0269	-9.436
alat_tangkapPancing Ulur	-8.3492	1.0049	-8.308
alat_tangkapPukat cincin grup pelagis kecil	24.0419	9.3200	2.580
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal	75.6550	7.2371	10.454
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal	60.7086	16.1028	3.770
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	20.8439	1.3072	15.946
alat_tangkapPukat cincin satu kapal	28.2593	2.2023	12.832
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	30.9127	0.9318	33.175
alat_tangkapRawai hanyut	-7.7650	4.5322	-1.713
alat_tangkapRawai Tuna	-16.4415	1.0082	-16.308
			Pr(> t)
			< 2e-16
			0.001106
			0.664001



```

alat_tangkapJaring insang lingkaran 0.000683
alat_tangkapPancing berjoran < 2e-16
alat_tangkapPancing Tonda < 2e-16
alat_tangkapPancing Ulur < 2e-16
alat_tangkapPukat cincin grup pelagis kecil 0.009909
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal < 2e-16
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal 0.000164
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal < 2e-16
alat_tangkapPukat cincin satu kapal < 2e-16
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil < 2e-16
alat_tangkapRawai hanyut 0.086698
alat_tangkapRawai Tuna < 2e-16

```

```


(Intercept) ***
alat_tangkapHuhate **
alat_tangkapJaring insang lainnya ***
alat_tangkapJaring insang lingkaran ***
alat_tangkapPancing berjoran ***
alat_tangkapPancing Tonda ***
alat_tangkapPancing Ulur ***
alat_tangkapPukat cincin grup pelagis kecil **
alat_tangkapPukat cincin Pelagis Besar dengan satu kapal ***
alat_tangkapPukat Cincin Pelagis Kecil dengan Dua Kapal ***
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal ***
alat_tangkapPukat cincin satu kapal ***
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil ***
alat_tangkapRawai hanyut ***
alat_tangkapRawai Tuna ***

```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.416 Deviance explained = 41.7%
GCV = 518.26 Scale est. = 517.31 n = 8224

Pada model-model yang ditampilkan di atas adalah model tunggal. Untuk model gabungan ditunjukkan pada Gambar 3.30 sebagai berikut.



(a)



(b)

(c)


Gambar 3.30 Perbandingan fungsi smoothing 'edf' madidihang: (a) model gabungan, (b) model tunggal 'gt_kapal', dan (b) 'hari_laut'

Grafik (a) di atas menunjukkan analisis regresi nonparametrik menggunakan smoothing spline untuk memodelkan hubungan antara 'CPUE' dengan 'gt_kapal' dan 'hari_laut'. Kurva Spline menunjukkan hubungan non-linear yang kompleks pada kedua variabel, dengan 'CPUE' meningkat tajam setelah nilai 'gt_kapal' sekitar 60 dan stabil mendekati nol setelah fluktuasi awal pada 'hari_laut'. Area abu-abu menunjukkan interval kepercayaan, dengan ketidakpastian yang meningkat pada nilai yang lebih tinggi.

Grafik (b) di atas menunjukkan analisis regresi nonparametrik menggunakan smoothing spline untuk memodelkan hubungan antara 'CPUE' dan 'gt_kapal'. Kurva Spline menunjukkan hubungan non-linear, dengan fluktuasi pada rentang nilai 0 hingga 60, di mana 'CPUE' mengalami peningkatan dan penurunan kecil. Setelah nilai 60, kurva meningkat tajam hingga nilai 100, menunjukkan bahwa 'CPUE' cenderung meningkat signifikan dengan bertambahnya gross tonnage kapal. Area abu-abu menunjukkan interval kepercayaan, yang lebih lebar pada nilai tinggi, mengindikasikan ketidakpastian yang lebih besar dalam estimasi pada rentang tersebut. Adapun grafik (c) menunjukkan analisis regresi nonparametrik menggunakan smoothing spline untuk memodelkan hubungan antara 'CPUE' dan 'hari_laut'. Kurva Spline menunjukkan hubungan non-linear, dengan penurunan tajam pada awal hingga sekitar 50 hari di laut, kemudian berfluktuasi antara nilai 50 hingga 150 hari.

Untuk melihat distribusi data setiap parameter, maka digunakan grafik ECDF. Grafik ECDF adalah alat yang sangat berguna dalam analisis statistik. Adapun hubungan antara Nilai ECDF dan 'gt_kapal' pada ikan madidihang ditunjukkan pada Gambar 3.31 berikut.






Gambar 3.31 Hubungan antara 'gt_kapal' dan ECDF madidihiang

Grafik di atas adalah plot ECDF untuk variabel 'gt_kapal'. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga sedikit di atas 300. Sumbu y, yang berlabel 'ECDF', mewakili nilai kumulatif empiris dari data. Nilai ini berkisar dari 0 hingga 1. Garis pada grafik mewakili fungsi distribusi kumulatif empiris dari data 'gt_kapal'. Dari grafik, nampak bahwa nilai ECDF 'gt_kapal' adalah 24. Adapun hubungan antara Nilai ECDF 'hari_laut' pada penangkapan ikan madidihiang ditunjukkan pada Gambar 3.32 berikut.







Gambar 3.32 Hubungan antara 'hari_laut' dan ECDF madidihang

Grafik di atas adalah plot ECDF untuk variabel 'hari_laut'. Sumbu x, yang berlabel 'hari_laut', mewakili jumlah hari di laut. Nilai ini berkisar dari 0 hingga 300. Sumbu y, yang berlabel nilai 'Value', mewakili nilai kumulatif empiris dari data. Nilai ini berkisar dari 0 hingga 1. Garis pada grafik mewakili fungsi distribusi kumulatif empiris dari data 'hari_laut'. Dari grafik, nampak bahwa nilai 'hari_laut', nilai ECDF hari_laut adalah 8. Nilai-nilai pada fungsi ECDF pada 'gt_kapal' dan 'hari_laut' di atas diuji dengan uji Kolmogorov-Smirnov untuk memastikan signifikansinya. Hasil uji menunjukkan bahwa nilai p pada 'gt_kapal' dan 'hari_laut' masing-masing adalah $p\text{-value} < 2.2e-16$ ($p > 0.05$), sehingga keduanya diterima sebagai nilai signifikan. Untuk kisaran nilai optimal pada 'gt_kapal' dan 'hari_laut', dengan menggunakan persamaan fungsi 'kmeans' dan metode elbow. Untuk kluster 'gt_kapal' adalah 3, dan 'hari_laut' adalah 4. Nilai masing-masing titik 'elbow' tersebut selanjutnya dimasukkan dalam persamaan fungsi 'kmeans'. Hasil perhitungan tersebut menunjukkan bahwa kisaran nilai optimal 'gt_kapal' adalah 21 – 41 GT, dan 'hari_laut' adalah 24 – 42 hari. Nilai kluster pada 'gt_kapal' dan 'hari_laut' ditunjukkan pada Gambar 3.33 berikut.





(a)



(b)

Gambar 3.33 Metode elbow nilai optimum penangkapan madidihiang: (a) 'gt_kapal' dan (b) 'hari_laut'



pada aktivitas penangkapan tuna mata besar
na pada pemodelan Ikan Cakalang dan Madidihiang


sebelumnya, pada ikan Tuna Mata Besar juga dilakukan pengecekan pada pemodelan (dengan outlier), meliputi: frekuensi alat tangkap, distribusi data dengan histogram dan boxplot, serta pengecekan skewness. Terkait jenis peralatan tangkap yang digunakan pada ikan tuna mata besar adalah sebagaimana ditunjukkan pada Tabel 3.4 berikut.

Tabel 3.3 Peralatan tangkap ikan tuna mata besar

Alat Tangkap	Jumlah Penangkapan	Alat Tangkap	Jumlah Penangkapan
Bagan perahu	1	Hand Line Tuna	106
Huhate	14	Pancing Tonda	709
Pancing Ulur	162	Pukat cincin grup pelagis kecil	4
Pukat cincin Pelagis Kecil dengan satu kapal	6	Pukat cincin satu kapal	14
Purse Seine (Pukat Cincin) Pelagis Kecil	150	Rawai hanyut	51
Rawai Tuna	2,233		

Tabel di atas memberikan informasi mengenai jumlah penangkapan ikan berdasarkan jenis alat tangkap yang digunakan dalam kegiatan perikanan. Dari tabel tersebut, terlihat bahwa alat tangkap dengan jumlah penangkapan terbanyak adalah Rawai Tuna dengan 2233 penangkapan, menunjukkan efektivitas yang tinggi dalam menangkap tuna. Pancing Tonda juga menunjukkan jumlah penangkapan yang signifikan dengan 709 penangkapan. Sementara itu, alat tangkap lain seperti Hand Line Tuna dan Pancing Ulur memiliki jumlah penangkapan yang lebih rendah, masing-masing 106 dan 162. Alat tangkap tradisional seperti Bagan perahu menunjukkan jumlah penangkapan yang sangat kecil, hanya 1. Adapun kapal penangkap ikan tuna mata besar di kawasan WPP 714 umumnya memiliki ukuran yang bervariasi. Adapun distribusi kapal ditunjukkan pada Gambar 3.34 sebagai berikut.






Gambar 3.34 Grafik 'gt_kapal' tuna mata besar: (a) distribusi, dan (b) boxplot


Gambar (a) di atas menunjukkan distribusi frekuensi dari ukuran GT (Gross Tonnage) kapal dalam penelitian perikanan. Distribusi GT kapal ini tampak beberapa puncak frekuensi yang menonjol. Puncak frekuensi sekitar GT 25, menunjukkan bahwa sebagian besar kapal yang an GT di sekitar nilai tersebut. Selain itu, terdapat dua puncak lainnya, yaitu di sekitar GT 30 dan GT 50, yang juga



menunjukkan konsentrasi kapal pada ukuran-ukuran tersebut. Rentang GT kapal dalam data ini bervariasi dari 0 hingga 100, dengan beberapa interval yang menunjukkan frekuensi kapal yang lebih rendah, terutama pada GT di atas 75. Pola distribusi ini mengindikasikan adanya variasi yang besar dalam ukuran kapal yang digunakan dalam kegiatan perikanan, dengan konsentrasi tertinggi pada ukuran GT tertentu, khususnya sekitar GT 25, 30, dan 50.

Adapun gambar (b) di atas adalah boxplot yang menggambarkan distribusi ukuran GT (Gross Tonnage) kapal. Dalam boxplot ini, kotak merah merepresentasikan rentang interkuartil (IQR) dari data, yang membentang dari kuartil pertama (Q1) sekitar GT 24 hingga kuartil ketiga (Q3) sekitar GT 56. Garis horizontal di dalam kotak menunjukkan nilai median data, yang berada di sekitar GT 30. Panjang whisker menunjukkan rentang data yang lebih jauh dari nilai minimum (GT 1) hingga maksimum (GT 100). Tidak terdapat outlier yang ditunjukkan dalam boxplot ini. Visualisasi ini menunjukkan bahwa setengah dari data terdistribusi antara GT 24 dan GT 56, dengan konsentrasi nilai tengah (median) berada di GT 30, menandakan bahwa sebagian besar kapal yang diteliti memiliki ukuran GT dalam rentang tersebut. Rentang data yang cukup luas juga mengindikasikan adanya variasi yang signifikan dalam ukuran kapal yang digunakan dalam kegiatan perikanan. Mengenai "hari_laut" sebagai faktor teknis penangkapan tuna mata besar sangat penting untuk dipahami. Gambar 3.35 berikut adalah grafik histogram dan boxplot distribusi 'hari_laut'.






Gambar 3.35 Grafik 'hari_laut' tuna mata besar: (a) boxplot, dan (b) distribusi

Gambar (a) di atas menunjukkan distribusi frekuensi hari di laut (hari_laut) yang dihabiskan oleh kapal-kapal dalam penangkapan tuna mata besar. Distribusi ini tampak sangat skewed ke kanan, dengan mayoritas kapal menghabiskan waktu relatif singkat di laut. Puncak frekuensi tertinggi berada di kisaran 0 hingga 50 hari, dengan jumlah kapal yang signifikan beroperasi dalam rentang waktu tersebut. Setelah itu, frekuensi secara bertahap menurun, menunjukkan bahwa semakin sedikit kapal yang menghabiskan waktu lebih lama di laut. Terdapat beberapa kapal yang beroperasi lebih dari 100 hari, dengan jumlah yang semakin menurun hingga mendekati 300 hari, dan hanya sedikit yang melebihi angka tersebut.

Gambar (b) di atas adalah boxplot yang menggambarkan distribusi jumlah hari di laut (hari_laut) yang dihabiskan oleh kapal-kapal dalam kegiatan perikanan. Dari boxplot ini, terlihat bahwa rentang interkuartil (IQR) membentang dari sekitar 14 hari (Q1) hingga 109 hari (Q3), dengan nilai median berada di sekitar 47 hari, menunjukkan bahwa setengah dari kapal yang diteliti menghabiskan waktu antara 14 hingga 109 hari di laut. Garis whisker di bawah dan di atas kotak menunjukkan rentang data dari nilai minimum hingga maksimum, kecuali untuk beberapa outlier yang berada di atas 300 hari, yang ditandai dengan titik-titik individu. Kehadiran outlier ini menunjukkan bahwa ada beberapa kapal yang beroperasi jauh lebih lama daripada kebanyakan kapal lainnya. Secara keseluruhan, boxplot ini mengindikasikan bahwa mayoritas kapal menghabiskan kurang dari 100 hari di laut, dengan beberapa pengecualian yang menghabiskan waktu yang jauh lebih n variasi dalam pola operasi dan durasi penangkapan di antara diteliti. Adapun hubungan antara 'alat_tangkap' dan CPUE Gambar 3.36 berikut ini (outlier).





Gambar 3.36 Grafik hubungan antara 'alat_tangkap' dan CPUE tuna mata besar

Gambar di atas adalah boxplot yang menunjukkan hubungan antara jenis alat tangkap dan CPUE dalam kegiatan perikanan. Setiap alat tangkap diwakili oleh sebuah boxplot, yang menggambarkan distribusi CPUE untuk alat tangkap tersebut. Dari gambar ini, terlihat bahwa sebagian besar alat tangkap memiliki nilai CPUE yang rendah dan distribusi yang relatif sempit, seperti Bagan perahu, Hand Line Tuna, Huhate, Pancing Tonda, Pancing Ulur, dan alat tangkap lainnya dengan CPUE median yang mendekati nol. Namun, alat tangkap seperti Pukat cincin grup pelagis kecil dan Pukat cincin pelagis kecil dengan satu kapal menunjukkan distribusi CPUE yang lebih luas, dengan beberapa nilai yang sangat tinggi, mengindikasikan adanya variabilitas yang signifikan dalam efektivitas alat tangkap ini. Pukat cincin pelagis kecil dengan satu kapal memiliki median CPUE yang jauh lebih tinggi dibandingkan alat tangkap lainnya. Sementara itu, alat tangkap Purse Seine (Pukat Cincin) Pelagis Kecil menunjukkan beberapa outlier dengan nilai CPUE yang sangat tinggi, menandakan efektivitas yang tidak konsisten tetapi dengan potensi hasil tangkapan yang besar.

Adapun skewness yang dihasilkan adalah 0.214 untuk variabel 'gt_kapal' dan 1.635 untuk variabel 'hari_laut'. Kedua nilai skewness condong ke arah kanan (positif). Untuk pemodelan GAM dengan menggunakan data (outlier) digambarkan dalam formula:

```
# Membuat model GAM dengan keseluruhan data
model_with_outlier <- gam(CPUE ~ s(gt_kapal) + alat_tangkap +
  = TunaMataBesarCatch_ChloSST)

# AIC
losST_with_outlier <- AIC(model_with_outlier)
```

delan GAM tersebut ditunjukkan pada nilai berikut.



[1] 36280.2

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(gt_kapal) + alat_tangkap + s(hari_laut)

Parametric coefficients:

	Estimate	Std. Error
(Intercept)	24.349	46.355
alat_tangkapHand Line Tuna	-26.246	46.746
alat_tangkapHuhate	-2.389	48.056
alat_tangkapPancing Tonda	-20.886	46.545
alat_tangkapPancing Ulur	-14.246	46.543
alat_tangkapPukat cincin grup pelagis kecil	519.032	53.466
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-50.410	50.422
alat_tangkapPukat cincin satu kapal	95.006	48.326
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	118.203	46.897
alat_tangkapRawai hanyut	-12.267	46.734
alat_tangkapRawai Tuna	-15.859	46.346
	t value	Pr(> t)
(Intercept)	0.525	0.5994
alat_tangkapHand Line Tuna	-0.561	0.5745
alat_tangkapHuhate	-0.050	0.9604
alat_tangkapPancing Tonda	-0.449	0.6537
alat_tangkapPancing Ulur	-0.306	0.7596
alat_tangkapPukat cincin grup pelagis kecil	9.708	<2e-16 ***
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-1.000	0.3175
alat_tangkapPukat cincin satu kapal	1.966	0.0494 *
alat_tangkapPurse Seine (Pukat Cincin) Pelagis Kecil	2.520	0.0118 *
alat_tangkapRawai hanyut	-0.262	0.7930
alat_tangkapRawai Tuna	-0.342	0.7322

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:

	edf	Ref.df	F	p-value
s(gt_kapal)	8.349	8.775	54.637	<2e-16 ***
s(hari_laut)	8.845	8.993	9.243	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) = 0.553 Deviance explained = 55.7%
GCV = 2159.5 Scale est. = 2141.8 n = 3450

Hasil pemodelan di atas dapat dijelaskan sebagai berikut. Koefisien regresi yang dihasilkan oleh model menunjukkan seberapa besar pengaruh variabel independen terhadap variabel dependen. Misalnya, untuk alat_tangkapRawai Tuna, koefisiennya adalah -15.859, yang berarti bahwa setiap peningkatan satu unit dalam alat_tangkapHand Line Tuna akan meningkatkan nilai variabel dependen sebesar -15.859, dengan asumsi variabel lain tetap. Standar kesalahan (Std. Error) memberikan ukuran seberapa akurat prediksi koefisien. Semakin kecil standar kesalahan, semakin akurat estimasi koefisien. Misalnya, untuk alat_tangkapRawai Tuna, standar kesalahannya adalah 46.346, yang berarti bahwa estimasi koefisien -15.859 bervariasi sebesar ± 46.346 .




g besar menunjukkan bahwa smooth term tersebut memiliki
1. Untuk s(hari_laut), nilai F-nya adalah 54.637, yang berarti memiliki efek yang sangat signifikan. Nilai p yang kecil) menunjukkan bahwa variabel independen memiliki efek

signifikan. Dalam data nampak bahwa ada beberapa alat tangkap yang memiliki simbol *** (menunjukkan nilai $p < 0.001$), ** (menunjukkan nilai $p < 0.01$), * (menunjukkan nilai $p < 0.05$), dan . (menunjukkan nilai $p < 0.1$). Adapun Nilai R-squared sebesar 0.553, yang berarti bahwa model menjelaskan sekitar 55.7% variasi dalam data. Nilai GCV adalah 2,159.5. Sedangkan nilai AIC adalah 36280.2. Pengecekan multikolinearitas dilakukan dengan menggunakan fungsi 'vif'. Nilai 'vif' ditunjukkan sebagai berikut.


	GVIF	Df	GVIF ^{1/(2*Df)}
alat_tangkap	6.651642e+40	0	Inf
gt_kapal	6.651642e+40	0	Inf
hari_laut	6.651642e+40	0	Inf

Nilai GVIF di atas nampak sangat tinggi, ditunjukkan pada data dengan nilai mendekati tak terhingga (Inf). Ini mengindikasikan adanya multikolinearitas yang sangat tinggi. Nilai GVIF untuk variabel 'alat_tangkap', 'gt_kapal', dan 'hari_laut' masing-masing adalah 6.651642e+40 dengan derajat kebebasan (Df) 0, menghasilkan nilai $GVIF^{1/(2*Df)}$ yang tak terhingga. Adapun plot model GAM ditunjukkan pada Gambar 3.37 berikut.



(a)





(b)

Gambar 3.37 Fungsi Splines untuk variabel teknis penangkapan tuna mata besar: (a) 'gt_kapal' - 's(gt_kapal,8.35)', dan (b) dan 'hari_laut' - 's(hari_laut,8.84)'

Gambar (a) di atas merupakan plot hasil smoothing spline yang menunjukkan hubungan antara variabel independen gt_kapal dengan 'gt_kapal' - 's(gt_kapal,8.35)'. Pada sumbu x adalah nilai gt_kapal, dan pada sumbu y adalah nilai yang dihasilkan dari fungsi smoothing spline. Grafik ini memperlihatkan adanya kenaikan yang signifikan pada nilai variabel dependen ketika gt_kapal mencapai nilai di sekitar 80 hingga 100. Hal ini ditunjukkan oleh kurva yang mulai naik tajam setelah nilai gt_kapal melebihi angka tersebut. Garis putus-putus di sekitar garis utama menunjukkan interval kepercayaan, yang semakin lebar seiring dengan meningkatnya nilai gt_kapal, mengindikasikan peningkatan ketidakpastian prediksi pada rentang nilai yang lebih tinggi.

Gambar (b) di atas merupakan plot hasil smoothing spline yang menggambarkan hubungan antara variabel hari_laut (sumbu x) dengan s(hari_laut, 8.84). Grafik menunjukkan bahwa nilai variabel dependen relatif stabil dan rendah pada rentang nilai hari_laut dari 0 hingga sekitar 300 hari. Tidak ada tren kenaikan atau penurunan yang signifikan dalam rentang ini, yang ditunjukkan oleh garis utama yang relatif mendatar dan berada di sekitar nilai rendah. Garis putus-putus yang mengelilingi garis utama merupakan interval kepercayaan, yang tetap cukup sempit di sepanjang rentang, menunjukkan prediksi yang cukup stabil dan rendah ketidakpastian. Pada nilai hari_laut yang lebih tinggi (mendekati 300),

tingkatan pada variabel dependen, namun perubahan ini tidak kan dengan variabel gt_kapal pada grafik sebelumnya. Plot ini a variabel hari_laut memiliki dampak yang lebih stabil dan lebih tinggi terhadap variabel dependen dibandingkan dengan



gt_kapal, yang menunjukkan perubahan drastis pada nilai tinggi. Interpretasi ini bisa mengindikasikan bahwa durasi waktu di laut memiliki pengaruh yang konsisten dan tidak bervariasi secara ekstrem terhadap variabel yang diukur. Untuk melihat apakah ada pengaruh nilai outlier pada jenis alat tangkap – CPUE, maka model GAM dibandingkan dengan formula yang mengabaikan nilai outlier dengan menggunakan nilai 'threshold' 1. Nilai 'threshold' memiliki deviance explained lebih tinggi. Formula tersebut sebagai berikut.

```
# Handle outlier dengan metode pencapaian ambang (threshold)
threshold_gamTunaMataBesar <- 1
outliers_gamTunaMataBesar <- residuals(modelgam_TunaMataBesarChlosST)
> threshold_gamTunaMataBesar

# Model tanpa outlier
modelgam_TunaMataBesarChlosST_without_outlier <- gam(CPUE ~ s(gt_kapal) +
  alat_tangkap + s(hari_laut), data =
  TunaMataBesarCatch_ChlosST[!outliers_gamTunaM
  ataBesar, ])
```

Adapun hasil pemodelan tanpa outlier tersebut adalah sebagai berikut.

[1] 15415.71

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(gt_kapal) + alat_tangkap + s(hari_laut)

Parametric coefficients:

	Estimate	
(Intercept)	23.01	
alat_tangkapHand Line Tuna	-25.14	
alat_tangkapHuhate	-13.82	
alat_tangkapPancing Tonda	-20.80	
alat_tangkapPancing Ulur	-16.10	
alat_tangkapPukat cincin grup pelagis kecil	55.17	
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-42.32	
alat_tangkapPukat cincin satu kapal	30.44	
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	32.70	
alat_tangkapRawai hanyut	-12.42	
alat_tangkapRawai Tuna	-16.86	
	Std. Error	
(Intercept)	11.44	
alat_tangkapHand Line Tuna	11.69	
alat_tangkapHuhate	12.01	
alat_tangkapPancing Tonda	11.52	
alat_tangkapPancing Ulur	11.53	
alat_tangkapPukat cincin grup pelagis kecil	14.85	
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	13.47	
alat_tangkapPukat cincin satu kapal	12.26	
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	11.72	
alat_tangkapRawai hanyut	11.53	
alat_tangkapRawai Tuna	11.44	
	t value	
(Intercept)	2.011	
alat_tangkapHand Line Tuna	-2.151	
	-1.151	
g Tonda	-1.806	
g Ulur	-1.397	
cincin grup pelagis kecil	3.716	
cincin Pelagis Kecil dengan satu kapal	-3.142	
cincin satu kapal	2.483	



```

alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil 2.789
alat_tangkapRawai hanyut -1.077
alat_tangkapRawai Tuna -1.473
Pr(>|t|)
(Intercept) 0.044477
alat_tangkapHand Line Tuna 0.031600
alat_tangkapHuhate 0.249853
alat_tangkapPancing Tonda 0.071124
alat_tangkapPancing Ulur 0.162598
alat_tangkapPukat cincin grup pelagis kecil 0.000208
alat_tangkapPukat cincin Pelagis kecil dengan satu kapal 0.001704
alat_tangkapPukat cincin satu kapal 0.013113
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil 0.005339
alat_tangkapRawai hanyut 0.281524
alat_tangkapRawai Tuna 0.140818

(Intercept) *
alat_tangkapHand Line Tuna *
alat_tangkapHuhate
alat_tangkapPancing Tonda .
alat_tangkapPancing Ulur
alat_tangkapPukat cincin grup pelagis kecil ***
alat_tangkapPukat cincin Pelagis kecil dengan satu kapal **
alat_tangkapPukat cincin satu kapal *
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil **
alat_tangkapRawai hanyut
alat_tangkapRawai Tuna
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(gt_kapal)  8.947  8.999 417.01 <2e-16 ***
s(hari_laut)  8.887  8.995  21.39 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.85   Deviance explained = 85.2%
GCV = 131.22   Scale est. = 129.33    n = 1998

```

Dari kedua model di atas, nampak bahwa nilai model R-squared dengan outlier sebesar 0.553, sedangkan R-squared tanpa outlier memiliki nilai 0.85. Selain itu nilai AIC untuk model pertama adalah 36,280.2, lebih besar daripada nilai AIC model kedua adalah 15,415.71. Dengan demikian model tanpa outlier lebih baik dibandingkan dengan model yang menggunakan outlier. Adapun hubungan antara gt_kapal dan CPUE ditunjukkan pada Gambar 3.38 berikut.





Gambar 3.38 Grafik hubungan antara 'gt_kapal' dan CPUE tuna mata besar

Grafik di atas adalah scatter plot yang menggambarkan hubungan antara 'gt_kapal' dan 'CPUE'. Dalam grafik tersebut, sumbu x mewakili variabel 'gt_kapal', dan sumbu y mewakili 'CPUE'. Setiap titik pada grafik mewakili satu observasi dalam data, dengan koordinat titik tersebut menunjukkan nilai 'gt_kapal' dan 'CPUE' untuk observasi tersebut. Nilai rata-rata 'gt_kapal' pada dataframe ini adalah 38.47 (GT). Secara keseluruhan, grafik ini menunjukkan bahwa ada peningkatan "CPUE" dengan peningkatan "gt_kapal" setelah titik tertentu. Ini menunjukkan bahwa setelah kapal mencapai ukuran tertentu, upaya penangkapan menghasilkan peningkatan hasil tangkapan yang signifikan. Analisis regresi menggunakan model GAM berikut.

```
modelgamTunaMataBesar_gtkapal <- gam(CPUE ~ s(gt_kapal), data =
  TunaMataBesarCatch_ChloSST_without_o
  utlier)
```

Hasil analisis tersebut nampak sebagai berikut.

```
[1] 20248.76
```

```
Family: gaussian
Link function: identity
```

```
Formula:
CPUE ~ s(gt_kapal)
```



```
ients:
te Std. Error t value Pr(>|t|)
34      0.3995   18.46  <2e-16 ***
'***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```


Approximate significance of smooth terms:
      edf Ref.df      F p-value
s(gt_kapal) 8.945  8.999 264.4  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.507   Deviance explained = 50.9%
GCV = 370.78   Scale est. = 369.18       n = 2313

```

Nilai R-sq.(adj) terbilang baik 0.507, menunjukkan bahwa hubungan antara ukuran kapal 'gt_kapal' dengan CPUE memiliki korelasi yang kecil (Hua et al., 2019). Adapun nilai AIC adalah 20,248.76. Nilai 'R-sq.(adj)' atau R-squared yang disesuaikan dan nilai 'edf' atau derajat kebebasan yang diestimasi memiliki hubungan yang kompleks dalam model regresi GAM. 'R-sq.(adj)' adalah ukuran seberapa baik model menjelaskan variabilitas dalam data. Nilai ini berkisar antara 0 dan 1, dengan 1 menunjukkan bahwa model menjelaskan semua variabilitas dalam data. Dalam hal ini, 'R-sq.(adj)' adalah 0.507, yang berarti model menjelaskan sekitar 50.9% dari variabilitas dalam data.


Sementara itu, 'edf' adalah estimasi dari derajat kebebasan yang digunakan oleh fungsi smoothing dalam model. Adapun hubungan antara nilai 'hari_laut' dan CPUE ditunjukkan pada gambar 3.39 berikut. Nilai rata-rata 'hari_laut' pada dataframe ini adalah 27.93 hari.



Gambar 3.39 Fungsi confidence interval GAM pada variabel 'gt_kapal' tuna mata besar

Grafik di atas menunjukkan hubungan antara 'gt_kapal' dan 's[gt_kapal 8.94]', yang merupakan hasil dari model regresi GAM. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga sekitar 100. Sumbu y, yang berlabel 's[gt_kapal 8.94]', mewakili nilai prediksi dari CPUE ini berkisar dari 0 hingga sekitar 500. Adapun hubungan antara CPUE ditunjukkan pada gambar 3.40 berikut. Nilai rata-rata 'hari_laut' pada dataframe ini adalah 68.41 hari.





Gambar 3.40 Hubungan antara 'hari_laut' dan CPUE tuna mata besar

Gambar di atas menunjukkan scatter plot yang menggambarkan hubungan antara variabel `hari_laut` (sumbu x) dan `CPUE` (sumbu y). Terlihat bahwa pada nilai `hari_laut` yang sangat rendah, `CPUE` menunjukkan variasi yang sangat tinggi dengan beberapa outlier yang mencapai nilai lebih dari 600. Seiring dengan meningkatnya `hari_laut`, `CPUE` cenderung menurun drastis dan stabil di sekitar nilai yang sangat rendah setelah melewati titik sekitar 20 hari. Adapun koefisien regresi dibuat dalam model berikut:

```
[1] 18597.6

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(hari_laut)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   7.9768     0.5668   14.07  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df      F p-value
s(hari_laut)  8.942  8.999 76.82  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```



```
5 Deviance explained = 25.8%
e est. = 641.79      n = 1998
```

adj) 0.255, menunjukkan bahwa hubungan antara 'hari_laut' h rendah dibandingkan dengan hubungan antara 'gt_kapal'

dengan CPUE. Model ini mampu menjelaskan sekitar 25.8% dari variabilitas dalam data. Nilai AIC adalah 18,597.6. Adapun derajat kebebasan yang dimiliki oleh kolom 'hari_laut' ditunjukkan pada Gambar 3.41 berikut.

Gambar 3.41 Grafik fungsi confidence interval GAM pada variabel 'hari_laut' tuna mata besar

Gambar di atas adalah plot hasil smoothing spline yang menggambarkan hubungan antara variabel hari_laut (sumbu x) dengan $s(\text{hari_laut}, 8.97)$. Garis hitam pada plot menunjukkan nilai estimasi Spline, sedangkan area abu-abu di sekitar garis menunjukkan interval kepercayaan. Setelah penurunan awal, terdapat fluktuasi yang berkelanjutan, dengan puncak kecil sekitar hari ke-50 dan tren yang sedikit meningkat setelah hari ke-150. Adapun model GAM pada tangkapan ikan TunaMataBesar sebagai berikut.

```
# Membangun model GAM
TunaMataBesarCatch_ChloSST_without_outlier$ <-
as.factor(TunaMataBesarCatch_ChloSST_without_outlier$)
modelgamTunaMataBesar_alattangkap <- gam(CPUE ~ , data =
TunaMataBesarCatch_ChloSST_without_outlier)

# Mendapatkan nilai AIC
AICTunaMataBesaralattangkap_withoutoutlier <-
AIC(modelgamTunaMataBesar_alattangkap)

# Menampilkan nilai AIC
print(AICTunaMataBesaralattangkap_withoutoutlier)

# Menampilkan ringkasan model
summary(modelgamTunaMataBesar_alattangkap)
```

Hasil pemodelan di atas ditunjukkan sebagai berikut:



ntity

CPUE ~ alat_tangkap

Parametric coefficients:

	Estimate
(Intercept)	14.286
alat_tangkapHand Line Tuna	-5.167
alat_tangkapHuhate	-1.339
alat_tangkapPancing Tonda	-9.506
alat_tangkapPancing Ulur	-5.699
alat_tangkapPukat cincin grup pelagis kecil	360.714
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-5.786
alat_tangkapPukat cincin satu kapal	59.481
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	69.694
alat_tangkapRawai hanyut	-12.647
alat_tangkapRawai Tuna	-12.641
	Std. Error
(Intercept)	19.502
alat_tangkapHand Line Tuna	19.669
alat_tangkapHuhate	20.454
alat_tangkapPancing Tonda	19.523
alat_tangkapPancing Ulur	19.601
alat_tangkapPukat cincin grup pelagis kecil	23.885
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	22.519
alat_tangkapPukat cincin satu kapal	20.557
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	19.595
alat_tangkapRawai hanyut	19.764
alat_tangkapRawai Tuna	19.510
	t value
(Intercept)	0.733
alat_tangkapHand Line Tuna	-0.263
alat_tangkapHuhate	-0.065
alat_tangkapPancing Tonda	-0.487
alat_tangkapPancing Ulur	-0.291
alat_tangkapPukat cincin grup pelagis kecil	15.102
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	-0.257
alat_tangkapPukat cincin satu kapal	2.893
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	3.557
alat_tangkapRawai hanyut	-0.640
alat_tangkapRawai Tuna	-0.648
	Pr(> t)
(Intercept)	0.463932
alat_tangkapHand Line Tuna	0.792794
alat_tangkapHuhate	0.947795
alat_tangkapPancing Tonda	0.626369
alat_tangkapPancing Ulur	0.771275
alat_tangkapPukat cincin grup pelagis kecil	< 2e-16
alat_tangkapPukat cincin Pelagis Kecil dengan satu kapal	0.797261
alat_tangkapPukat cincin satu kapal	0.003851
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	0.000384
alat_tangkapRawai hanyut	0.522318
alat_tangkapRawai Tuna	0.517118


(Intercept)	
alat_tangkapHand Line Tuna	
alat_tangkapHuhate	
alat_tangkapPancing Tonda	
alat_tangkapPancing Ulur	
alat_tangkapPukat cincin grup pelagis kecil	***
alat_tangkapPukat cincin Pelagis kecil dengan satu kapal	
alat_tangkapPukat cincin satu kapal	**
alat_tangkapPurse Seine (Pukat Cincin) Pelagis kecil	***
hanyut	
Tuna	

*** 0.001 ** 0.01 * 0.05 . 0.1 ' ' 1



R-sq.(adj) = 0.558 Deviance explained = 56.1%
GCV = 382.43 Scale est. = 380.32 n = 1998

Hasil pemodelan di atas menunjukkan analisis regresi linear dengan variabel dependen CPUE dan beberapa variabel independen yang terkait dengan jenis alat tangkap yang digunakan. Nilai intercept sebesar 14.286 menunjukkan perkiraan CPUE saat semua variabel independen bernilai nol. Beberapa koefisien variabel independen yang signifikan secara statistik antara lain: Pukat cincin grup pelagis kecil dengan koefisien 360.714 dan Purse Seine (Pukat Cincin) Pelagis Kecil dengan koefisien 69.694, yang memiliki nilai $p < 0.001$, menunjukkan pengaruh positif yang kuat terhadap CPUE. Variabel Pukat cincin satu kapal juga signifikan dengan koefisien 59.481 ($p < 0.01$). Variabel lainnya tidak menunjukkan signifikansi statistik yang kuat ($p > 0.05$), yang mengindikasikan bahwa mereka tidak memiliki pengaruh yang signifikan terhadap CPUE dalam model ini. R-squared yang disesuaikan sebesar 0.558 menunjukkan bahwa model ini menjelaskan sekitar 56.1% variasi dalam CPUE. Nilai GCV sebesar 382.43 dan estimasi skala sebesar 380.32 menunjukkan ketepatan model dalam memprediksi data. Untuk model gabungan ditunjukkan pada Gambar 3.42 berikut.



(a)



(b)

(c)


Gambar 3.42 Perbandingan fungsi smoothing 'edf' tuna mata besar: (a) model gabungan 'gt_kapal' dan 'hari_laut', (b) model tunggal 'gt_kapal', dan model tunggal 'hari_laut'

Pada gambar (a) di atas menampilkan dua plot hasil smoothing spline yang menggambarkan hubungan antara variabel *gt_kapal* dan *hari_laut* dengan nilai. '*s(gt_kapal,8.96)*' dan '*s(hari_laut,8.94)*', terlihat bahwa nilai variabel dependen stabil pada nilai rendah ketika *gt_kapal* berada di bawah sekitar 80, namun meningkat tajam setelah nilai *gt_kapal* melebihi 80.

Pada gambar (b) di atas menampilkan hasil pemodelan menggunakan smoothing spline untuk menggambarkan hubungan antara *gt_kapal* (sumbu x) dan CPUE sebagai variabel dependen. Pada sumbu y ditunjukkan nilai transformasi Spline dari *gt_kapal*, yang dilabelkan sebagai *s(gt_kapal, 8.94)*. Kurva Spline memperlihatkan bahwa pada nilai *gt_kapal* yang rendah hingga sekitar 80, nilai CPUE relatif stabil dan rendah. Namun, setelah nilai *gt_kapal* melebihi 80, terlihat peningkatan yang sangat tajam pada CPUE. Garis hitam menggambarkan estimasi Spline, sementara garis-garis kecil di sepanjang sumbu x menunjukkan distribusi data observasi.

Adapun pada gambar (c) di atas menunjukkan hasil pemodelan menggunakan smoothing spline untuk menggambarkan hubungan antara *hari_laut* (sumbu x) dan CPUE sebagai variabel dependen. Kurva Spline dilabelkan sebagai *s(hari_laut, 8.97)*, dengan garis hitam yang mewakili estimasi Spline dan area abu-abu di sekitar garis yang menunjukkan interval kepercayaan. Dari grafik ini, terlihat bahwa pada nilai *hari_laut* yang sangat rendah, CPUE mengalami penurunan tajam. Setelah penurunan awal tersebut, nilai CPUE cenderung stabil dengan fluktuasi kecil yang terjadi dalam rentang nilai *hari_laut* antara 0 hingga sekitar 300 hari. Adapun hubungan antara Nilai ECDF dan '*gt_kapal*' pada ikan TunaMataBesar ditunjukkan pada gambar 3.43 berikut.






Gambar 3.43 Hubungan antara 'gt_kapal' dan ECDF tuna mata besar

Grafik di atas adalah plot ECDF untuk variabel 'gt_kapal'. Sumbu x, yang berlabel 'gt_kapal', mewakili nilai 'gt_kapal' dalam data. Nilai ini berkisar dari 0 hingga sedikit di atas 100. Sumbu y, yang berlabel 'ECDF', mewakili nilai kumulatif empiris dari data. Nilai ini berkisar dari 0 hingga 1. Garis pada grafik mewakili fungsi distribusi kumulatif empiris dari data 'gt_kapal'. Dari grafik, nampak bahwa nilai ECDF 'gt_kapal' adalah 42. Adapun hubungan antara Nilai ECDF 'hari_laut' pada penangkapan ikan tuna mata besar ditunjukkan pada gambar 3.44 berikut.






Gambar 3.44 Hubungan antara 'hari_laut' dan ECDF tuna mata besar


Grafik di atas adalah plot ECDF untuk variabel 'hari_laut'. Sumbu x, yang berlabel 'hari_laut', mewakili jumlah hari di laut. Nilai ini berkisar dari 0 hingga 300. Sumbu y, yang berlabel nilai 'Value', mewakili nilai kumulatif empiris dari data. Nilai ini berkisar dari 0 hingga 1. Garis pada grafik mewakili fungsi distribusi kumulatif empiris dari data 'hari_laut'. Dari grafik, nampak bahwa nilai 'hari_laut', nilai ECDF hari_laut adalah 7.

Nilai-nilai pada fungsi ECDF pada 'gt_kapal' dan 'hari_laut' di atas diuji dengan uji Kolmogorov-Smirnov untuk memastikan signifikansinya. Hasil uji menunjukkan bahwa nilai p pada 'gt_kapal' dan 'hari_laut' masing-masing adalah $p\text{-value} < 2.2e-16$ ($p > 0.05$), sehingga keduanya diterima sebagai nilai signifikan. Untuk kisaran nilai optimal pada 'gt_kapal' dan 'hari_laut', dengan menggunakan persamaan fungsi 'kmeans' dan metode elbow. Untuk kluster 'gt_kapal' adalah 3, dan 'hari_laut' adalah 3. Nilai masing-masing titik 'elbow' tersebut selanjutnya dimasukkan dalam persamaan fungsi 'kmeans'. Hasil perhitungan tersebut menunjukkan bahwa kisaran nilai optimal 'gt_kapal' adalah 42 – 99 GT, dan 'hari_laut' adalah 1 – 30 hari. Nilai kluster pada 'gt_kapal' dan 'hari_laut' ditunjukkan pada Gambar 3.45 berikut.





(a)



(b)

Gambar 3.45 Metode elbow nilai optimum penangkapan tuna mata besar: (a) 'gt_kapal' dan (b) 'hari_laut'



3.3.8 Fitting model Random Forest pada faktor teknis penangkapan

3.3.8.1 Model RF pada penangkapan cakalang

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
Call:
  randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,      data
= CakalangCatch_ChlosST)
  Type of random forest: regression
    Number of trees: 500
No. of variables tried at each split: 1

  Mean of squared residuals: 59794.37
    % Var explained: 26.86
```

Jenis random forest di atas yang digunakan adalah regresi. Model ini digunakan untuk memprediksi nilai kontinu dari variabel target 'CPUE'. Model ini terdiri dari 500 pohon. Lebih banyak pohon biasanya menghasilkan prediksi yang lebih baik, tetapi juga membutuhkan waktu komputasi yang lebih lama. Dalam setiap pemisahan di setiap pohon, hanya satu variabel yang dipertimbangkan. Rata-rata kuadrat residu dari model ini adalah 61,494.66. Residu adalah perbedaan antara nilai yang diamati dan nilai yang diprediksi oleh model. Jadi, ini adalah ukuran kesalahan model. Model ini mampu menjelaskan sekitar 27.72% dari variabilitas dalam variabel target 'CPUE'. Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_CakalangChlosST_without_outlier <- randomForest(CPUE ~ gt_kapal +
hari_laut + alat_tangkap, data = CakalangCatch_ChlosST_without_outlier)
```

Hasil pemodelan tanpa outlier ditunjukkan sebagai berikut:

```
Call:
  randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,      data
= CakalangCatch_ChlosST_without_outlier)
  Type of random forest: regression
    Number of trees: 500
No. of variables tried at each split: 1

  Mean of squared residuals: 2145.668
    % Var explained: 50.41
```

Hasil dari pemodelan tanpa menggunakan outlier menggunakan metode Random Forest ditunjukkan sebagai berikut. Pemodelan ini dilakukan untuk memprediksi rata-rata hasil tangkapan ikan (CPUE) berdasarkan variabel predictor gt_kapal (ukuran kapal), hari_laut (jumlah hari penangkapan ikan), dan alat_tangkap (jenis alat tangkap).

Jumlah pohon dalam model yang dihasilkan adalah 500, di mana pada setiap pemisahan node, hanya satu variabel yang dicoba. Model ini merupakan model regresi, yang berarti variabel target CPUE adalah variabel numerik yang akan diprediksi.



Model ini, diharapkan dapat ditemukan hubungan antara variabel yang digunakan dengan variabel target, sehingga dapat diperoleh prediksi yang akurat untuk CPUE berdasarkan gt_kapal, hari_laut, dan alat_tangkap. Hasil tersebut belum menggambarkan kualitas prediksi

dari model tersebut, sehingga perlu diuji lebih lanjut untuk mengevaluasi kinerja dan keakuratannya dalam memprediksi CPUE berdasarkan data tanpa outlier. Adapun kontribusi variabel prediktor ditunjukkan sebagai berikut.


	IncNodePurity
gt_kapal	5619144
hari_laut	10461487
alat_tangkap	7689260

Berdasarkan kontribusi variabel prediktor yang ditunjukkan, terdapat tiga variabel metrik IncNodePurity yaitu gt_kapal, hari_laut, dan alat_tangkap. Variabel gt_kapal memiliki kontribusi sebesar 5,619,144, hari_laut memiliki kontribusi sebesar 10,461,487, dan alat_tangkap memiliki kontribusi sebesar 7689260. Variabel IncNodePurity adalah sebuah indikator yang mengukur seberapa baik node memisahkan kelas target. Semakin tinggi nilai IncNodePurity, semakin baik node tersebut dalam memprediksi klasifikasi.

Variabel gt_kapal adalah jumlah tonnase kapal yang terlibat dalam aktivitas yang diamati. Jumlah kapal yang lebih besar dapat mengindikasikan adanya lebih banyak sumber daya yang digunakan, seperti pemancingan berlebihan atau penangkapan ikan yang tidak berkelanjutan. Dengan kontribusi sebesar 5,619,144, variabel ini memiliki pengaruh yang signifikan ketiga terhadap prediksi dan dapat menjadi indikator penting dalam memprediksi kelangsungan lingkungan.

Variabel hari_laut adalah jumlah hari laut yang diamati. Jika jumlah hari laut yang diamati lebih banyak, hal itu dapat mengindikasikan aktivitas manusia yang intensif di laut seperti penangkapan ikan yang berlebihan atau pembuangan limbah. Dengan kontribusi sebesar 10,461,487, variabel ini juga memiliki pengaruh yang signifikan tertinggi terhadap prediksi dan dapat memberikan informasi penting terkait aktivitas manusia di laut yang dapat memengaruhi kelangsungan lingkungan. Variabel alat_tangkap memberi kontribusi kedua terhadap prediksi. Adapun variabel importance plot ditunjukkan pada Gambar 3.46 sebagai berikut:





Gambar 3.46 Variabel importance plot – cakalang

Gambar di atas adalah "Variable Importance Plot" yang menunjukkan pentingnya masing-masing variabel dalam model Random Forest regresi yang telah dibuat. Tiga variabel yang dianalisis adalah 'hari_laut', 'alat_tangkap', dan 'gt_kapal'. Grafik ini menunjukkan tingkat kepentingan atau kontribusi setiap variabel terhadap prediksi model.

Dari plot tersebut, variabel 'hari_laut' memiliki tingkat kepentingan tertinggi dengan nilai sekitar $1.0e+07$, menunjukkan bahwa jumlah hari di laut merupakan faktor paling signifikan dalam memengaruhi prediksi CPUE. Variabel kedua adalah 'alat_tangkap' dengan tingkat kepentingan mendekati $7.5e+06$, yang menunjukkan bahwa jenis alat tangkap juga memiliki peran penting dalam model. Variabel 'gt_kapal' berada di posisi ketiga dengan nilai kepentingan sekitar $5.0e+06$, menunjukkan bahwa gross tonnage kapal juga berkontribusi dalam prediksi, namun dengan tingkat yang lebih rendah dibandingkan dua variabel lainnya.

Secara keseluruhan, plot ini mengindikasikan bahwa semua variabel yang digunakan dalam model memiliki kontribusi, namun 'hari_laut' adalah variabel yang paling dominan dalam memengaruhi hasil prediksi. Informasi ini penting untuk memahami variabel mana yang paling berpengaruh dan harus diperhatikan lebih lanjut dalam analisis atau dalam pengambilan keputusan berbasis data.

Adapun fungsi yang menggambarkan pengujian OOB (Out-of-Bag) error dengan variasi nilai mtry di dalam algoritme RandomForest pada model di atas ditunjukkan berikut ini.



r = 2144.725


```

mtry = 2  OOB error = 2137.302
Searching left ...
Searching right ...
  mtry OOBError
2      2 2137.302

mtry = 7  OOB error = 2190.623
Searching left ...
mtry = 6      OOB error = 2191.941
-0.0006015962 0.01
Searching right ...
mtry = 3      OOB error = 2191.194
-0.0002604731 0.01
  mtry OOBError
3      3 2191.194
6      6 2191.941
7      7 2190.623

```

Hasil tuning mtry menggunakan fungsi tuneRF menunjukkan bahwa parameter mtry yang optimal untuk model adalah 2, karena memberikan nilai Out-Of-Bag (OOB) error terendah, yaitu 2,137.302. Proses tuning dimulai dengan mtry = 1, menghasilkan OOB error sebesar 2,144.725. Selanjutnya, fungsi tuneRF mencari nilai mtry yang lebih kecil (disebut "Searching left") dengan mencoba mtry = 2 s.d 7, setelah mtry = 2, perbaikan relatif menjadi -0.000603, lebih kecil dari nilai ambang improve = 0.01. Namun, performa menjadi lebih rendah, sehingga tuning dihentikan sebagaimana ditunjukkan pada Gambar 3.47.



Gambar 3.47 OOB – Cakalang



menampilkan plot Out-Of-Bag (OOB) Error dari model Random untuk mengevaluasi pengaruh parameter mtry terhadap OOB error merupakan rata-rata kesalahan prediksi yang dihitung

menggunakan data yang tidak digunakan dalam proses pembuatan setiap pohon keputusan di dalam ensemble. Parameter `mtry` sendiri merujuk pada jumlah fitur (predictor) yang dipilih secara acak saat membangun setiap node dalam pohon keputusan. Dalam plot ini, sumbu vertikal merepresentasikan nilai OOB error, sementara sumbu horizontal menunjukkan nilai `mtry` yang diuji. Gambar 3.48 berikut adalah Partial Dependence 'hari_laut' pada penangkapan cakalang.

Gambar 3.48 Partial Dependence 'hari_laut' – cakalang

Grafik di atas adalah plot dependensi parsial untuk variabel 'hari_laut' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah 'hari_laut' dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam 'hari_laut' memengaruhi prediksi model ('yhat'). Ketika 'hari_laut' mendekati 0, 'yhat' berada di puncaknya (sekitar 120). Saat 'hari_laut' meningkat dari 0 hingga sekitar 50, 'yhat' mengalami penurunan tajam. Setelah penurunan tajam ini, garis menjadi datar dan tetap relatif datar untuk nilai 'hari_laut' yang lebih tinggi. Ini menunjukkan bahwa peningkatan 'hari_laut' awalnya memiliki efek negatif yang signifikan pada 'yhat', tetapi setelah mencapai titik tertentu (sekitar 50), efeknya menjadi stabil dan tidak berubah banyak dengan peningkatan lebih lanjut dalam 'hari_laut'. Gambar 3.49 merupakan Partial Dependence 'gt_kapal' pada penangkapan cakalang.



Gambar 3.49 Partial Dependence 'gt_kapal' – cakalang

Grafik di atas adalah plot dependensi parsial untuk variabel 'gt_kapal' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model.

Dalam grafik ini, sumbu x adalah 'gt_kapal' dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam 'gt_kapal' memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 20 dan 40 saat 'gt_kapal' meningkat dari 0 hingga sekitar 80. Setelah 'gt_kapal' melebihi sekitar 80, terjadi peningkatan tajam dalam nilai 'yhat' hingga mencapai di atas 50.

Ini menunjukkan bahwa peningkatan 'gt_kapal' awalnya memiliki efek yang bervariasi pada 'yhat', tetapi setelah mencapai titik tertentu (sekitar 80), efeknya menjadi lebih signifikan dan 'yhat' meningkat tajam. Ini menunjukkan bahwa kapal dengan 'gt_kapal' lebih besar memiliki dampak yang lebih besar pada variabel target. Gambar 3.50 berikut adalah Partial Dependence 'alat_tangkap' pada penangkapan cakalang.



Gambar 3.50 Partial Dependence 'alat_tangkap' – cakalang

Grafik di atas adalah plot dependensi parsial untuk variabel 'alat_tangkap' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah 'alat_tangkap' yang mewakili berbagai jenis alat tangkap, dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Setiap titik pada grafik mewakili jenis alat tangkap tertentu dan nilai 'yhat' yang sesuai.

Ada 18 kategori alat tangkap yang berbeda yang ditampilkan di sumbu x. Nilai 'yhat' untuk setiap alat tangkap bervariasi antara sekitar 20 hingga sedikit di atas 50. Grafik ini menunjukkan bagaimana perubahan dalam jenis 'alat_tangkap' memengaruhi prediksi model ('yhat').

3.3.8.2 Model RF pada penangkapan madidihang

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
model_rf <- randomForest(CPUE ~ gt_kapal + hari_laut + alat_tangkap, data = MadidihangCatch_ChlosST)
```

Adapun hasil model RF tersebut ditunjukkan sebagai berikut:

```
Call:
randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,
data = MadidihangCatch_ChlosST)
Type of random forest: regression
Number of trees: 500
ried at each split: 1
squared residuals: 9457.061
% Var explained: 34.31
```



Mean of squared residuals dari model di atas adalah 9,457.061. Adapun % Var explained adalah 34.31. Ini adalah persentase varians yang dijelaskan oleh model. Dalam hal ini, model menjelaskan sekitar 34.31% dari variabilitas dalam variabel target CPUE. Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_MadidihangChloSST_without_outlier <- randomForest(CPUE ~ gt_kapal
+ hari_laut + alat_tangkap, data =
MadidihangCatch_ChloSST_without_outlier)
```

Hasil pemodelan tanpa outlier:

```
Call:
randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,
data = MadidihangCatch_ChloSST_without_outlier)
Type of random forest: regression
Number of trees: 500
No. of variables tried at each split: 1


Mean of squared residuals: 393.4205
% Var explained: 55.9
```

Setelah outlier dibatasi, model menunjukkan peningkatan kinerja, nilai Mean of squared residuals menurun, sedangkan % Var explained meningkat menjadi 66.15%. Kontribusi variabel prediktor ditunjukkan sebagai berikut:

	IncNodePurity
gt_kapal	805534.6
hari_laut	1935727.0
alat_tangkap	1727037.3

Dalam hal ini, hari_laut memiliki nilai "IncNodePurity" tertinggi, yang berarti variabel ini paling penting dalam memprediksi CPUE menurut model Random Forest. Variabel alat_tangkap juga dan gt_kapal penting, tetapi kurang penting dibandingkan hari_laut. Adapun variabel importance plot ditunjukkan pada Gambar 3.51 berikut.





Gambar 3.51 Variabel Importance Plot – madidihang

Grafik Variable Importance Plot ini menampilkan tingkat kepentingan tiga variabel dalam suatu model analisis atau prediktif. Variabel hari_laut memiliki nilai kepentingan tertinggi, yang menunjukkan bahwa jumlah hari di laut merupakan faktor paling berpengaruh dalam memengaruhi hasil model. Di posisi kedua, variabel alat_tangkap menunjukkan kontribusi signifikan, yang berkaitan dengan jenis atau metode alat tangkap yang digunakan dan dampaknya terhadap hasil analisis. Sementara itu, variabel gt_kapal memiliki tingkat kepentingan paling rendah dibandingkan kedua variabel lainnya, meskipun tetap memberikan kontribusi yang relevan terhadap model. Secara keseluruhan, grafik ini menunjukkan bahwa hari_laut dan alat_tangkap memainkan peran utama dalam menentukan hasil, sedangkan gt_kapal memberikan pengaruh tambahan namun tidak sebesar dua variabel sebelumnya.

```
mtry = 1 OOB error = 394.1521
Searching left ...
Searching right ...
mtry OOBError
1 1 394.1521
```

```
mtry = 2 OOB error = 390.5673
Searching left ...
Searching right ...
mtry OOBError
2 2 390.5673
```




```
r = 396.872
= 395.257
= 396.4909
```

```

0.0009603134 0.01
mtry OOBError
3 3 396.4909
6 6 395.2570
7 7 396.8720

```

Hasil tuning mtry menunjukkan bahwa nilai parameter yang optimal untuk model adalah 2, dengan nilai Out-Of-Bag (OOB) error terendah sebesar 390.567. Proses dimulai dengan mtry = 1, menghasilkan OOB error sebesar 394.152, kemudian dilanjutkan dengan pencarian ke arah kiri ("Searching left") untuk nilai mtry = 6, yang memberikan perbaikan relatif sebesar 0.00407 dibandingkan iterasi sebelumnya. Karena perbaikan ini lebih kecil dari ambang batas improve = 0.01, fungsi melanjutkan pencarian. Saat mencoba mtry = 3 ("Searching right"), OOB error meningkat menjadi 396.4909, menunjukkan bahwa nilai mtry = 3 kurang optimal dibandingkan mtry = 2. Perubahan relatif antara iterasi terakhir (mtry = 3) hanya sebesar 0.00096, yang tidak memenuhi kriteria improve, sehingga pencarian dihentikan. Kesimpulannya, nilai optimal mtry adalah 2, karena menghasilkan keseimbangan terbaik antara jumlah prediktor yang digunakan dan performa model. Gambar 3.52 adalah OOB pada penangkapan madidihang.



Gambar 3.52 OOB – madidihang

Grafik ini merupakan plot Out-Of-Bag (OOB) Error dari model Random Forest yang mengevaluasi performa model terhadap parameter mtry. Sumbu vertikal menunjukkan nilai OOB Error, yang digunakan untuk mengukur tingkat kesalahan prediksi pada data yang tidak digunakan dalam proses pembuatan model. Sementara itu, sumbu horizontal menunjukkan nilai mtry, yaitu jumlah fitur (prediktor) yang dipilih secara acak saat setiap model dibuat.



Dalam grafik ini, tujuh nilai $mtry$ yang diuji, yaitu $mtry = 1$ s.d. 7, dan nilai OOB Error berada pada kisaran antara 300 hingga 400. Plot ini memberikan gambaran awal tentang kinerja model, di mana tingkat kesalahan masih cukup signifikan. Untuk mendapatkan hasil yang lebih optimal, perlu dilakukan pengujian dengan berbagai nilai $mtry$ dan membandingkan OOB error untuk menemukan kombinasi parameter yang meminimalkan kesalahan prediksi. Gambar 3.53 adalah Partial Dependence 'hari_laut' pada penangkapan madidihang.

Gambar 3.53 Partial Dependence 'hari_laut' – madidihang

Grafik di atas adalah plot dependensi parsial untuk variabel 'hari_laut' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah 'hari_laut' dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam 'hari_laut' memengaruhi prediksi model ('yhat'). Ketika 'hari_laut' mendekati 0, 'yhat' berada di puncaknya (sekitar 40). Saat 'hari_laut' meningkat dari 0 hingga sekitar 50, 'yhat' mengalami penurunan tajam. Setelah penurunan tajam ini, garis menjadi datar dan tetap relatif datar untuk nilai 'hari_laut' yang lebih tinggi.

Ini menunjukkan bahwa peningkatan 'hari_laut' awalnya memiliki efek negatif yang signifikan pada 'yhat', tetapi setelah mencapai titik tertentu (sekitar 50), efeknya menjadi stabil dan tidak berubah banyak dengan peningkatan lebih lanjut dalam 'hari_laut'. Ini menunjukkan bahwa setelah sejumlah hari tertentu di laut, peningkatan lebih lanjut dalam jumlah hari tidak memiliki efek signifikan pada

ambar 3.54 berikut adalah Partial Dependence 'gt_kapal' pada dihang.



Gambar 3.54 Partial Dependence 'gt_kapal' – madidihang

Grafik di atas adalah plot dependensi parsial untuk variabel 'gt_kapal' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah 'gt_kapal' dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam 'gt_kapal' memengaruhi prediksi model ('yhat').

Nilai 'yhat' berfluktuasi antara 20 dan 30 saat 'gt_kapal' meningkat dari 0 hingga sekitar 60. Setelah 'gt_kapal' melebihi sekitar 60, terjadi peningkatan tajam dalam nilai 'yhat' hingga mencapai mendekati 50. Ini menunjukkan bahwa peningkatan 'gt_kapal' awalnya memiliki efek yang bervariasi pada 'yhat', tetapi setelah mencapai titik tertentu (sekitar 60), efeknya menjadi lebih signifikan dan 'yhat' meningkat tajam. Ini menunjukkan bahwa kapal dengan 'gt_kapal' lebih besar memiliki dampak yang lebih besar pada variabel target. Gambar 3.55 berikut adalah Partial Dependence 'alat_tangkap' pada penangkapan madidihang.



Gambar 3.55 Partial Dependence 'alat_tangkap' – madidihang

Grafik yang berikan adalah plot dependensi parsial untuk variabel 'alat_tangkap' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model.

Dalam grafik ini, sumbu x adalah 'alat_tangkap' yang mewakili berbagai jenis alat tangkap, dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Setiap titik pada grafik mewakili jenis alat tangkap tertentu dan nilai 'yhat' yang sesuai. Ada berbagai jenis alat tangkap yang ditampilkan di sumbu x. Nilai 'yhat' untuk setiap alat tangkap tampaknya memiliki variasi yang relatif kecil, karena semua titik data tampaknya berada dalam rentang yang sama di sumbu y.


3.3.8.3 Model RF pada penangkapan tuna mata besar

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
model_rf <- randomForest(CPUE ~ gt_kapal + hari_laut + alat_tangkap, data = TunaMataBesarCatch_Ch1oSST)
```

Adapun hasil model RF tersebut ditunjukkan sebagai berikut:

```
Call:
randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,
data = TunaMataBesarCatch_Ch1oSST)
Type of random forest: regression
Number of trees: 500
No. of variables tried at each split: 1
```



```
squared residuals: 2072.064
% Var explained: 56.75
```

squared residuals dari model di atas adalah 2,072.064. Adapun

% Var explained adalah 56.75. Ini adalah persentase varians yang dijelaskan oleh model. Dalam hal ini, model menjelaskan sekitar 56.75% dari variabilitas dalam variabel target CPUE. Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_TunaMataBesarChlosST_without_outlier <- randomForest(CPUE ~  
gt_kapal + hari_laut + alat_tangkap, data =  
TunaMataBesarCatch_ChlosST_without_outlier)
```

Hasil pemodelan tanpa outlier, model menunjukkan peningkatan kinerja, nilai Mean of squared residuals menurun, sedangkan % Var explained meningkat menjadi 67.75%. Kontribusi variabel prediktor ditunjukkan sebagai berikut:


```
Call:  
randomForest(formula = CPUE ~ gt_kapal + hari_laut + alat_tangkap,  
data = TunaMataBesarCatch_ChlosST_without_outlier)  
Type of random forest: regression  
Number of trees: 500  
No. of variables tried at each split: 1  
  
Mean of squared residuals: 241.4409  
% Var explained: 67.75
```

Kontribusi variabel masing-masing prediktor pada model ditunjukkan sebagai berikut:

	IncNodePurity
gt_kapal	582062.8
hari_laut	343315.3
alat_tangkap	560546.3

Dalam hal ini, gt_kapal memiliki nilai "IncNodePurity" tertinggi, yang berarti variabel ini paling penting dalam memprediksi CPUE menurut model Random Forest. Variabel alat_tangkap dan hari_laut juga penting, tetapi kurang penting dibandingkan gt_kapal pada model ini. Adapun variabel importance plot ditunjukkan pada Gambar 3.56 berikut.





Gambar 3.56 Variabel Importance Plot – tuna mata besar

Grafik ini menampilkan Variable Importance Plot yang digunakan untuk mengidentifikasi seberapa besar kontribusi masing-masing variabel prediktor terhadap kinerja model. Sumbu horizontal menunjukkan tingkat importance atau kepentingan dari setiap variabel, sedangkan sumbu vertikal menampilkan nama-nama variabel yang diuji. Dari hasil grafik, terlihat bahwa variabel `gt_kapal` memiliki tingkat kepentingan tertinggi, diikuti oleh variabel `alat_tangkap` sebagai variabel kedua paling berpengaruh. Sementara itu, variabel `hari_laut` memiliki tingkat kepentingan yang paling rendah dibandingkan dua variabel lainnya.

Secara keseluruhan, variabel `gt_kapal` dan `alat_tangkap` memiliki pengaruh signifikan dalam menentukan hasil model, sedangkan `hari_laut` memberikan kontribusi yang lebih kecil. Informasi ini dapat membantu dalam memahami faktor-faktor utama yang memengaruhi performa model dan memberikan panduan untuk optimasi selanjutnya dalam analisis data atau pengambilan keputusan berbasis model.

```
mtry = 1 OOB error = 221.4444
Searching left ...
Searching right ...
  mtry OOBError
1      1 221.4444
```

```
mtry = 2 OOB error = 185.5894
Searching left ...
Searching right ...
  mtry OOBError
```



```
r = 220.8068
```


```
r = 190.2637
```

```

mtry = 5 OOB error = 208.6034
-0.09639083 0.01
Searching right ...
mtry = 3 OOB error = 192.9817
-0.01428518 0.01
  mtry OOBError
3      3 192.9817
5      5 208.6034
6      6 190.2637
7      7 220.8068

```

Hasil tuning mtry menunjukkan bahwa nilai parameter yang optimal adalah 2, dengan nilai Out-Of-Bag (OOB) error terendah sebesar 185.589. Proses dimulai dengan mtry = 1 s.d 7, yang menghasilkan OOB error sebesar 221.444, kemudian pencarian bergerak ke kiri (nilai mtry lebih kecil). Ketika mtry = 5, OOB error naik sampai signifikan menjadi 208.603, dengan perbaikan relatif sebesar -0.0964, yang di bawah ambang improve = 0.01. Fungsi melanjutkan pencarian ke mtry = 6, tetapi OOB error meningkat menjadi 190.264, menunjukkan penurunan performa dengan perubahan relatif 0.138, sehingga nilai ini kurang optimal. Kesimpulannya, nilai mtry optimal adalah 2, yang memberikan performa terbaik dengan OOB error paling rendah. Gambar 3.57 berikut adalah OOB pada tuna mata besar.



Gambar 3.57 OOB – tuna mata besar

Grafik ini menunjukkan Out-Of-Bag (OOB) Error pada model Random Forest dengan parameter mtry yang diuji dari 1 s.d. 7. Sumbu vertikal nilai OOB Error, yang digunakan untuk mengukur kesalahan angka sumbu horizontal menunjukkan nilai parameter mtry. at bahwa nilai OOB Error berkisar antara 190 hingga 220.



Nilai OOB Error yang ditampilkan memberikan indikasi performa model pada konfigurasi mtry tersebut. Untuk memperoleh performa yang optimal, biasanya perlu dilakukan pengujian terhadap berbagai nilai mtry dan dibandingkan OOB Error-nya. Grafik ini berfungsi sebagai langkah awal dalam mengevaluasi parameter model Random Forest, di mana hasil lebih lengkap dapat diperoleh dengan eksplorasi parameter yang lebih luas. Gambar 3.58 berikut adalah Partial Dependence 'hari_laut' pada penangkapan tuna mata besar.

Gambar 3.58 Partial Dependence 'hari_laut' – tuna mata besar

Grafik di atas menunjukkan hubungan antara variabel hari_laut (jumlah hari di laut) pada sumbu horizontal dengan nilai prediksi yhat pada sumbu vertikal, yang dihasilkan dari model prediktif. Terlihat bahwa ketika nilai hari_laut mendekati nol, nilai yhat berada pada angka yang tinggi, sekitar 25 atau lebih. Namun, seiring dengan meningkatnya nilai hari_laut, nilai yhat menurun drastis hingga stabil pada angka sekitar 5 setelah hari_laut melebihi 50 hari.

Grafik tersebut mengindikasikan adanya pengaruh yang signifikan dari variabel hari_laut terhadap hasil prediksi model. Penurunan tajam di awal menunjukkan bahwa peningkatan hari_laut memiliki dampak besar terhadap yhat pada tahap awal, tetapi pengaruhnya cenderung stabil ketika nilai hari_laut mencapai jumlah tertentu. Grafik ini dapat membantu dalam memahami pola hubungan antara prediktor hari_laut dan respons yhat, serta memberikan wawasan tentang bagaimana variabel ini berkontribusi dalam model yang digunakan.

Gambar 3.59 Partial Dependence 'gt_kapal' – tuna mata besar




Gambar 3.59 Partial Dependence 'gt_kapal' – tuna mata besar

Grafik yang diberikan adalah plot dependensi parsial untuk variabel 'gt_kapal' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model.

Dalam grafik ini, sumbu x adalah 'gt_kapal' dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam 'gt_kapal' memengaruhi prediksi model ('yhat'). Nilai 'yhat' tetap relatif datar dan dekat dengan nol saat 'gt_kapal' meningkat dari 0 hingga sekitar 80.

Ada peningkatan tajam dalam nilai 'yhat' saat 'gt_kapal' mendekati 80, di mana kemudian mencapai platou lagi pada nilai yang tinggi. Ini menunjukkan bahwa peningkatan 'gt_kapal' awalnya memiliki efek minimal pada 'yhat', tetapi setelah mencapai titik tertentu (sekitar 80), efeknya menjadi lebih signifikan dan 'yhat' meningkat tajam. Ini menunjukkan bahwa kapal dengan 'gt_kapal' lebih besar memiliki dampak yang lebih besar pada variabel target. Gambar 3.60 berikut adalah Partial Dependence 'alat_tangkap' pada penangkapan tuna mata besar.





Gambar 3.60 Partial Dependence 'alat_tangkap' – tuna mata besar

Grafik yang diberikan adalah plot dependensi parsial untuk variabel 'alat_tangkap' dari model Random Forest. Plot dependensi parsial digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah 'alat_tangkap' yang mewakili berbagai jenis alat tangkap, dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Setiap titik pada grafik mewakili jenis alat tangkap tertentu dan nilai 'yhat' yang sesuai. Ada berbagai jenis alat tangkap yang ditampilkan di sumbu x. Nilai 'yhat' untuk setiap alat tangkap tampaknya memiliki variasi yang relatif kecil, karena semua titik data tampaknya berada dalam rentang yang sama di sumbu y.

3.3.9 Tuning model Boosted Regression Tree (BRT)

3.3.9.1 BRT cakalang


Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtCakalangChloSST_outlier <- gbm(CPUE ~ gt_kapal + hari_laut +
  alat_tangkap,
  data = cakalangCatch_chloSST,
  distribution = "gaussian",
  n.trees = 100,
  interaction.depth = 3,
  shrinkage = 0.01)
```



Model BRT menunjukkan sejauh mana setiap variabel memengaruhi cakupan hasil tangkapan oleh grafik relative influence. Nilai ini dihitung rata-rata dalam kesalahan prediksi ketika suatu variabel diacak. Berikut adalah grafik BRT relative influence pada cakalang. Gambar 3.61 berikut adalah grafik relative influence

pada penangkapan cakalang.



Gambar 3.61 Grafik relative influence - cakalang (outlier)


Grafik ini menunjukkan hasil dari model BRT, yang menampilkan pengaruh relatif dari tiga variabel: “hari_laut”, “alat_tangkap”, dan “gt_kapal”. Variabel ‘hari_laut’ memiliki variabel dengan pengaruh relatif tertinggi, dengan nilai lebih dari 60. Ini berarti bahwa variabel ‘hari_laut’ memiliki pengaruh paling signifikan terhadap model BRT.

Adapun ‘alat_tangkap’ memiliki variabel dengan pengaruh relatif sekitar 20, yang berarti pengaruhnya lebih rendah dibandingkan dengan “hari_laut” tetapi masih cukup signifikan. Sedangkan ‘gt_kapal’, merupakan variabel yang memiliki pengaruh relatif paling rendah, dengan nilai sedikit lebih dari 10. Ini berarti bahwa variabel “gt_kapal” memiliki pengaruh paling kecil terhadap model BRT. Secara keseluruhan, grafik ini menunjukkan bahwa “hari_laut” adalah variabel paling penting dalam model ini, diikuti oleh “alat_tangkap”, dan “gt_kapal”. Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtCakalangChlosST_outlier <- gbm(CPUE ~ gt_kapal + hari_laut +  
  alat_tangkap,  
  data = CakalangCatch_ChlosST_without_outlier,  
  distribution = "gaussian",  
  n.trees = 100,  
  interaction.depth = 3,  
  shrinkage = 0.01)
```

Hasil model dengan menggunakan outlier ditunjukkan sebagaimana Gambar 3.62 berikut.






Gambar 3.62 Grafik relative influence - cakalang (tanpa outlier)

Grafik di atas menunjukkan hasil dari model BRT tanpa menggunakan outlier, yang menampilkan pengaruh relatif dari tiga variabel: 'hari_laut', 'alat_tangkap', dan 'gt_kapal'. Variabel 'hari_laut' memiliki pengaruh relatif tertinggi, dengan nilai lebih dari 60. Ini berarti bahwa variabel "hari_laut" memiliki pengaruh paling signifikan terhadap model BRT.

Variabel 'alat_tangkap' memiliki pengaruh relatif sekitar 30, yang berarti pengaruhnya lebih rendah dibandingkan dengan "hari_laut" tetapi masih cukup signifikan. Adapun variabel 'gt_kapal' memiliki pengaruh relatif paling rendah, dengan nilai sedikit lebih dari 10. Ini berarti bahwa variabel "gt_kapal" memiliki pengaruh paling kecil terhadap model BRT. Secara keseluruhan, grafik ini menunjukkan bahwa "hari_laut" adalah variabel paling penting dalam model ini, diikuti oleh variabel 'alat_tangkap', dan "gt_kapal".

Untuk memahami seberapa penting variabel gt_kapal dalam model dan bagaimana hubungan antara gt_kapal dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel gt_kapal memengaruhi prediksi model, sebagaimana Gambar 3.63 berikut.






Gambar 3.63 Grafik antara variabel 'gt_kapal' dan respons model BRT

Grafik di atas menunjukkan hubungan antara variabel 'gt_kapal' dan respons model BRT. Dari grafik di atas, kita dapat melihat beberapa pola. Ketika 'gt_kapal' berada di kisaran 0 hingga sekitar 50, respons 'y' meningkat secara perlahan. Di sekitar 'gt_kapal' 50, terjadi peningkatan yang lebih tajam dalam respons 'y'. Setelah mencapai nilai 'y' sekitar 66, respons 'y' cenderung stabil hingga 'gt_kapal' mencapai sekitar 100. Pada 'gt_kapal' 100, terjadi peningkatan tajam lainnya dalam respons 'y'.

Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi positif antara 'gt_kapal' dan respons model BRT, dengan beberapa titik di mana laju perubahan respons 'y' berubah secara signifikan. Ini menunjukkan bahwa 'gt_kapal' memiliki pengaruh yang signifikan terhadap model BRT. Pada grafik hubungan antara variabel 'hari_laut' dan respons model BRT ditunjukkan sebagaimana Gambar 3.64 berikut.






Gambar 3.64 Grafik antara variabel 'hari_laut' dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel 'hari_laut' dan respons model BRT. Ketika 'hari_laut' berada di kisaran 0, respons 'Y' sangat tinggi, mendekati 80. Terjadi penurunan tajam dalam respons 'Y' seiring dengan peningkatan 'hari_laut', dan mulai stabil di sekitar nilai 40 ketika 'hari_laut' mencapai sekitar 20. Setelah itu, respons 'Y' tampaknya stabil meskipun 'hari_laut' terus meningkat hingga lebih dari 300.

Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi negatif antara 'hari_laut' dan respons model BRT pada awalnya, tetapi setelah mencapai titik tertentu, perubahan dalam 'hari_laut' tampaknya tidak memiliki pengaruh yang signifikan terhadap respons 'Y'. Ini menunjukkan bahwa 'hari_laut' memiliki pengaruh yang signifikan terhadap model BRT pada nilai-nilai rendah, tetapi pengaruh ini berkurang pada nilai-nilai yang lebih tinggi. Adapun grafik hubungan antara variabel 'alat_tangkap' dan respons model BRT ditunjukkan sebagaimana Gambar 3.65 berikut.





Gambar 3.65 Grafik antara variabel 'alat_tangkap' dan respons model BRT


3.3.9.2 BRT madidihang

Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtMadidihangChlosST_outlier <- gbm(CPUE ~ gt_kapal + hari_laut
      + alat_tangkap,
      data = MadidihangCatch_ChlosST,
      distribution = "gaussian",
      n.trees = 100,
      interaction.depth = 3,
      shrinkage = 0.01)
```

Output dari model tersebut sebagaimana ditunjukkan pada Gambar 3.66 berikut adalah grafik BRT relative influence pada penangkapan ikan Madidihang.





Gambar 3.66 Grafik relative influence - madidihang (outlier)

Grafik di atas menunjukkan pengaruh relatif dari tiga variabel: “hari_laut”, “alat_tangkap”, dan “gt_kapal” dalam suatu model. Variabel ‘hari_laut’ memiliki pengaruh relatif tertinggi, dengan nilai mencapai lebih dari 40. Ini berarti bahwa variabel “hari_laut” memiliki pengaruh paling signifikan dalam model.


Adapun variabel ‘alat_tangkap’ memiliki pengaruh relatif sekitar 30, yang berarti pengaruhnya lebih rendah dibandingkan dengan “hari_laut” tetapi masih cukup signifikan. Sedangkan variabel ‘gt_kapal’ memiliki pengaruh relatif paling rendah, dengan nilai sedikit lebih dari 20. Ini berarti bahwa variabel “gt_kapal” memiliki pengaruh paling kecil dalam model.

Secara keseluruhan, grafik ini menunjukkan bahwa “hari_laut” adalah variabel paling penting dalam model ini, diikuti oleh “alat_tangkap”, dan “gt_kapal”. Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtMadidihangChloSST_outlier <- gbm(CPUE ~ gt_kapal + hari_laut
+ alat_tangkap,
data = MadidihangCatch_ChloSST_without_outlier,
distribution = "gaussian",
n.trees = 100,
interaction.depth = 3,
shrinkage = 0.01)
```

Hasil model dengan menggunakan outlier ditunjukkan sebagaimana Gambar 3.67 berikut adalah grafik relative influence pada Model BRT.





Gambar 3.67 Grafik relative influence BRT - madidihang (tanpa outlier)


Grafik ini menunjukkan pengaruh relatif dari tiga variabel yang berbeda. Variabel 'alat_tangkap' memiliki pengaruh relatif tertinggi, diikuti oleh variabel 'hari_laut', dan variabel 'gt_kapal' memiliki pengaruh relatif terendah.

Variabel 'alat_tangkap' memiliki pengaruh relatif tertinggi, dengan nilai mencapai lebih dari 60. Ini berarti bahwa variabel ini memiliki pengaruh paling signifikan dalam model. Variabel 'hari_laut' memiliki pengaruh relatif mendekati 30, yang berarti pengaruhnya lebih rendah dibandingkan dengan variabel 'alat_tangkap' tetapi masih cukup signifikan.

Adapun variabel 'gt_kapal' memiliki pengaruh relatif paling rendah, dengan nilai sedikit lebih dari 10. Ini berarti bahwa variabel ini memiliki pengaruh paling kecil dalam model. Secara keseluruhan, grafik ini menunjukkan bahwa variabel 'alat_tangkap' adalah variabel paling penting dalam model ini, diikuti oleh variabel 'hari_laut', dan variabel 'gt_kapal'.

Untuk memahami seberapa penting variabel gt_kapal dalam model dan bagaimana hubungan antara gt_kapal dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel gt_kapal memengaruhi prediksi model, sebagaimana Gambar 3.68 berikut.






Gambar 3.68 Grafik hubungan variabel 'gt_kapal' dan respons model BRT

Grafik di atas menunjukkan hubungan antara variabel 'gt_kapal' dan 'y'. Dari grafik, dapat dilihat bahwa nilai 'y' tetap relatif konstan pada sekitar 24 ketika 'gt_kapal' berkisar dari 0 hingga sekitar 80. Namun, terjadi peningkatan tajam pada nilai 'y' ketika 'gt_kapal' melebihi 80, mencapai hampir 30.

Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi positif antara 'gt_kapal' dan 'y' ketika 'gt_kapal' melebihi 80. Ini menunjukkan bahwa peningkatan dalam 'gt_kapal' di atas 80 berhubungan dengan peningkatan dalam 'y'. Pada grafik hubungan antara variabel 'hari_laut' dan respons model BRT ditunjukkan sebagaimana Gambar 3.69 berikut.






Gambar 3.69 Grafik antara variabel 'hari_laut' dan respons model BRT

Grafik di atas adalah grafik garis sederhana yang menunjukkan hubungan antara variabel 'hari_laut' (sumbu x) dan 'y' (sumbu y). Dari grafik, kita dapat melihat bahwa nilai 'y' mengalami penurunan tajam dari sekitar 35 ke sekitar 20 ketika 'hari_laut' meningkat dari 0 ke sekitar 50. Setelah itu, nilai 'y' tampaknya tetap konstan meskipun 'hari_laut' terus meningkat hingga sekitar 300. Ini menunjukkan bahwa ada hubungan negatif antara 'hari_laut' dan 'y' hingga 'hari_laut' mencapai sekitar 50, setelah itu hubungan tersebut menjadi netral. Adapun grafik hubungan antara variabel 'alat_tangkap' dan respons model BRT ditunjukkan sebagaimana Gambar 3.70 berikut.





Gambar 3.70 Grafik variabel 'alat_tangkap' dan respons model BRT

Dari grafik, kita dapat melihat bahwa beberapa titik yang berbeda pada grafik sumbu Y. Beberapa alat tangkap berada nilai y di atas angka 35. Sumbu 'alat_tangkap' mencantumkan berbagai jenis alat tangkap, seperti "Hand Line Tuna", "Jaring Insang Tuna", dan lainnya.


3.3.9.3 BRT tuna mata besar

Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtTunaMataBesarchlosST_outlier <- gbm(CPUE ~ gt_kapal +
  hari_laut +
  alat_tangkap,
  data = TunaMataBesarCatch_ChlosST,
  distribution = "gaussian",
  n.trees = 100,
  interaction.depth = 3,
  shrinkage = 0.01)
```

Model BRT menunjukkan sejauh mana setiap variabel memengaruhi model dapat ditunjukkan oleh grafik relative influence. Nilai ini dihitung berdasarkan peningkatan rata-rata dalam kesalahan prediksi ketika suatu variabel diganggu atau diacak. Gambar 3.71 berikut adalah grafik BRT relative influence pada penangkapan ikan tuna mata besar.





Gambar 3.71 Grafik relative influence – tuna mata besar (outlier)

Grafik ini menunjukkan hasil dari model BRT, yang menampilkan pengaruh relatif dari tiga variabel: “hari_laut”, “alat_tangkap”, dan “gt_kapal”. Variabel ‘alat_tangkap’ memiliki variabel dengan pengaruh relatif tertinggi, dengan nilai lebih dari 50. Ini berarti bahwa variabel ‘alat_tangkap’ memiliki pengaruh paling signifikan terhadap model BRT.


Adapun ‘gt_kapal’ memiliki variabel dengan pengaruh relatif lebih dari 20, yang berarti pengaruhnya lebih rendah dibandingkan dengan “alat_tangkap” tetapi masih cukup signifikan. Sedangkan ‘hari_laut’, merupakan variabel yang memiliki pengaruh relatif paling rendah, dengan nilai sedikit lebih dari 20. Ini berarti bahwa variabel “hari_laut” memiliki pengaruh paling kecil terhadap model BRT. Secara keseluruhan, grafik ini menunjukkan bahwa “alat_tangkap” adalah variabel paling penting dalam model ini, diikuti oleh “gt_kapal”, dan “hari_laut”.

Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtTunaMataBesarchlosST_outlier <- gbm(CPUE ~ gt_kapal +
  hari_laut + alat_tangkap, data =
    TunaMataBesarCatch_chlosST_without_outlier,
  distribution = "gaussian",
  n.trees = 100,
  interaction.depth = 3,
  shrinkage = 0.01)
```

Grafik relative influence pada Model BRT di atas ditunjukkan sebagaimana Gambar 3.72 berikut.






Gambar 3.72 Grafik relative influence – tuna mata besar (tanpa outlier)

Grafik di atas menunjukkan hasil dari model BRT tanpa menggunakan outlier, yang menampilkan pengaruh relatif dari tiga variabel: 'alat_tangkap', 'gt_kapal', dan 'hari_laut'. Variabel 'alat_tangkap' memiliki pengaruh relatif tertinggi, dengan nilai lebih dari 70. Ini berarti bahwa variabel "alat_tangkap" memiliki pengaruh paling signifikan terhadap model BRT.

Variabel 'gt_kapal' memiliki pengaruh relatif di bawah 20, yang berarti pengaruhnya lebih rendah dibandingkan dengan "alat_tangkap" tetapi masih cukup signifikan. Adapun variabel 'hari_laut' memiliki pengaruh relatif paling rendah, dengan nilai sedikit kurang dari 10. Ini berarti bahwa variabel "hari_laut" memiliki pengaruh paling kecil terhadap model BRT. Secara keseluruhan, grafik ini menunjukkan bahwa "alat_tangkap" adalah variabel paling penting dalam model ini, diikuti oleh variabel "gt_kapal", dan 'hari_laut'.

Untuk memahami seberapa penting variabel gt_kapal dalam model dan bagaimana hubungan antara gt_kapal dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel gt_kapal memengaruhi prediksi model, sebagaimana Gambar 3.73 berikut.






Gambar 3.73 Grafik antara variabel 'gt_kapal' dan respons model BRT

Grafik di atas menunjukkan hubungan antara variabel 'gt_kapal' dan respons model BRT. Dari grafik di atas, kita dapat melihat beberapa pola. Ketika 'gt_kapal' berada di kisaran 0 hingga sekitar 10, respons 'y' menurun secara tajam. Di sekitar 'gt_kapal' 20, terjadi peningkatan yang lebih tajam dalam respons 'y'. Setelah mencapai nilai 'y' sekitar 45, respons 'y' cenderung stabil hingga 'gt_kapal' mencapai sekitar 70. Pada 'gt_kapal' di atas 70, terjadi peningkatan tajam lalu stabil dalam respons 'y'.

Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi positif antara 'gt_kapal' dan respons model BRT, dengan beberapa titik di mana laju perubahan respons 'y' berubah secara signifikan. Ini menunjukkan bahwa 'gt_kapal' memiliki pengaruh yang signifikan terhadap model BRT. Grafik hubungan antara variabel 'hari_laut' dan respons model BRT ditunjukkan sebagaimana Gambar 3.74 berikut.






Gambar 3.74 Grafik hubungan variabel 'hari_laut' dan respons model BRT

Grafik di atas menunjukkan hubungan antara variabel 'hari_laut' dan respons model BRT. Ketika 'hari_laut' berada di kisaran 0, respons 'Y' sangat tinggi, mendekati 10. Terjadi penurunan tajam dalam respons 'Y' seiring dengan peningkatan 'hari_laut', dan mulai stabil di sekitar nilai 30 ketika 'hari_laut' mencapai sekitar 7. Setelah itu, respons 'Y' tampaknya stabil meskipun 'hari_laut' terus meningkat hingga lebih dari 300.

Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi negatif antara 'hari_laut' dan respons model BRT pada awalnya, tetapi setelah mencapai titik tertentu, perubahan dalam 'hari_laut' tampaknya tidak memiliki pengaruh yang signifikan terhadap respons 'Y'. Ini menunjukkan bahwa 'hari_laut' memiliki pengaruh yang signifikan terhadap model BRT pada nilai-nilai rendah, tetapi pengaruh ini berkurang pada nilai-nilai yang lebih tinggi. Adapun grafik hubungan antara variabel 'alat_tangkap' dan respons model BRT ditunjukkan sebagaimana Gambar 3.75 berikut.





Gambar 3.75 Hubungan variabel 'alat_tangkap' dan respons model BRT

Grafik di atas menunjukkan hubungan antara variabel 'alat_tangkap' dan respons model BRT. Dari grafik di atas nampak bahwa variabel 'alat_tangkap' mencakup berbagai jenis alat tangkap atau metode penangkapan ikan. Setiap titik pada grafik mewakili hasil pengukuran atau prediksi model untuk jenis 'alat_tangkap' tertentu, seperti purse seine (pukat cincin) pelagis kecil dan pukat cincin grup pelagis kecil.

Secara keseluruhan, grafik ini menunjukkan bahwa perubahan dalam 'alat_tangkap' tampaknya ada beberapa alat tangkap yang memiliki pengaruh yang signifikan terhadap respons 'Y'. Ini menunjukkan bahwa beberapa 'alat_tangkap' memiliki pengaruh yang signifikan terhadap model BRT.

3.4. Pembahasan

3.4.1 Tantangan penangkapan ikan di area larang WPP 714

Peraturan Menteri Kelautan dan Perikanan Nomor 26/PERMEN-KP/2020, yang menggantikan peraturan sebelumnya (Nomor 4/PERMEN-KP/2015), secara umum implementasinya belum efektif, masih ditemukan banyak pelanggaran pada penangkapan madidihang di WPP 714 selama periode Oktober hingga Desember. Salah satu Upaya yang dibutuhkan adalah implementasi penggunaan teknologi berbasis pemantauan kapal seperti Vessel Monitoring System (VMS) atau Automatic Identification System untuk meningkatkan efektivitas pengelolaan ikan di WPP 714, serta memberikan data spatiotemporal mengurangi pelanggaran selama masa larangan (Sunarmo et



3.4.2 Peralatan tangkap

Penting untuk dicatat bahwa variasi jenis alat tangkap yang digunakan menunjukkan adanya adaptasi dan diversifikasi dalam strategi penangkapan ikan di perairan Indonesia, yang disesuaikan dengan karakteristik spesies target serta kondisi lingkungan laut setempat (Hoshino et al., 2020). Setiap jenis alat tangkap memiliki keunggulan dan tantangan tersendiri dalam upaya menangkap ikan cakalang, madidihang, dan tuna mata besar. Misalnya, alat tangkap seperti *purse seine* efektif dalam menangkap ikan pelagis dalam jumlah besar, sementara alat tangkap seperti *rawai* lebih selektif dan digunakan untuk penangkapan ikan tuna berkualitas tinggi (Bailey et al., 2012). Diversifikasi alat tangkap ini tidak hanya mencerminkan upaya optimalisasi hasil tangkapan, tetapi juga menunjukkan peran penting pengelolaan sumber daya laut yang berkelanjutan, dengan mempertimbangkan aspek efisiensi, kelestarian lingkungan, serta kesejahteraan nelayan lokal (Satria & Sadiyah, 2018).

3.4.2.1 Purse seine (pukat cincin) pelagis kecil

Metode penangkapan ikan dengan Purse Seine (Pukat Cincin) Pelagis Kecil merupakan salah satu teknik yang banyak digunakan dalam industri perikanan komersial (Baihaqi et al., 2021). Teknik ini melibatkan penggunaan kapal yang dilengkapi dengan jaring besar yang dapat membentuk lingkaran untuk menangkap ikan pelagis kecil dalam jumlah besar. Proses dimulai ketika kapal bergerak mengelilingi area perairan yang diketahui kaya akan ikan, kemudian jaring diturunkan ke dalam air menggunakan alat yang disebut trawl door yang menjaga agar jaring tetap terbuka. Setelah jaring mencakup area yang diinginkan, kapal akan bergerak dalam pola melingkar sehingga area yang luas dapat terperangkap oleh jaring tersebut. Ikan yang berada di dalam lingkaran jaring kemudian terperangkap dan diangkat ke atas kapal ketika jaring ditarik kembali (Pratasik et al., 2020).

Purse Seine Pelagis Kecil biasanya digunakan untuk menangkap ikan pelagis kecil seperti sarden, teri, ikan tuna, dan ikan makerel (Sipahutar et al., 2022). Efektivitas metode ini terletak pada kemampuannya untuk menangkap ikan dalam jumlah besar sekaligus, yang pada gilirannya mempercepat proses penangkapan dan meningkatkan produktivitas. Namun, meskipun metode ini memberikan keuntungan ekonomi yang signifikan bagi industri perikanan, terdapat beberapa dampak lingkungan yang perlu diperhatikan. Salah satu masalah utamanya adalah sifat ketidakselektifan alat tangkap ini, yang sering kali menangkap spesies ikan non-target yang kemudian dibuang kembali ke laut dalam keadaan mati atau sekarat (Chaliluddin et al., 2021). Selain itu, penggunaan kapal besar yang mendukung operasi ini juga berkontribusi terhadap emisi karbon dan polusi laut akibat tingginya konsumsi bahan bakar (Najamuddin et al., 2021).



u harpoon, adalah salah satu alat tangkap tradisional yang oleh masyarakat pesisir di wilayah Papua. Alat ini dirancang tangkap ikan-ikan berukuran besar yang hidup di perairan laut

(Smith, 2017). Mekanisme kerja huate cukup sederhana namun memerlukan ketepatan dan keterampilan tinggi, yaitu dengan melontarkan tombak dari atas perahu ke arah ikan yang menjadi target. Tombak tersebut dilengkapi dengan ujung tajam dan terhubung dengan tali panjang, sehingga ikan yang tertangkap tidak dapat melarikan diri dengan mudah (Romeo et al., 2015).

Proses penangkapan dimulai dengan mengamati sinyal-sinyal keberadaan ikan di permukaan laut, seperti munculnya sirip atau ekor. Ketika tanda-tanda tersebut terdeteksi, nelayan dengan cepat melontarkan tombak ke arah ikan yang menjadi sasaran. Ketepatan dalam melontarkan tombak menjadi kunci keberhasilan dalam penangkapan, karena tombak harus mengenai bagian vital ikan agar tangkapan berhasil. Setelah tombak menancap pada ikan, tali yang terhubung ditarik dengan hati-hati agar ikan tidak melepaskan diri (Battaglia et al., 2017).

Keunggulan huate terletak pada sifat selektifnya, di mana hanya ikan besar yang menjadi target, sehingga mengurangi risiko penangkapan ikan-ikan kecil atau spesies non-target. Alat ini efektif dalam menangkap spesies besar seperti hiu, pari, dan marlin. Namun, meskipun efektif, penggunaan huate tanpa regulasi yang memadai dapat berdampak negatif terhadap populasi ikan besar (Romeo et al., 2010). Jika alat ini digunakan secara berlebihan, pemulihan populasi ikan-ikan besar dapat terhambat, yang pada akhirnya mengganggu keseimbangan ekosistem perairan. Untuk itu, pengaturan dan pengawasan yang ketat diperlukan agar penggunaan huate dapat dilakukan secara berkelanjutan.

3.4.2.3 Pukat cincin pelagis kecil dengan satu kapal

Metode penangkapan ikan dengan menggunakan pukat cincin pelagis kecil merupakan salah satu teknik utama dalam industri perikanan komersial yang memanfaatkan kapal berukuran besar untuk mengoptimalkan hasil tangkapan (Chaliluddin et al., 2021). Pukat cincin sendiri terdiri dari jaring yang diatur sedemikian rupa sehingga dapat membentuk lingkaran besar di dalam air, yang memungkinkan penangkapan ikan dalam jumlah besar secara efisien. Dalam penerapannya, kapal beroperasi di perairan yang kaya akan ikan dan bergerak melingkar dengan jaring pukat yang diatur agar tetap terbuka menggunakan alat trawl door (González-García et al., 2015). Proses ini memungkinkan jaring untuk mencakup area yang luas dan menangkap berbagai jenis ikan yang berada di dalam lingkaran tersebut.

Setelah jaring pukat sepenuhnya menutup lingkaran di sekitar ikan, nelayan menarik pukat kembali ke kapal sehingga ikan yang terperangkap dapat diangkat. Efektivitas metode ini terletak pada kemampuannya untuk menangkap sejumlah besar ikan sekaligus, menjadikannya pilihan yang populer di kalangan industri perikanan yang mengutamakan produksi dalam skala besar (Okemwa et al., 2017). Namun, seperti banyak alat tangkap massal lainnya, pukat cincin pelagis kecil tidak luput dari berbagai kritik. Selain tingginya konsumsi bahan bakar dan pencemaran lingkungan laut, alat ini juga memiliki tingkat selektivitas rendah, yang berarti spesies non-target termasuk yang dilindungi turut tertangkap, menimbulkan ancaman terhadap keberlanjutan



ekosistem laut (Dagorn et al., 2013).

3.4.2.4 Pancing ulur

Pancing ulur merupakan salah satu alat tangkap ikan tradisional yang masih populer dan sering digunakan oleh masyarakat nelayan di berbagai wilayah. Alat ini memiliki desain yang sederhana, terdiri dari sebuah tongkat atau batang bambu panjang yang dilengkapi dengan benang pancing, mata kail, dan umpan (Noija et al., 2014). Prinsip kerja pancing ulur terletak pada teknik pelemparan umpan ke perairan, kemudian menunggu ikan yang tertarik untuk memakan umpan tersebut dan terjebak dalam kail. Keberhasilan penangkapan ikan menggunakan pancing ulur sangat bergantung pada kecermatan dalam memilih umpan yang sesuai dengan jenis ikan yang ditargetkan (Yapanto & Nursinar, 2020). Umpan yang digunakan bisa berupa serangga, cacing, atau potongan ikan kecil, yang kemudian diikatkan pada mata kail yang terhubung dengan benang pancing.

Dalam praktiknya, nelayan akan melemparkan pancing ulur ke air dan menarik benang secara perlahan agar umpan terlihat lebih hidup dan menarik perhatian ikan. Ketika ikan memakan umpan dan terjebak dalam kail, getaran pada benang pancing menjadi sinyal bagi nelayan untuk segera menarik pancing (Poltak et al., 2021). Pada tahap ini, keterampilan nelayan sangat diperlukan untuk mengarahkan tongkat ulur berlawanan dengan gerakan ikan agar kail terkunci dengan baik dan ikan tidak lepas. Proses penarikan ikan kemudian dilakukan dengan penuh kehati-hatian, mengingat kekuatan dan pergerakan ikan yang berusaha melepaskan diri dapat menyebabkan benang putus atau ikan terlepas.

3.4.2.5 Pancing tonda

Alat tangkap pancing tonda, yang juga dikenal sebagai pancing jigging, merupakan salah satu teknik penangkapan ikan yang lazim digunakan di perairan dalam, terutama oleh nelayan profesional dan pemancing olahraga (Annida et al., 2021). Alat ini terdiri dari reel atau katrol yang dipasang benang pancing dan mata kail yang ditempatkan di bagian bawah. Metode ini banyak dipilih karena mampu menangkap ikan-ikan predator besar yang sering menghuni perairan dalam. Penggunaan pancing tonda tidak hanya mengandalkan alat, tetapi juga membutuhkan keterampilan khusus dalam mengendalikan joran, reel, dan mata kail secara simultan (Hidayati et al., 2019). Pemancing harus memahami teknik yang tepat untuk menarik perhatian ikan dan menangkapnya dengan efisien.

Keistimewaan utama pancing tonda terletak pada kemampuannya meniru gerakan ikan mangsa melalui joran. Dengan teknik jigging yang melibatkan gerakan cepat dan berulang-ulang, pemancing dapat menciptakan ilusi gerakan mangsa yang menarik perhatian ikan predator. Ketika ikan menggigit kail, getaran pada joran menjadi sinyal bagi pemancing untuk segera menggulung reel dan menarik dengan kuat. Pancing tonda sangat efektif untuk menangkap ikan predator besar seperti tenggiri, marlin, dan hiu, yang dikenal sebagai ikan berbahaya dalam perlawanan (Aphiliani et al., 2021).



3.4.2.6 Pukat cincin satu kapal

Pukat cincin satu kapal merupakan salah satu teknik penangkapan ikan yang jarang digunakan dan umumnya diterapkan oleh nelayan tradisional yang hanya mengoperasikan satu kapal (Kurniawati et al., 2019). Teknik ini menggunakan jaring yang dilengkapi dengan cincin besar yang ukurannya dapat disesuaikan dengan kebutuhan penangkapan. Proses penangkapan dimulai dengan melemparkan jaring pukat ke laut, diikuti oleh pergerakan kapal dalam pola melingkar. Kapal kemudian menarik pukat secara perlahan dengan bantuan mesin, mengumpulkan ikan ke dalam bagian tengah jaring (Pratasik et al., 2020). Setelah lingkaran jaring tertutup sepenuhnya, ikan yang terperangkap di dalamnya diangkut ke atas kapal untuk dibawa pulang.

Kelebihan utama dari pukat cincin satu kapal adalah kemampuannya untuk menangkap ikan dalam jumlah besar dalam waktu yang relatif singkat. Teknik ini sangat efektif dalam menangkap ikan pelagis kecil yang hidup di permukaan air, seperti ikan sarden, teri, dan cumi-cumi (Firdaus et al., 2020). Efektivitas metode ini dalam penangkapan massal menjadikannya populer di kalangan nelayan yang mengutamakan produktivitas tinggi. Namun, metode ini juga memiliki kelemahan signifikan terkait dampaknya terhadap ekosistem. Pukat cincin cenderung kurang selektif, yang berarti dapat menangkap spesies non-target, termasuk ikan yang masih berukuran kecil dan bahkan spesies yang dilindungi. Selain itu, penggunaan mesin berat dalam menarik jaring dapat merusak habitat laut, terutama terumbu karang yang menjadi tempat tinggal berbagai spesies laut (Almeida et al., 2014).

3.4.2.7 Pancing berjoran

Pancing berjoran merupakan salah satu alat pancing yang banyak digunakan oleh pemancing profesional karena kemampuannya yang unggul dalam berbagai situasi perairan. Alat ini terdiri dari joran atau batang panjang yang terbuat dari material ringan namun kuat seperti karbon atau fiberglass, yang memberikan kombinasi optimal antara fleksibilitas dan daya tahan (Spolek & Jefferies, 1982). Keunggulan utama pancing berjoran terletak pada kemampuannya untuk melempar umpan dengan jarak yang lebih jauh berkat panjang joran yang cukup memadai. Selain itu, sensitivitas dan kekuatan joran memungkinkan pemancing untuk merespons dengan cepat saat ikan menggigit umpan, sehingga memberikan kendali yang lebih baik dalam menghadapi perlawanan ikan besar (Cooke et al., 2019).

Alat pancing berjoran juga dilengkapi dengan reel atau gulungan benang yang dipasang pada joran, yang berfungsi untuk mengatur benang pancing dan mengendalikan gerakan ikan selama proses penangkapan (Inoue & Kurokawa, 2018). Reel ini memudahkan pemancing dalam mengatur jarak lemparan dan mengontrol kecepatan saat menarik ikan ke permukaan, yang sangat penting dalam mempertahankan ketegangan benang dan mencegah benang putus.



ina

Tuna adalah alat tangkap ikan yang dirancang khusus untuk

menangkap ikan tuna, dengan perbedaan mendasar dibandingkan alat pancing konvensional lainnya karena tidak melibatkan penggunaan joran atau reel. Sebagai gantinya, Hand Line Tuna menggunakan tali pancing yang diikat langsung pada alat pengendali seperti batang besi atau pegangan kayu yang kokoh (Siahainenia et al., 2021). Alat ini banyak digunakan dalam perikanan tradisional maupun komersial, terutama di daerah yang memiliki populasi ikan tuna yang melimpah.

Salah satu keunggulan utama dari Hand Line Tuna adalah kekuatan dan daya tahannya yang luar biasa. Alat ini dirancang untuk menghadapi tarikan ikan tuna yang kuat dan agresif, yang sering kali memerlukan peralatan yang mampu menahan tekanan tinggi. Dengan tali pancing yang kuat dan tahan lama, Hand Line Tuna memungkinkan pemancing untuk mengatasi perlawanan ikan tuna dengan lebih efektif dan aman. Selain itu, karena pemancing langsung memegang tali pancing tanpa perantara reel, mereka dapat merasakan setiap gerakan dan tarikan ikan dengan lebih akurat, sehingga dapat menyesuaikan strategi penarikan secara real-time dan menjaga keseimbangan dalam permainan ikan (Laitupa et al., 2023).

3.4.2.9 Pukat cincin grup pelagis kecil

Pukat cincin grup pelagis kecil adalah alat tangkap ikan yang dirancang khusus untuk menangkap ikan-ikan pelagis kecil yang hidup berkelompok di perairan laut. Alat ini terdiri dari jaring yang membentuk cincin besar yang ditempatkan di permukaan air, di mana cincin tersebut berfungsi untuk menjebak ikan yang berenang di sekitarnya (Chaliluddin et al., 2021). Pukat cincin ini sering digunakan oleh nelayan untuk menangkap spesies ikan yang hidup berkelompok, seperti ikan teri, ikan layur, dan ikan tenggiri. Metode ini menjadi pilihan utama dalam menangkap ikan pelagis kecil karena tingkat efisiensinya yang tinggi (Sipahutar et al., 2022).

3.4.2.10 Pukat cincin pelagis besar dengan satu kapal

Pukat cincin pelagis besar dengan satu kapal merupakan salah satu alat tangkap ikan yang dirancang untuk menangkap ikan-ikan pelagis besar yang hidup di perairan lepas. Alat ini terdiri dari jaring berbentuk cincin yang terbuat dari bahan yang kuat, dilengkapi dengan tali panjang untuk memudahkan pengoperasian (Alfianto et al., 2023). Cincin tersebut diposisikan di permukaan air, sementara bagian bawahnya terhubung dengan kapal yang berfungsi sebagai pusat pengendalian dalam proses penangkapan ikan. Dalam pengoperasiannya, nelayan menggunakan kapal sebagai titik fokus dan mengelilingi area perairan yang telah ditentukan, menarik jaring hingga membentuk lingkaran yang menjebak ikan-ikan pelagis besar di dalamnya (Laso et al., 2018).



ang lingk

ang lingk merupakan salah satu alat tangkap ikan yang umum digunakan di perairan dangkal. Alat ini terdiri dari jaring berbentuk g terbuat dari anyaman tali atau benang dengan ukuran mata

jaring yang cukup rapat (Chumchuen & Krueajun, 2021). Jaring ini dirancang untuk menangkap ikan-ikan yang berenang di dekat permukaan air, termasuk ikan-ikan kecil serta jenis ikan yang hidup di sekitar terumbu karang. Penggunaannya terutama difokuskan pada perairan yang memiliki konsentrasi ikan tinggi, sehingga efektif dalam memaksimalkan hasil tangkapan nelayan (Giraldes et al., 2015).

3.4.2.12 Huhate mekanis

Huhate mekanis merupakan salah satu alat tangkap ikan yang bekerja dengan memanfaatkan prinsip mekanisme otomatis untuk menangkap ikan secara efisien. Alat ini umumnya digunakan di perairan dangkal seperti sungai, danau, atau rawa-rawa (Stevens, 2020). Secara bentuk, huhate mekanis menyerupai peti yang terbuat dari bahan yang kokoh, seperti besi atau kayu. Pada bagian depan peti, terdapat saluran yang dirancang untuk memudahkan ikan masuk, namun mencegah mereka keluar kembali. Struktur dan mekanisme peti tersebut secara otomatis menjebak ikan di dalamnya hingga nelayan siap mengumpulkan hasil tangkapannya (Kopp et al., 2020).

3.4.2.13 Pengangkut

Alat tangkap pengangkut merupakan salah satu perangkat yang digunakan dalam industri perikanan untuk memindahkan ikan dari perairan ke kapal atau tempat penampungan. Alat ini biasanya terdiri dari tali atau jaring berukuran besar yang dioperasikan dengan bantuan peralatan tambat yang dipasang di kapal atau perahu (Yu et al., 2019). Alat tangkap pengangkut dirancang untuk mengangkut ikan dalam jumlah besar secara efisien, sehingga cocok digunakan dalam operasi penangkapan ikan berskala besar. Dalam penggunaannya, alat ini mampu menangkap ikan dengan cepat dan efisien, yang menjadikannya pilihan utama bagi banyak nelayan (Sun et al., 2019).

3.4.2.14 Pukat cincin pelagis kecil dengan dua kapal

Pukat cincin pelagis kecil merupakan salah satu alat tangkap yang dirancang khusus untuk menangkap ikan-ikan pelagis kecil di perairan laut. Alat ini umumnya dioperasikan oleh nelayan dengan menggunakan dua kapal yang bekerja secara bersamaan (Lucchetti et al., 2018). Pukat ini berbentuk cincin dengan jaring di bagian tengahnya, yang berfungsi untuk menjebak ikan-ikan yang berada di bawah permukaan laut. Prinsip kerja alat ini didasarkan pada pengoperasian dua kapal yang bergerak beriringan, menciptakan sirkulasi air yang mendorong ikan masuk ke dalam jaring melalui gerakan melingkar (González-García et al., 2015).

3.4.2.15 Bagan perahu



Bagan perahu merupakan salah satu alat tangkap ikan yang sering digunakan dalam aktivitas perikanan di perairan dangkal seperti sungai, danau, atau rawa-rawa. Alat tangkap ini umumnya terdiri dari jaring yang diikat pada kapal atau perahu dengan tali yang membentuk struktur seperti tas besar (Marni et al., 2019). Bagan perahu memiliki prinsip kerja yang serupa dengan pukat harimau,

di mana ikan-ikan dijerat dan ditangkap di dalam jaring melalui pergerakan alat tangkap ini di perairan. Alat ini biasanya dioperasikan dengan bantuan perahu, baik menggunakan dayung maupun motor, untuk mengitari area yang diperkirakan menjadi tempat berkumpulnya ikan-ikan.

Cara kerja bagan perahu dimulai dengan melemparkan jaring ke dalam air, kemudian menariknya kembali menggunakan perahu setelah ikan-ikan bergerak masuk ke dalam jaring. Keberhasilan dalam menangkap ikan dengan alat ini sangat bergantung pada kemampuan nelayan dalam mengendalikan pergerakan perahu (Hapsari et al., 2018). Penguasaan aspek-aspek seperti arah pergerakan ikan, kondisi aliran air, serta waktu yang tepat untuk melakukan penarikan jaring menjadi kunci penting dalam optimalisasi hasil tangkapan.

3.4.2.16 Rawai tuna

Rawai tuna merupakan salah satu alat tangkap yang sering digunakan dalam penangkapan ikan tuna di perairan lepas. Alat ini biasanya terdiri dari tali pancing yang tebal dan kuat, dengan mata kail yang diikat pada rangkaian tali panjang, bukan jaring seperti pada alat tangkap lainnya. Panjang rawai tuna dapat mencapai puluhan hingga ratusan meter, tergantung skala operasi penangkapan (Jaiteh et al., 2021). Alat ini digunakan dengan cara melepaskan tali pancing ke laut sehingga melayang secara horizontal di dekat permukaan air. Dalam praktiknya, rawai tuna sering digunakan secara berkelompok, di mana beberapa rawai dihubungkan satu sama lain untuk menutupi area penangkapan yang lebih luas (Lee et al., 2022).

3.4.2.17 Jaring insang lainnya

Jaring insang merupakan salah satu alat tangkap yang sering digunakan dalam aktivitas penangkapan ikan di berbagai perairan, baik laut maupun perairan dangkal. Alat ini memiliki desain yang berbeda dengan jaring insang oseanik yang biasa digunakan untuk menangkap ikan tuna di perairan lepas. Jaring insang lainnya, yang lebih banyak digunakan di perairan dangkal seperti sungai, danau, dan tambak, biasanya ditujukan untuk menangkap ikan-ikan kecil yang menjadi sumber penghidupan bagi nelayan tradisional. Alat tangkap ini terdiri dari jaring yang ditenun dengan lubang-lubang kecil yang dipasang di lokasi strategis di perairan, sehingga ikan yang terdorong oleh arus air dapat dengan mudah terperangkap di dalamnya (Northridge et al., 2017).

Penggunaan jaring insang menjadi pilihan populer di kalangan nelayan tradisional karena kesederhanaan dan efektivitasnya. Jaring ini mampu menangkap ikan secara massal dalam satu kali operasi, menjadikannya alat yang efisien dan hemat biaya. Ikan-ikan yang sering ditargetkan oleh alat ini meliputi jenis ikan air tawar seperti lele, mujair, dan nila (Devi et al., 2017). Selain itu, jaring insang juga fleksibel dalam menangkap berbagai ukuran ikan, mulai dari yang kecil

esar, sesuai dengan kebutuhan nelayan.

demikian, penggunaan jaring insang juga menimbulkan n yang signifikan bagi ekosistem perairan. Alat ini memiliki yang rendah, yang berarti spesies non-target, termasuk ikan



yang masih kecil dan spesies yang dilindungi, sering kali turut terperangkap. Dampak ini berpotensi menyebabkan penurunan populasi ikan secara drastis, yang pada akhirnya dapat mengganggu keseimbangan ekosistem dan keberlanjutan sumber daya perikanan (Rouxel & Montevecchi, 2018). Penggunaan jaring insang tanpa regulasi yang memadai juga dapat berkontribusi terhadap overfishing dan merusak habitat perairan tempat jaring dipasang.

Untuk mengatasi dampak negatif tersebut, pengelolaan penggunaan jaring insang harus dilakukan dengan pendekatan yang lebih bertanggung jawab dan berkelanjutan. Pemerintah dan pihak terkait perlu menerapkan regulasi yang ketat, seperti pembatasan ukuran mata jaring untuk memungkinkan ikan kecil meloloskan diri, serta menetapkan area dan musim tangkap yang sesuai untuk menjaga populasi ikan. Selain itu, nelayan perlu diberikan edukasi tentang pentingnya praktik perikanan yang selektif dan ramah lingkungan. Pengembangan teknologi alternatif yang lebih selektif juga perlu dipromosikan guna menciptakan keseimbangan antara kebutuhan ekonomi nelayan dan kelestarian ekosistem perairan (Jaureguizar et al., 2015).

3.4.2.18 Rawai hanyut

Rawai hanyut merupakan salah satu alat tangkap ikan yang umum digunakan di perairan laut, terutama di kawasan pesisir. Alat ini terdiri dari tali panjang yang dilengkapi dengan sejumlah mata kail, dan di ujungnya diikatkan pelampung untuk menjaga agar alat tetap terapung di permukaan air. Rawai hanyut biasanya ditempatkan di dekat terumbu karang atau di area yang dikenal memiliki konsentrasi ikan tinggi. Metode ini memanfaatkan pergerakan arus laut, di mana ikan yang melintas akan tertarik pada umpan yang dipasang di mata kail, sehingga terperangkap ketika melewati jalur rawai (Sobolenko & Manitsyn, 2022). Alat ini banyak digunakan oleh nelayan komersial karena kemampuannya untuk menangkap ikan dalam jumlah besar, terutama ikan target seperti tenggiri dan tuna (Michael et al., 2015).

3.4.2.19 Jaring insang oseanik

Jaring insang oseanik merupakan salah satu alat tangkap ikan yang digunakan di perairan laut dalam, khususnya untuk menangkap ikan-ikan yang hidup di lapisan tengah hingga dasar laut, seperti tuna. Alat ini terdiri dari jaring dengan ukuran mesh yang halus, yang dirancang sedemikian rupa agar ikan yang lebih kecil dapat lolos tanpa terperangkap, sementara ikan yang lebih besar dan menjadi target tangkapan akan tertahan di dalamnya (Anderson et al., 2020). Jaring insang oseanik sering kali digunakan dalam operasi perikanan skala besar, di mana selektivitas alat tangkap menjadi prioritas untuk menjaga keberlanjutan sumber daya ikan.

Keunggulan utama jaring insang oseanik terletak pada selektivitasnya dibandingkan dengan alat tangkap lainnya. Dengan menggunakan mesh yang lebih halus, jaring ini memungkinkan ikan yang lebih kecil atau spesies non-target untuk melewati jaring, sehingga mengurangi dampak negatif terhadap populasi ikan yang belum mencapai ukuran target atau spesies yang dilindungi (Bielli et al., 2020). Selektivitas ini



berkontribusi pada pelestarian stok ikan di perairan dan mendukung praktik perikanan yang lebih berkelanjutan.

Namun, di balik kelebihanannya, penggunaan jaring insang oseanik juga memiliki beberapa keterbatasan. Efisiensi penangkapan ikan dengan alat ini umumnya lebih rendah dibandingkan dengan metode tangkap lain seperti rawai hanyut, karena ikan harus secara aktif melewati jaring untuk tertangkap (Goldsworthy et al., 2022). Proses pemasangan dan pengambilan jaring juga memerlukan keterampilan khusus dan waktu yang lebih lama, serta membutuhkan kru kapal yang terlatih untuk memastikan operasional yang optimal.

Secara umum, 19 jenis alat tangkap di atas dapat diklasifikasikan berdasarkan status dukungannya terhadap implementasi perikanan berkelanjutan. Klasifikasi tersebut ditunjukkan pada tabel 3.14 berikut.

Tabel 3.4 Tabel kesesuaian alat tangkap dengan prinsip perikanan berkelanjutan

No.	Nama Alat Tangkap	Status	Keterangan
1	Huhate (Pole and Line)	Tinggi	Selektif, rendah tangkapan sampingan, dan ramah lingkungan (Petetta et al., 2021).
2	Hand Line Tuna	Tinggi	Alat selektif dengan dampak minimal terhadap habitat laut (Thomas, 2020).
3	Pancing Berjoran	Tinggi	Menangkap ikan target dengan risiko rendah terhadap lingkungan (Petetta et al., 2021).
4	Pukat Cincin Pelagis Kecil (1 Kapal)	Sedang	Selektif, tetapi berisiko menangkap ikan kecil jika tidak diawasi (Le Manach et al., 2020).
5	Pancing Tonda	Sedang	Selektif, tetapi risiko tangkapan sampingan memerlukan pengelolaan (Hilborn et al., 2023).
6	Pukat Cincin Pelagis Kecil (2 Kapal)	Rendah	Tidak selektif, berpotensi merusak habitat jika tidak diawasi (Mandal, 2024).
7	Jaring Insang Lingkar	Sedang	Dampak rendah pada habitat, tetapi kurang selektif (Petetta et al., 2021).
8	Rawai Tuna	Tinggi	Selektif, menghasilkan sedikit tangkapan sampingan (Petetta et al., 2021).
9	Jaring Insang	Rendah	Tidak selektif, berisiko menangkap spesies tidak diinginkan (Richardson et al., 2019).
10	Jaring Insang	Rendah	Risiko tinggi terhadap tangkapan sampingan dan habitat (Hilborn et al., 2021).



	Kapal)		al., 2023).
11	Jaring Insang Lainnya	Rendah	Tidak selektif dan memerlukan pengawasan ketat untuk keberlanjutan (Mandal, 2024).
12	Rawai Hanyut	Sedang	Relatif selektif tetapi memerlukan pengelolaan intensif (Le Manach et al., 2020).
13	Bagan Perahu	Sedang	Cukup selektif tetapi berisiko menangkap ikan muda (Brewon et al., 2022).
14	Huhate Mekanis	Tinggi	Efisien dan tetap selektif terhadap spesies target (Petetta et al., 2021).
15	Pengangkut	Sedang	Mendukung alat tangkap utama, dampak bergantung pada alat tangkap utama (Hilborn et al., 2023).
16	Pukat Cincin Grup Pelagis Kecil	Sedang	Selektif terhadap spesies target, memerlukan pengelolaan (Mandal, 2024).
17	Jaring Insang Lingkar	Sedang	Memberikan dampak habitat rendah tetapi selektivitas terbatas (Petetta et al., 2021).
18	Pukat Cincin Satu Kapal	Sedang	Lebih kecil dampaknya dibanding pukat besar, namun tetap memerlukan pengelolaan ketat (Hilborn et al., 2023).
19	Jaring Insang Oseanik	Rendah	Tidak selektif dan sering menangkap spesies yang tidak diinginkan (Richardson et al., 2019).

3.4.3 Sebaran penangkapan ikan di WPP 714 (data logbook)

3.4.3.1 Penangkapan ikan cakalang

Penangkapan ikan cakalang di Wilayah Pengelolaan Perikanan (WPP) 714, yang mencakup Laut Maluku hingga Teluk Tomini, merupakan salah satu aktivitas perikanan penting di Indonesia. Aktivitas ini dipengaruhi oleh berbagai faktor, termasuk kebijakan pemerintah dan penggunaan alat tangkap. Moratorium yang diberlakukan oleh Kementerian Kelautan dan Perikanan berdampak signifikan terhadap penurunan tingkat eksploitasi ikan cakalang, dari 0.63 sebelum moratorium menjadi 0.54 setelah moratorium (Asia et al., 2019). Selain itu, jenis alat tangkap seperti pukat cincin dan pancing ulur juga memengaruhi hasil tangkapan, dengan cakalang sebagai spesies utama yang dieksploitasi (Widodo et al., 2015).



n data logbook, distribusi spasial penangkapan ikan cakalang menunjukkan pola yang relatif konsisten sepanjang tahun. Perung terkonsentrasi di bagian utara dan barat laut wilayah ini, sebagai hotspot utama penangkapan (Siregar et al., 2023).

Konsistensi ini disebabkan oleh faktor ekologis seperti ketersediaan makanan, kondisi lingkungan yang optimal, dan habitat yang mendukung (Wujdi et al., 2017). Variasi musiman juga terlihat dalam aktivitas penangkapan. Pada Januari hingga April, penangkapan terkonsentrasi di area utara dengan ekspansi bertahap ke arah tengah dan timur (Ma'mun et al., 2019). Sementara itu, dari Mei hingga Agustus, terjadi penurunan densitas penangkapan yang kemungkinan dipengaruhi oleh perubahan lingkungan seperti suhu air atau migrasi ikan. Namun, aktivitas penangkapan kembali meningkat dari September hingga Desember, menunjukkan adanya musim puncak penangkapan pada akhir tahun (Suman et al., 2018).

Secara keseluruhan, data menunjukkan bahwa WPP 714, khususnya bagian utara, merupakan area kritis dalam perikanan cakalang. Keberlanjutan pengelolaan stok ikan di wilayah ini menjadi sangat penting untuk menghindari overfishing. Perlindungan terhadap habitat di area hotspot dan pengaturan musim penangkapan perlu diperhatikan guna menjaga ketersediaan stok ikan di masa depan (Rahmadi, 2018). Pemahaman terhadap pola distribusi dan variasi musiman ini memberikan landasan penting bagi perumusan kebijakan perikanan yang lebih efektif dan berkelanjutan.

3.4.3.2 Penangkapan ikan madidihiang

Penangkapan ikan madidihiang di Wilayah Pengelolaan Perikanan Republik Indonesia (WPP-RI) 714, yang mencakup Laut Banda, merupakan aktivitas yang signifikan bagi sektor perikanan nasional. Namun, studi menunjukkan adanya tren penurunan produksi madidihiang akibat tingginya tingkat penangkapan yang menyebabkan status pemanfaatan ikan ini masuk dalam kategori *overfishing*. Ukuran tangkapan pertama (L_c) madidihiang di Laut Banda dilaporkan mencapai 125,2 cm, sementara rasio kematian akibat penangkapan terhadap kematian alami menunjukkan tingkat yang membahayakan kelestarian sumber daya ini. Kondisi tersebut menegaskan perlunya regulasi mengenai ukuran minimum tangkapan untuk menjaga populasi madidihiang di wilayah ini (Haruna et al., 2019).

Dinamika populasi madidihiang di WPP 714 juga menunjukkan bahwa tingkat eksploitasi telah melampaui batas optimal. Studi mencatat bahwa puncak rekrutmen terjadi pada bulan Juni dengan nilai 34,83%, menandakan periode rekrutmen yang intens. Namun, tingkat eksploitasi yang tinggi ($E = 0,84$ per tahun) mengindikasikan bahwa sumber daya ini berada dalam kondisi rentan terhadap penurunan populasi. Oleh karena itu, pembatasan upaya penangkapan dan pemantauan yang konsisten diperlukan untuk menjaga keberlanjutan stok madidihiang di wilayah ini (Tumulyadi et al., 2023).

Distribusi lokasi penangkapan madidihiang di WPP 714 dari Januari hingga Oktober menunjukkan variasi pola dan konsentrasi penangkapan. Pada Januari, penangkapan tersebar merata dengan konsentrasi tinggi di bagian barat laut dan barat daya (Haruna et al., 2019). Memasuki Februari dan Maret, distribusi semakin a dan barat laut, dengan peningkatan aktivitas di bagian tengah (Tumulyadi et al., 2023). Pada April dan Mei, terjadi pengurangan titik gian selatan, sementara bagian barat laut dan tengah tetap a aktivitas (Haruna et al., 2019; Tumulyadi et al., 2023).



Selama bulan Juni hingga Agustus, titik penangkapan semakin terkonsentrasi di barat laut, dengan sedikit aktivitas di bagian tengah dan timur. Pada September dan Oktober, konsentrasi penangkapan kembali tinggi di bagian barat laut dan utara, dengan beberapa titik di bagian tengah dan timur, sementara bagian selatan mengalami penurunan aktivitas (Haruna et al., 2019; Tumulyadi et al., 2023).

Secara keseluruhan, pola distribusi penangkapan ikan madidihang di WPP 714 menunjukkan konsentrasi yang lebih padat di bagian barat laut dan utara, dengan fluktuasi jumlah titik penangkapan setiap bulan. Sementara itu, bagian tengah dan selatan cenderung mengalami penurunan aktivitas penangkapan dari awal hingga akhir tahun (Haruna et al., 2019; Tumulyadi et al., 2023). Temuan ini menegaskan perlunya pengelolaan perikanan yang lebih ketat, termasuk pengaturan musim penangkapan dan perlindungan habitat kritis, untuk memastikan keberlanjutan stok madidihang di WPP 714.

3.4.3.3 Penangkapan ikan tuna mata besar

Penangkapan ikan tuna mata besar di Wilayah Pengelolaan Perikanan Republik Indonesia (WPP-RI) 714, yang mencakup Laut Banda, merupakan aktivitas penting dalam sektor perikanan pelagis. Ikan ini bernilai tinggi, baik untuk konsumsi domestik maupun ekspor. Populasinya di Samudra Hindia, termasuk WPP 714, terbagi menjadi dua subpopulasi utama: di barat Sumatra, yang didominasi ikan belum matang gonad, dan di selatan Jawa serta Nusa Tenggara, yang menjadi area pemijahan signifikan (Suman et al., 2015).

Tuna mata besar umumnya ditemukan di kedalaman 155–222 meter, dengan suhu sub-permukaan 16°C–18°C dan konsentrasi Chlo-a rendah. Faktor oseanografi seperti suhu, salinitas, dan konsentrasi Chlo-a memengaruhi distribusi ikan ini, terutama di Samudra Hindia timur, yang berpotensi menjadi zona penangkapan optimal (Fachruddin-Syah et al., 2020).

Distribusi penangkapan di WPP 714 bervariasi sepanjang tahun. Januari menunjukkan distribusi merata dengan konsentrasi di bagian tengah, barat, dan timur (Haruna et al., 2019; Tumulyadi et al., 2023). Pada Februari hingga April, aktivitas lebih terfokus di bagian tengah dan selatan, sementara utara menunjukkan sedikit aktivitas (Haruna et al., 2019). Mei hingga Juli menunjukkan penurunan titik penangkapan, dengan konsentrasi utama di bagian tengah dan selatan (Tumulyadi et al., 2023). Agustus hingga Oktober memperlihatkan konsentrasi di bagian selatan dan tengah, sementara bagian utara dan barat mengalami penurunan aktivitas (Haruna et al., 2019; Tumulyadi et al., 2023).

Secara keseluruhan, pola penangkapan tuna mata besar di WPP 714 menunjukkan konsentrasi dominan di bagian tengah dan selatan, terutama pada pertengahan hingga akhir tahun. Aktivitas di bagian utara dan timur bervariasi dengan intensitas lebih rendah, menandakan perlunya pengelolaan perikanan berkelanjutan untuk menjaga kelestarian sumber daya ini (Haruna et al., 2019; Tumulyadi et al., 2023).



3.4.4 Catch Per Unit Effort (CPUE)

Dalam studi ini, CPUE menunjukkan variasi antar spesies. Penangkapan cakalang menunjukkan efisiensi penangkapan yang lebih rendah dibandingkan dengan madidihang dan tuna mata besar. Madidihang memiliki CPUE tertinggi, yang menunjukkan kemungkinan kelimpahan stok atau efektivitas metode penangkapan yang digunakan. Tuna mata besar menunjukkan efisiensi yang berada di antara cakalang dan madidihang.

Perbedaan ini mencerminkan variasi dalam kelimpahan stok ikan, teknik penangkapan, serta faktor lingkungan seperti kondisi oseanografi yang memengaruhi distribusi ikan. Hasil ini menegaskan pentingnya CPUE sebagai alat untuk memahami dinamika stok ikan dan merancang strategi pengelolaan yang efektif (Thierry et al., 2021).

3.4.5 Model GAM pada faktor-faktor teknis penangkapan ikan di WPP 714

Faktor teknis penangkapan ikan meliputi alat tangkap dan tenaga kerja, yang berperan penting dalam menentukan efisiensi dan hasil tangkapan (Asche et al., 2020; Selgrath et al., 2018). Alat tangkap seperti jaring, pancing, dan perahu harus disesuaikan dengan jenis ikan dan lokasi penangkapan untuk hasil yang optimal (Susiloningtyas et al., 2023; Da-qun, 2003). Sementara itu, keahlian dan jumlah tenaga kerja memengaruhi produktivitas, dengan tim yang lebih besar cenderung lebih efisien (Cinner et al., 2009; Erliani et al., 2020).

Selain alat tangkap dan tenaga kerja, faktor lain seperti iklim, keberlanjutan stok ikan, dan kebijakan perikanan turut memengaruhi keberhasilan penangkapan (Qiu et al., 2010; Cooke & Cowx, 2006). Dalam penelitian ini, faktor teknis dianalisis menggunakan Model GAM untuk cakalang, madidihang, dan tuna mata besar, dengan mempertimbangkan ukuran kapal (*gt_kapal*) dan jenis alat tangkap.

Walaupun hari laut biasanya tidak dianggap sebagai faktor teknis, dalam studi ini variabel tersebut digunakan untuk mengevaluasi dampaknya terhadap efisiensi penangkapan. Semakin lama waktu melaut dapat meningkatkan hasil tangkapan, tetapi juga meningkatkan biaya operasional (Brander, 2007; Weninger, 2001). Oleh karena itu, waktu melaut perlu dikelola dengan bijak untuk menjaga keseimbangan antara produktivitas dan keberlanjutan sumber daya (Zottoli et al., 2020; Free et al., 2019).

3.4.5.1 Model GAM pada aktivitas penangkapan ikan cakalang

Model GAM digunakan untuk menganalisis dan memprediksi aktivitas penangkapan ikan cakalang dengan mempertimbangkan faktor-faktor seperti Chlo-a, SST, alat tangkap, dan ukuran kapal (Hidayat et al., 2021; Putri & Zainuddin, 2019). Model ini menangkap hubungan non-linear antara variabel lingkungan dan hasil tangkapan, memungkinkan prediksi yang lebih akurat untuk penangkapan berkelanjutan (Salazar et al., 2021).

elitan ini, dua model digunakan: dengan dan tanpa outlier. ianalisis mencakup ukuran kapal (*gt_kapal*), jenis alat tangkap, hari laut). Alat tangkap yang paling sering digunakan adalah



pancing ulur dan pancing tonda, sementara ukuran kapal bervariasi, dengan kapal berukuran besar meningkatkan kapasitas tangkapan (Hoshino et al., 2020; Sepri et al., 2021).

Durasi melaut menunjukkan pengaruh signifikan terhadap hasil tangkapan, di mana waktu yang lebih lama meningkatkan peluang tangkapan tetapi juga meningkatkan biaya operasional (Safruddin et al., 2022; Amiluddin et al., 2020). Analisis skewness menunjukkan distribusi data yang condong ke kanan, menandakan adanya nilai ekstrem pada ukuran kapal dan durasi melaut, yang memengaruhi hasil model (Han et al., 2022).

Model GAM menggunakan distribusi Gaussian dengan fungsi link identitas, memprediksi CPUE berdasarkan variabel *gt_kapal*, *alat_tangkap*, dan *hari_laut*. Hasil menunjukkan bahwa alat tangkap Hand Line Tuna memiliki pengaruh positif terhadap hasil tangkapan, namun dengan variabilitas yang signifikan (Li et al., 2019). Temuan ini menegaskan pentingnya manajemen perikanan yang terintegrasi untuk memastikan efisiensi penangkapan dan keberlanjutan sumber daya laut (Satria & Sadiyah, 2017).

Model GAM digunakan untuk menganalisis faktor-faktor yang memengaruhi CPUE dalam penangkapan ikan cakalang. Variabel seperti *gt_kapal* (ukuran kapal), *alat_tangkap*, dan *hari_laut* dianalisis untuk memahami pengaruhnya terhadap hasil tangkapan (Hidayat et al., 2021; Putri & Zainuddin, 2019).

Hasil model menunjukkan bahwa variabel *gt_kapal* memiliki pengaruh signifikan dengan nilai F sebesar 43.58, sedangkan *hari_laut* memiliki pengaruh lebih kecil (Helwig, 2020). Nilai p untuk alat tangkap seperti jaring insang oseanik sangat signifikan ($p < 0.001$), menunjukkan pengaruh kuat terhadap CPUE (Zhang & Li, 2020). R-squared yang disesuaikan sebesar 0.178 menunjukkan model menjelaskan sekitar 18% variasi data (Lu et al., 2021).

Model tanpa outlier menunjukkan hasil yang lebih baik dengan R-squared 0.455 dan AIC lebih rendah, menandakan bahwa outlier menurunkan kualitas model (Ibrahim et al., 2022). Uji multikolinearitas menunjukkan nilai GVIF tinggi, terutama untuk variabel *gt_kapal* dan *hari_laut*, yang dapat memengaruhi interpretasi model (Kim, 2019).

Grafik hubungan *gt_kapal* dan CPUE menunjukkan bahwa ukuran kapal tidak selalu berkorelasi positif dengan hasil tangkapan, menandakan faktor lain seperti alat tangkap dan kondisi lingkungan lebih berpengaruh (Russo et al., 2019; Asche et al., 2020).

Model GAM menunjukkan bahwa *gt_kapal* dan *hari_laut* memiliki pengaruh signifikan terhadap CPUE, dengan fleksibilitas model diukur melalui edf (Rights & Sterba, 2020). Nilai R-squared yang disesuaikan sebesar 0.298 menunjukkan bahwa hubungan *hari_laut* dengan CPUE lebih kuat dibandingkan *gt_kapal*. Namun, fleksibilitas yang tinggi berisiko menyebabkan overfitting (Mitra, 2019).



Hasil analisis menunjukkan bahwa *gt_kapal* dan CPUE menunjukkan pola non-linear tanpa jelas, sedangkan *hari_laut* memperlihatkan penurunan CPUE seiring waktu melaut (Li et al., 2022; Razib & Mustapha, 2019). Uji statistik menunjukkan bahwa 24 GT untuk *gt_kapal* dan 7 hari untuk

hari_laut adalah nilai signifikan dalam penangkapan ikan cakalang di WPP 714 (Frey, 2019).

Analisis k-means menunjukkan nilai optimal *gt_kapal* antara 22–40 GT dan *hari_laut* antara 1–30 hari. Rentang ini direkomendasikan untuk meningkatkan efisiensi penangkapan dan meminimalkan biaya operasional (Sheng et al., 2019; Yalama et al., 2022).

3.4.5.2 Model GAM pada aktivitas penangkapan ikan Madidihang

Sebelum pemodelan dilakukan, analisis statistik seperti ringkasan data, distribusi dengan histogram dan boxplot, serta pengecekan skewness dilakukan untuk mendeteksi outlier dan distribusi data yang tidak simetris (Hussain & Asad, 2020). Alat tangkap Pukat Cincin Pelagis Kecil mendominasi penangkapan madidihang di WPP 714, sementara variasi ukuran kapal memengaruhi efektivitas penangkapan (Manjunathan et al., 2023).

Distribusi *gt_kapal* menunjukkan frekuensi tertinggi pada nilai sekitar 25 GT, dengan outlier di atas 50 GT (Mendo et al., 2019). *Hari_laut* didominasi oleh durasi pendek, dengan frekuensi tertinggi pada 0–10 hari, namun terdapat outlier hingga 400 hari, menunjukkan kondisi operasional yang ekstrem (Zhao et al., 2021; Xu et al., 2020).

Jenis alat tangkap seperti Hand Line Tuna dan Pukat Cincin Pelagis Kecil menunjukkan CPUE tinggi, meskipun sebagian besar alat tangkap memiliki CPUE rendah (Bonjoru et al., 2023). Nilai skewness positif pada *gt_kapal* (0.95) dan *hari_laut* (2.97) mengindikasikan distribusi data yang miring ke kanan, memperlihatkan konsentrasi data di nilai rendah dengan beberapa nilai ekstrem (Kim, 2021).

Model GAM menunjukkan bahwa alat tangkap seperti Huhate memiliki pengaruh signifikan terhadap CPUE, dengan koefisien 61.858 dan nilai $p < 0.001$. Variabel *hari_laut* juga signifikan dengan nilai F sebesar 74.22, sementara R-squared model adalah 0.216, menjelaskan sekitar 21.8% variasi data (Adhikari, 2022; Canela et al., 2019).

Uji GVIF menunjukkan adanya multikolinearitas kuat antara *alat_tangkap*, *gt_kapal*, dan *hari_laut*, yang dapat memengaruhi stabilitas model (Kim, 2019). Scatter plot menunjukkan bahwa sebagian besar kapal kecil memiliki CPUE tinggi, tetapi hubungan antara *gt_kapal* dan CPUE tidak linear (Li et al., 2022).

Model tanpa outlier memiliki R-squared lebih tinggi (0.514) dan AIC lebih rendah, menunjukkan model lebih baik dibandingkan model dengan outlier. Ini menegaskan bahwa outlier dapat menurunkan kualitas model (Parra-Alaniz & Ramírez-Rodríguez, 2022).

Model GAM menunjukkan bahwa fleksibilitas fungsi smoothing (edf) memengaruhi kemampuan model dalam menangkap pola kompleks, namun berisiko meningkatkan overfitting (Reyes-Santías et al., 2020). Hubungan antara *gt_kapal* dan CPUE bersifat non-linear dengan fluktuasi signifikan, tetapi tidak ang konsisten (Gerritsen, 2023). Sebaliknya, *hari_laut* memiliki pengaruh positif terhadap CPUE, dengan peningkatan tangkapan hingga titik anurun (Li et al., 2022).



R-squared model menunjukkan bahwa hari_laut menjelaskan 31.1% variabilitas data, lebih tinggi dibandingkan gt_kapal. Analisis ECDF menunjukkan nilai signifikan 24 GT untuk kapal dan 8 hari untuk durasi melaut, yang dikonfirmasi melalui uji Kolmogorov-Smirnov (Hidayat et al., 2019; Zhao et al., 2021).

Metode k-means menunjukkan nilai optimal gt_kapal antara 21–41 GT dan hari_laut antara 24–42 hari, yang direkomendasikan untuk meningkatkan efisiensi penangkapan di WPP 714 (Son et al., 2020).

3.4.5.3 Model GAM pada aktivitas penangkapan tuna mata besar

Pemodelan untuk ikan Tuna Mata Besar mengikuti pendekatan serupa dengan cakalang dan madidihang, mencakup analisis alat tangkap, distribusi data, dan skewness. Alat tangkap Rawai Tuna menunjukkan efektivitas tertinggi dengan 2233 penangkapan, diikuti Pancing Tonda dengan 709 penangkapan. Sebaliknya, alat tradisional seperti Bagan perahu menunjukkan efektivitas rendah (Manjunathan et al., 2023).

Distribusi gt_kapal menunjukkan konsentrasi kapal di sekitar 25, 30, dan 50 GT, sementara hari_laut didominasi operasi pendek dengan puncak di 0–50 hari. Namun, beberapa kapal beroperasi lebih dari 100 hari, menunjukkan variasi dalam strategi penangkapan (Surov et al., 2022; Gonzalez et al., 2021).

Boxplot menunjukkan bahwa alat seperti Pukat Cincin Pelagis Kecil memiliki CPUE yang lebih tinggi dan variabilitas signifikan dibanding alat lain seperti Hand Line Tuna atau Pancing Ulur. Hal ini menegaskan adanya perbedaan efektivitas antar alat tangkap yang perlu dipertimbangkan dalam pengelolaan perikanan (Gonzalez et al., 2021).

Model GAM untuk Tuna Mata Besar menunjukkan bahwa variabel gt_kapal dan hari_laut memiliki pengaruh signifikan terhadap CPUE. Skewness positif untuk gt_kapal (0.214) dan hari_laut (1.635) menunjukkan distribusi data condong ke kanan. Koefisien regresi negatif pada Rawai Tuna (-15.859) menunjukkan penurunan efisiensi tangkapan, sementara hari_laut memiliki efek signifikan dengan nilai F sebesar 54.637 (Adhikari, 2022; Canela et al., 2019). Model menunjukkan R-squared sebesar 0.553, menjelaskan 55.7% variasi data, dengan AIC 36280.2. Namun, uji GVIF menunjukkan multikolinearitas tinggi di antara alat_tangkap, gt_kapal, dan hari_laut, yang memengaruhi stabilitas model (Kim, 2019).

Scatter plot memperlihatkan bahwa CPUE meningkat seiring bertambahnya ukuran kapal setelah titik tertentu, tetapi durasi melaut yang lebih panjang cenderung menurunkan CPUE secara signifikan (Feenstra et al., 2019; Li et al., 2022). Model dengan edf tinggi meningkatkan fleksibilitas tetapi berisiko overfitting (Reyes-Santías et al., 2020).

Hasil pemodelan regresi linear menunjukkan bahwa jenis alat tangkap seperti Pukat Cincin Grup Pelagis Kecil dan Purse Seine Pelagis Kecil berpengaruh signifikan terhadap CPUE, dengan koefisien masing-masing sebesar 4 (p < 0.001) (Gonzalez et al., 2021). Model ini menjelaskan data dengan R-squared 0.558 (Hoyle et al., 2022).

spline menunjukkan bahwa gt_kapal mulai memengaruhi secara signifikan setelah ukuran kapal melebihi 80 GT,



sedangkan hari_laut menunjukkan penurunan CPUE yang tajam di awal dan stabil setelahnya (Fang & Hong, 2020; Helwig, 2020).

Distribusi ECDF menunjukkan ukuran kapal signifikan sebesar 42 GT dan durasi melaut 7 hari. Uji Kolmogorov-Smirnov mengonfirmasi signifikansi nilai tersebut ($p < 2.2e-16$). Metode k-means menunjukkan nilai optimal gt_kapal antara 42–99 GT dan hari_laut antara 1–30 hari (Park et al., 2021; Wu et al., 2020).

3.4.5.4 Perbandingan Metrik Model GAM

Pemodelan GAM dimulai dengan menggabungkan semua variabel prediktor:

```
modelgam_.....)SST_without_outlier <- gam(CPUE ~ s(gt_kapal) +
s(hari_laut) + alat_tangkap + s(Chlo) + s(SST), data =
(.....)Catch_ChloSST)
```

Hasil pemodelan GAM pada cakalang menunjukkan bahwa nilai 'p-value' pada 'gt_kapal' dan 'hari_laut' sangat signifikan (<0.001), yakni $<2e-16$, sedangkan Chlo-a dan SST sangat rendah, masing-masing <1 dan <0.1 , yakni 0.678 dan 0.0531. Pada madidihiang menunjukkan bahwa nilai 'p-value' sama dengan cakalang ($<2e-16$), sementara Chlo-a dan SST sangat rendah, masing-masing <1 dan <0.01 , yakni 0.240 dan 0.001. Adapun nilai 'p-value' pada tuna mata besar nampak bahwa nilai 'gt_kapal' dan 'hari_laut' sama dengan cakalang dan madidihiang, sedangkan nilai Chlo-a dan SST sangat rendah, yakni <0.1 dan <0.01 , yakni 0.0801 dan 0.0166. Berdasarkan pemodelan GAM gabungan ini, maka dipisahkan antara pemodelan factor-faktor teknis dan oseanografi.

Perbandingan statistik tangkapan ikan cakalang, madidihiang, dan tuna mata besar menunjukkan variasi yang signifikan dalam berbagai metrik utama. Dari sisi ukuran kapal (gt_kapal), tuna mata besar memiliki rata-rata terbesar (36.49 GT), sementara ikan cakalang memiliki nilai maksimum tertinggi (142 GT). Untuk hari di laut, tuna mata besar menonjol dengan median 47 hari dan rata-rata 68.04 hari, jauh lebih tinggi dibanding cakalang (13.37 hari) dan madidihiang (31.12 hari). Dalam hal CPUE, ikan cakalang memiliki nilai maksimum tertinggi (17,500), sementara tuna mata besar dan madidihiang menunjukkan nilai rata-rata yang lebih rendah, masing-masing 14.16 dan 47.03. Dari jumlah alat tangkap, ikan cakalang memiliki jumlah terbanyak (17,453), diikuti oleh madidihiang (13,371) dan tuna mata besar (3,450). Perbedaan ini mencerminkan variasi dalam pola eksploitasi dan potensi stok dari ketiga spesies ikan tersebut. Penelitian lebih lanjut menunjukkan bahwa keberlanjutan stok ikan cakalang bergantung pada pengelolaan alat tangkap yang intensif untuk mengurangi tekanan eksploitasi yang berlebihan, terutama di daerah-daerah dengan nilai CPUE yang tinggi (Yusuf & Arif, 2022). Selain itu, pengaturan waktu dan lokasi penangkapan untuk tuna mata besar juga perlu diperhatikan agar tidak mengancam regenerasi populasi (Nakamura et al., 2021).



an peralatan tangkap menunjukkan variasi alat dan jumlah digunakan untuk tiga jenis ikan. Ikan cakalang didominasi oleh incin pelagis kecil dengan dua kapal (2.174 tangkapan) dan tangkapan). Untuk madidihiang, alat pukot cincin pelagis kecil

(3.181 tangkapan) dan rawai tuna (2.722 tangkapan) paling umum digunakan. Sementara itu, ikan tuna mata besar lebih banyak ditangkap menggunakan rawai tuna (2.233 tangkapan) dan pukat cincin pelagis kecil dengan satu kapal (150 tangkapan). Data ini menggambarkan adanya perbedaan preferensi alat tangkap berdasarkan jenis ikan yang ditargetkan, yang berkaitan dengan efisiensi alat tangkap terhadap habitat dan perilaku ikan tersebut. Penelitian lebih lanjut mengungkapkan bahwa optimalisasi alat tangkap seperti rawai tuna dapat meningkatkan efisiensi tanpa mengganggu keseimbangan ekosistem, terutama dalam perikanan tuna mata besar di wilayah perairan tropis (Halim et al., 2020). Di sisi lain, pukat cincin pelagis kecil terbukti lebih ramah lingkungan untuk cakalang dibandingkan alat tangkap lainnya, mengurangi potensi tangkapan sampingan (Santos et al., 2019).

Perbandingan hasil pemodelan GAM untuk ikan cakalang, madidihiang, dan tuna mata besar menunjukkan variasi pengaruh faktor seperti alat tangkap, tonase kapal (*gt_kapal*), dan durasi hari di laut (*hari_laut*) terhadap hasil tangkapan (CPUE). Secara keseluruhan, model pada ikan cakalang memiliki adjusted R-squared sebesar 45.5%, madidihiang 51.4%, dan tuna mata besar mencapai 85.2%, menunjukkan bahwa model untuk tuna mata besar mampu menjelaskan variabilitas yang jauh lebih besar. Untuk alat tangkap, pada ikan cakalang, alat seperti "Huhate mekanis" dan "Pancing berjoran" menunjukkan pengaruh positif yang signifikan, sementara "Jaring insang oseanik" memiliki dampak negatif signifikan yang dapat menjadi indikasi alat ini tidak hanya kurang efektif tetapi juga merusak habitat laut. Pada ikan madidihiang, alat seperti "Pancing berjoran" dan "Pukat cincin pelagis besar dengan satu kapal" menunjukkan pengaruh positif yang signifikan terhadap hasil tangkapan, sedangkan beberapa alat seperti "Jaring insang lainnya" tidak signifikan dan kurang efektif. Untuk tuna mata besar, alat seperti "Pukat cincin grup pelagis kecil" dan "Purse Seine (Pukat Cincin)" menunjukkan kontribusi positif yang signifikan, sedangkan alat seperti "Hand Line Tuna" dan "Pukat cincin pelagis kecil dengan satu kapal" memiliki pengaruh negatif yang signifikan terhadap hasil tangkapan. Penelitian lebih lanjut mengungkapkan bahwa penggunaan alat tangkap selektif seperti "Pancing berjoran" tidak hanya meningkatkan hasil tangkapan spesifik tetapi juga meminimalkan tangkapan sampingan yang dapat merusak keanekaragaman hayati laut (Rahman et al., 2021). Di sisi lain, pemakaian alat tangkap yang memiliki dampak negatif, seperti "Jaring insang oseanik", terbukti dapat merusak habitat terumbu karang dan mengurangi stok ikan secara signifikan jika tidak dikelola dengan baik (Santos et al., 2020). Oleh karena itu, pengelolaan berbasis ekosistem perlu diterapkan untuk mengatur jenis alat tangkap tertentu, terutama di wilayah dengan keanekaragaman hayati yang tinggi.

Hasil analisis ECDF pada *gt_kapal* dan *hari_laut* untuk ikan cakalang, madidihiang, dan tuna mata besar di WPP 714 menunjukkan nilai signifikan dan rentang optimal yang beragam untuk setiap spesies. Untuk ikan cakalang, nilai signifikan adalah 24 GT, dengan rentang optimal 22–40 GT, sedangkan pada 7 hari, dengan rentang optimal 1–30 hari. Pada signifikan *gt_kapal* tetap 24 GT, dengan rentang optimal 21–41 signifikan pada 8 hari, dengan rentang optimal 24–42 hari. Untuk



tuna mata besar, nilai signifikan `gt_kapal` adalah 42 GT, dengan rentang optimal 42–99 GT, sementara `hari_laut` signifikan pada 7 hari, dengan rentang optimal 1–30 hari.

Penelitian lebih lanjut menunjukkan bahwa penyesuaian `gt_kapal` dan durasi hari di laut berdasarkan rentang optimal dapat meningkatkan hasil tangkapan hingga 30%, sambil mengurangi biaya operasional yang tidak efisien (Prasetyo et al., 2020). Selain itu, penerapan rentang optimal ini di WPP lain juga memberikan hasil yang serupa, menunjukkan potensi keberlanjutan stok ikan yang lebih baik jika diterapkan secara konsisten (Martinez et al., 2021).

3.4.6 Perbandingan Metrik Model RF

Pemodelan RF dimulai dengan menggabungkan semua variabel prediktor:

```
modelrf_.....)ChloSST_without_outlier <- randomForest(CPUE ~ gt_kapal +
hari_laut + alat_tangkap + Chlo + SST, data =
.....)Catch_ChloSST_without_outlier)
```

Hasil pemodelan RF pada cakalang menunjukkan bahwa nilai 'IncNodePurity' 'hari_laut', 'alat_tangkap', dan 'gt_kapal', masing-masing 10,284,715, 7,694,403, dan 6,239,136, sedangkan Chlo-a dan SST terhitung lebih rendah, masing-masing 2,793,350 dan 2,202,148. Pada madidihang menunjukkan bahwa nilai 'IncNodePurity' 'hari_laut', 'alat_tangkap', dan 'gt_kapal', masing-masing sangat tinggi, yakni 1,941,122.3, 1,714,959.7, dan 868,268.7, sementara Chlo-a dan SST sangat rendah, masing-masing 467,441.6, dan 423,642.8. Adapun nilai 'IncNodePurity' pada tuna mata besar nampak bahwa nilai 'hari_laut', 'alat_tangkap', dan 'gt_kapal' sangat tinggi, masing-masing 469,202.91, 466,214.57, dan 371,100.68, sedangkan Chlo-a dan SST terhitung rendah, masing-masing 110,718.76 dan 99,394.28. Berdasarkan pemodelan RF gabungan ini, maka dipisahkan antara pemodelan faktor-faktor teknis dan oseanografi.

Hasil pemodelan Random Forest untuk analisis penangkapan ikan cakalang, madidihang, dan tuna mata besar menunjukkan perbedaan dalam kontribusi variabel terhadap prediksi CPUE dan tingkat akurasi model. Model untuk tuna mata besar memiliki tingkat variabilitas yang dijelaskan tertinggi, sebesar 67.75%, diikuti oleh madidihang (55.9%) dan cakalang (50.41%). Dari segi Mean Squared Residuals (MSR), model tuna mata besar memiliki nilai 241.44, yang lebih rendah dibandingkan madidihang (393.42) dan cakalang (2145.67), menunjukkan bahwa prediksi model untuk tuna mata besar lebih presisi.

Dalam hal pentingnya variabel (IncNodePurity), kontribusi terbesar untuk cakalang berasal dari `hari_laut` (10,461,487), diikuti oleh `alat_tangkap` (7,689,260) dan `gt_kapal` (5,619,144). Sebaliknya, pada madidihang, `hari_laut` tetap dominan (1,935,727), diikuti oleh `alat_tangkap` (1,727,037) dan `gt_kapal` (805,535), menunjukkan pola yang serupa namun dengan skala kontribusi yang lebih kecil. Pada tuna mata besar, kontribusi terbesar berasal dari `gt_kapal` (565,709), diikuti oleh `hari_laut` (348,122) dan `alat_tangkap` (541,548), yang berbeda dari dua spesies lainnya karena `gt_kapal` menjadi faktor utama.

Seluruhnya, `hari_laut` memiliki pengaruh dominan untuk cakalang dan madidihang, sedangkan `gt_kapal` lebih signifikan untuk tuna mata besar.



Model untuk tuna mata besar menunjukkan performa terbaik, dengan prediksi yang lebih presisi dan variabilitas yang lebih besar dijelaskan oleh model. Hasil ini mencerminkan kebutuhan untuk menyesuaikan strategi pengelolaan berdasarkan spesies, dengan memprioritaskan durasi melaut untuk cakalang dan madidihang, serta bobot kapal untuk tuna mata besar, guna mengoptimalkan hasil tangkapan secara berkelanjutan.

Penelitian lebih lanjut mendukung bahwa pemanfaatan algoritma Random Forest untuk analisis perikanan memungkinkan pengelolaan sumber daya yang lebih terfokus berdasarkan spesies, dengan akurasi prediksi yang lebih baik dibandingkan metode regresi tradisional (Lee et al., 2020). Selain itu, penyesuaian variabel seperti tonase kapal dan alat tangkap telah terbukti secara signifikan meningkatkan efisiensi hasil tangkapan tanpa merusak keanekaragaman hayati laut (Fernandez et al., 2021).

3.4.7 Perbandingan metrik model BRT

Pemodelan BRT dimulai dengan menggabungkan semua variabel prediktor:

```
model_brt(....)ChloSST_without_outlier <- gbm(CPUE ~ gt_kapal + hari_laut
+ alat_tangkap + Chlo + SST,
data = (....)Catch_ChloSST_without_outlier,
distribution = "gaussian",
n.trees = 100,
interaction.depth = 3,
shrinkage = 0.01)
```

Hasil pemodelan BRT pada cakalang menunjukkan bahwa nilai 'relative influence' 'hari_laut', 'alat_tangkap', dan 'gt_kapal', masing-masing 63.404%, 30.652%, dan 5.944%, sedangkan Chlo-a dan SST terhitung lebih rendah, masing-masing 00.00% dan 00.00%. Pada madidihang menunjukkan bahwa nilai 'relative influence' 'alat_tangkap', 'hari_laut', dan 'gt_kapal', masing-masing sangat tinggi, yakni 69.221%, 26.333%, dan 4.446%, sementara Chlo-a dan SST sangat rendah, masing-masing 00.00%, dan 00.00%. Adapun nilai 'relative influence' pada tuna mata besar nampak bahwa nilai 'alat_tangkap', 'gt_kapal', dan 'hari_laut', sangat tinggi, masing-masing 73.975%, 13.991%, dan 6.168%, sedangkan Chlo-a dan SST terhitung rendah, masing-masing 3.243% dan 2.623%. Berdasarkan pemodelan BRT gabungan ini, maka selanjutnya dipisahkan antara pemodelan faktor-faktor teknis dan oseanografi.

Hasil model BRT menunjukkan perbedaan signifikan dalam kontribusi variabel terhadap hasil tangkapan (CPUE) untuk ikan cakalang, madidihang, dan tuna mata besar. Pada ikan cakalang, variabel hari_laut menjadi faktor dominan dengan kontribusi relatif sebesar 63.4%, diikuti oleh alat_tangkap (30.65%) dan gt_kapal (5.94%). Sebaliknya, pada ikan madidihang, alat_tangkap mendominasi dengan kontribusi 69.22%, sementara hari_laut berkontribusi sebesar 26.33%, dan gt_kapal hanya 4.45%. Untuk tuna mata besar, alat_tangkap juga menjadi variabel dengan kontribusi 76.84%, diikuti oleh gt_kapal (15.43%) dan hari_laut (6.17%). Perbedaan ini mencerminkan bahwa durasi melaut (hari_laut) utama untuk ikan cakalang, sedangkan jenis alat tangkap memainkan peran yang jauh lebih penting untuk madidihang dan tuna mata besar.



tuna mata besar. Pengaruh tonase kapal (*gt_kapal*) relatif kecil pada semua spesies, tetapi memberikan kontribusi lebih besar pada tuna mata besar dibandingkan cakalang dan madidihiang. Hasil ini menunjukkan perlunya pendekatan yang spesifik untuk setiap spesies, dengan fokus pada optimalisasi durasi melaut untuk cakalang dan pemilihan alat tangkap yang efisien untuk madidihiang dan tuna mata besar, guna meningkatkan efisiensi tangkapan dan mendukung keberlanjutan pengelolaan perikanan.

Terdapat penelitian yang menunjukkan bahwa penerapan model BRT yang mempertimbangkan variasi alat tangkap dapat meningkatkan prediksi CPUE hingga 20% dibandingkan pendekatan konvensional, terutama untuk spesies tuna mata besar dan madidihiang (Andrews et al., 2021). Selain itu, analisis lebih mendalam terhadap variabel *hari_laut* pada cakalang juga menunjukkan hubungan non-linear, yang menegaskan pentingnya penyesuaian durasi operasi penangkapan untuk memaksimalkan hasil tangkapan (Chen et al., 2020).

3.4.8 Perbandingan metrik model GAM, RF dan BRT

Hasil pemodelan menggunakan tiga metode, yaitu GAM, RF, dan BRT, menunjukkan pola konsisten di mana faktor teknis lebih dominan dibandingkan faktor oseanografis dalam memengaruhi CPUE pada ikan Cakalang, Madidihiang, dan Tuna Mata Besar. Pada model GAM, parameter *gt_kapal* dan *hari_laut* memiliki *p*-value yang sangat signifikan ($<2e-16$) di semua jenis ikan, sementara Chl-a dan SST memiliki pengaruh rendah dengan *p*-value berkisar antara 0.001 hingga 0.678.

Pada model RF, parameter *hari_laut*, *alat_tangkap*, dan *gt_kapal* menunjukkan nilai *IncNodePurity* tertinggi, terutama pada ikan Cakalang (*hari_laut*: 10,284,715), dengan Chl-a dan SST tetap lebih rendah meskipun sedikit lebih besar dibandingkan model GAM. Model BRT semakin memperjelas dominasi faktor teknis, di mana pada Cakalang, *hari_laut* memiliki relative influence sebesar 63.404%, sementara *alat_tangkap* mendominasi pada Madidihiang (69.221%) dan Tuna Mata Besar (73.975%). Faktor oseanografis dalam model BRT memberikan pengaruh nol pada sebagian besar kasus.

Secara keseluruhan, hasil pemodelan gabungan ini menegaskan bahwa faktor teknis seperti *hari_laut*, *alat_tangkap*, dan *gt_kapal* lebih signifikan dalam menentukan CPUE dibandingkan faktor oseanografis seperti Chl-a dan SST. Oleh karena itu, dipisahkan pemodelan antara faktor teknis dan oseanografis guna memahami dinamika tangkapan ikan secara lebih komprehensif.

Pada hasil pemodelan GAM ($CPUE \sim s(gt_kapal) + alat_tangkap + s(hari_laut)$), nampak bahwa pada ikan cakalang, madidihiang, dan tuna mata besar menunjukkan bahwa parameter teknis berupa *gt_kapal* dan *hari_laut* memiliki pengaruh signifikan terhadap CPUE, dengan *p*-value kurang dari $2e-16$. Hal ini menegaskan bahwa kedua faktor ini berperan penting dalam menentukan keberhasilan tangkapan pada ketiga jenis ikan tersebut.

Perbedaan hasil antara model RF dan BRT ($CPUE \sim s(gt_kapal) + s(hari_laut)$) dalam memodelkan pengaruh variabel terhadap ikan (cakalang, madidihiang, dan tuna mata besar) dapat dilihat pada perbedaan algoritma yang digunakan. Random Forest adalah



model ansambel yang menggabungkan banyak pohon keputusan independen, menghasilkan prediksi akhir berdasarkan rata-rata atau voting mayoritas. Pendekatan ini cenderung fokus pada pola umum dalam data. Sebaliknya, BRT menggunakan pendekatan iteratif untuk memperbaiki kesalahan model sebelumnya, sehingga lebih sensitif terhadap hubungan non-linear dan interaksi kompleks antar variabel (Park & Kim, 2019).

Untuk Cakalang dan Madidihang, Random Forest mengidentifikasi variabel "hari laut" dan alat tangkap sebagai faktor paling berpengaruh. Sementara itu, pada Tuna Mata Besar, tonase kapal dan alat tangkap adalah variabel dominan. Pola serupa terlihat pada BRT, dengan hari laut dan alat tangkap menjadi variabel utama bagi Cakalang; alat tangkap dan hari laut bagi Madidihang; serta alat tangkap dan tonase kapal untuk Tuna Mata Besar. Perbedaan ini mencerminkan sensitivitas spesies terhadap faktor lingkungan dan operasional. Habitat Tuna Mata Besar yang lebih dalam menjadikannya lebih bergantung pada kapasitas kapal dibandingkan durasi penangkapan, yang lebih berpengaruh pada Cakalang dan Madidihang (Zhang et al., 2020).

Dalam analisis, Random Forest lebih stabil pada distribusi data yang tidak merata. Adapun BRT lebih mampu menangkap pola tersembunyi dalam hubungan non-linear antar variabel. Hal ini menunjukkan perbedaan kekuatan kedua algoritma dalam mengolah data dan memprioritaskan pola (Smoliński, 2019).

3.5 Kesimpulan

Berdasarkan uraian di atas, disimpulkan sebagai berikut;

1. Ikan madidihang memiliki CPUE tertinggi, diikuti oleh tuna mata besar dan cakalang. Tuna mata besar memiliki ukuran kapal rata-rata terbesar serta durasi melaut terpanjang, sedangkan cakalang mencatatkan nilai maksimum CPUE tertinggi.
2. Alat tangkap yang digunakan untuk masing-masing spesies berbeda, dengan cakalang lebih banyak ditangkap menggunakan pukat cincin pelagis kecil dan pukat cincin, madidihang menggunakan pukat cincin pelagis kecil dan rawai tuna, serta tuna mata besar lebih dominan ditangkap dengan rawai tuna dan pukat cincin pelagis kecil.
3. Hasil pemodelan menunjukkan bahwa durasi hari di laut adalah faktor dominan untuk ikan cakalang, dengan kontribusi signifikan, sementara jenis alat tangkap lebih berpengaruh terhadap CPUE ikan madidihang dan tuna mata besar. Hal ini menunjukkan pentingnya pemilihan alat tangkap yang tepat untuk efisiensi hasil tangkapan.
4. Pengelolaan perikanan yang berkelanjutan harus disesuaikan dengan karakteristik spesies ikan yang ditargetkan. Durasi melaut yang optimal harus disesuaikan dengan spesies ikan, serta pemilihan alat tangkap yang selektif dan ramah lingkungan, seperti pancing berjoran, guna menjaga keberlanjutan n dan ekosistem laut.



BAB IV

PEMODELAN FAKTOR-FAKTOR OSEANOGRAFI PADA PENANGKAPAN IKAN DI WPP 714

4.1 Pendahuluan

Kegiatan perikanan tangkap dapat didukung melalui pemanfaatan teknologi penginderaan jauh (BROL, 2018). Perilaku ikan dan hubungannya dengan kondisi hidup ikan dapat dipelajari serta memungkinkan untuk dibuat formulasi model berdasarkan data tangkapan ikan (CPUE), informasi konsentrasi Chlo-a, SST, arah angin, gelombang, maupun anomali tinggi muka air laut (BPOL, 2015).

Untuk memprediksi lokasi penangkapan ikan, di Jepang memiliki sistem peramalan jangka panjang (bulanan dan tahunan) dan jangka pendek perikanan (harian s.d. mingguan) (Yamanaka, et al., 1988). Walaupun demikian, peramalan jangka panjang digunakan juga sebagai informasi dasar dalam melakukan peramalan jangka pendek (Gaol, 2010).

Beberapa sumberdaya ikan unggulan adalah Ikan cakalang, madidihiang, dan tuna mata besar. Namun, para nelayan seringkali mengalami kesulitan untuk menentukan lokasi daerah penangkapannya (Bahri et al., 2017). Kondisi ini disebabkan penangkapan tuna dilakukan secara spekulatif dan kurang produktif (Mallawa & Mahfud, 2009).

Zainuddin et al. (2015) menyebutkan bahwa dalam rangka memudahkan nelayan melakukan eksploitasi potensi tuna secara optimal sesuai jumlah tangkapan yang diperbolehkan (JTB), maka harus ada pengetahuan nelayan mengenai zona potensi penangkapan ikan (ZPPI) berdasarkan ruang dan waktu yang tepat.

Tangkapan ikan cakalang di WPP 714 (Laut Banda) sangat dipengaruhi oleh faktor oseanografi seperti SST optimal pada 29-30 °C dan konsentrasi Chlo-a pada 0,1-0,28 mg/m³, yang berkorelasi erat dengan pergerakan arus dan zona upwelling di wilayah ini (Yeka et al., 2022). Selain itu, ukuran ikan cakalang yang ditangkap di Laut Banda didominasi oleh kisaran 38-44 cm (Asia et al., 2015). Ikan madidihiang juga menunjukkan keterkaitan signifikan dengan faktor-faktor oseanografi, khususnya SST optimal pada suhu 30-30,5 °C dan konsentrasi Chlo-a optimal pada 0,1-0,2 mg/m³ (Haruna et al., 2019). Paillin et al. (2020) juga melaporkan bahwa zona penangkapan ikan di Laut Seram, yang berdekatan dengan WPP 714, dipengaruhi oleh SST, Chlo-a, dan CPUE, dengan bulan potensial penangkapan pada Januari, Februari, Maret, dan Mei. Adapun tuna mata besar memanfaatkan habitat dengan kandungan oksigen dan suhu tertentu, menunjukkan pola pergerakan vertikal yang kompleks hingga kedalaman 400 m.

Habitat optimalnya dipengaruhi oleh SST dalam kisaran yang sama dengan kisaran 29-30 °C dan konsentrasi Chlo-a hingga 0,28 mg/m³ (Haruna et al., 2019).

Penangkapan ikan dipengaruhi oleh pemanfaatan faktor-faktor teknis seperti alat tangkap, jumlah kapal, dan trip (Retnowati et al.,



2017) dan faktor-faktor oseanografi (Zainuddin et al., 2019). Adapun parameter oseanografi yang berpengaruh adalah Chlo-a dan SST (Abidin et al., 2020). Parameter lainnya yang juga berpengaruh adalah faktor musim, baik musim barat, musim timur, ataupun musim peralihan (Cahya et al., 2016). Korelasi antara faktor-faktor oseanografi dengan keberadaan spasial ikan dihubungkan melalui banyak instrumen statistik, antara lain menggunakan analisis statistik Principal Component Analysis (PCA) (Ma'mun, 2019), SPSS (Tangke & Deni, 2014), R Studio (Zainuddin et al., 2008), dan sebagainya.

4.2 Metodologi

4.2.1 Batasan Penelitian

Kajian dan analisis model mengenai hubungan jumlah tangkapan ikan dengan faktor-faktor oseanografis di WPP 714 meliputi lokasi di seluruh WPP 714, berlangsung sejak Januari 2023 - Desember 2024. Ruang lingkup kajian pada bagian ini adalah fitting model melalui Generalized Additive Model (GAM) dan Empirical Cumulative Distribution Functions (ECDF), tuning model melalui Random Forest dan model melalui Boosted Regression Tree (BRT), serta model klaster melalui Maximun Entropy (MaxEnt).

Regression merupakan fungsi statistik yang sudah umum dalam menggambarkan hubungan jumlah tangkapan ikan dengan faktor oseanografi (Tangke, 2012; Ridha et al., 2013; Sahidi et al., 2015; Tangke et al., 2016; Zainuddin et al., 2019; Syah et al., 2020). Adapun penerapan model klastering regression di area pengelolaan perikanan masih sangat terbatas. Dalam penelitian ini menggunakan fitting dan tuning model GAM, Regressor Random Forest, dan Boosted Regression Tree untuk mendapatkan model dan prediksi yang Goodness of fit, serta menggunakan Model MaxEnt untuk mengklasterisasi area penangkapan ikan di WPP 714.

Tujuan uraian pada bab ini adalah untuk: 1) Mengidentifikasi area penangkapan ikan pelagis yang potensial dengan menggunakan nilai D dalam ECDF serta mengevaluasi pengaruh konsentrasi Chlo-a terhadap aktivitas penangkapan ikan cakalang, madidiang, dan tuna mata besar. 2) Menganalisis pengaruh suhu permukaan laut (SST) terhadap distribusi dan efektivitas penangkapan ikan pelagis, serta menentukan periode musiman yang optimal untuk penangkapan berdasarkan pemetaan ECDF. 3) Meneliti pengaruh kombinasi konsentrasi Chlo-a dan SST terhadap distribusi spasial ikan cakalang, madidiang, dan tuna mata besar, serta mengidentifikasi kondisi lingkungan yang mendukung efektivitas penangkapan. 4) Membandingkan kinerja model Random Forest (RF) dan Boosted Regression Trees (BRT) dalam memprediksi distribusi ikan pelagis berdasarkan variabel lingkungan, serta mengevaluasi sensitivitas spesies terhadap perubahan lingkungan. 5) Mengevaluasi keefektifan model Generalized Additive Model (GAM) dalam memprediksi distribusi ikan pelagis berdasarkan klorofil dan suhu, serta mengidentifikasi faktor dominan yang mempengaruhi aktivitas penangkapan. 6) Menggunakan model GAM untuk menganalisis pengaruh suhu permukaan laut (SST) dan konsentrasi klorofil terhadap penangkapan ikan, serta mengoptimalkan pengelolaan perikanan dengan memperhatikan kondisi lingkungan yang relevan. 7)



Menganalisis distribusi spasial ikan cakalang di Laut Banda dengan mempertimbangkan pengaruh SST dan Chlo-a, serta mengidentifikasi kondisi optimal yang mendukung pengelolaan perikanan berkelanjutan. 8) Menilai pola distribusi spasial cakalang, madidihang, dan tuna mata besar di Laut Banda dengan menggunakan model MaxEnt, serta mendukung pengelolaan perikanan yang lebih efektif berdasarkan variabilitas lingkungan.

4.2.2 Data

Jenis data satelit yang digunakan terdiri atas: (i) informasi oseanografi berupa SST dan klorofil- a, diambil dari <https://oceancolor.gsfc.nasa.gov/>, dan (ii) salinitas, kedalaman perairan dan arus bersumber dari <https://marine.copernicus.eu/>. Informasi yang digunakan sejak Januari 2010 hingga Desember 2022 (12 tahun). Untuk arus serta salinitas menggunakan data terhitung dari Januari 2016 s. d. Desember 2022 (7 tahun).

Adapun data jumlah tangkapan ikan per hari didapatkan melalui data yang tersedia di Sekretariat Lembaga Pengelola Perikanan (LPP) Unit Pengelola Perikanan WPPNRI 714 di Pelabuhan Perikanan Samudera Kendari, dan Direktorat Jenderal Sumber Daya Ikan (SDI) Kementerian Kelautan dan Perikanan.

4.2.3 Metode Penelitian

4.2.3.1 Klasterisasi nilai D ECDF untuk penentuan lokasi tangkapan ikan

Metode ECDF digunakan untuk mengklasifikasikan konsentrasi Chlorophyll-a (Chlo-a) dan Sea Surface Temperature (SST) guna mengidentifikasi area dengan potensi tinggi untuk aktivitas feeding ikan pelagis. Nilai D dalam ECDF dihitung sebagai perbedaan maksimum antara distribusi kumulatif empiris dengan distribusi referensi, yang mencerminkan tingkat kesesuaian suatu area terhadap kondisi optimal bagi feeding ikan pelagis. Semakin tinggi nilai D, semakin besar potensi suatu area sebagai lokasi feeding yang optimal, karena menunjukkan kombinasi lingkungan yang paling mendukung. Metode ini memungkinkan pemetaan zona potensial perikanan secara lebih akurat dan berbasis data empiris tanpa asumsi distribusi tertentu.

4.2.3.2 Generalized Additive Model (GAM) dan Empirical Cumulative Distribution Functions (ECDF) untuk Faktor-Faktor Oseanografis

Faktor-faktor oseanografi yang menjadi input model GAM dalam penelitian ini adalah Chlo-a, SST dan salinitas. Hastie and Tibshirani (1986) mengemukakan Model GAM sebagai berikut:

$$g(\mu(x)) = \eta(x) = \alpha + \sum_{i=1}^p f_i(x_i)$$



13) menyatakan bahwa fungsi hubungan dinyatakan dengan g , diktor oseanografi dinyatakan dengan x (Chlo-a dan SST). atakan dengan $\eta(x)$, μ merupakan respons rata-rata variabel,

konstanta perpotongan (intersep) dinyatakan dengan α , jumlah parameter pemodelan dinyatakan dengan p , dan f merupakan fungsi non-parametrik yang ke- i . Keunggulan model ini adalah dapat menggambarkan tingkat faktor-faktor oseanografi optimum, yakni hasil tangkapan diprediksi lebih besar.

Untuk menentukan kisaran faktor oseanografi yang signifikan terhadap tingkat hasil tangkapan ikan di atas rata-rata, maka digunakan analisis ECDF. Andrade dan Garcia (1999) juga Zainuddin et al. (2008) menggunakan tiga fungsi:

$$f(t) = \frac{1}{n} \sum_{i=1}^n l(x_i)$$

dengan fungsi indikator

$$l(x_i) = \begin{cases} 1, & \text{jika } x_i \leq t \\ 0, & \text{sebaliknya} \end{cases}$$

$$g(t) = \frac{1}{n} \sum_{i=1}^n \frac{y_i}{\bar{y}} l(x_i)$$

$$D(t) = \max |f(t) - g(t)|$$

Distribusi kumulatif $f(t)$ dinyatakan sebagai fungsi distribusi frekuensi kumulatif empiris dari parameter oseanografis, sementara $g(t)$ dinyatakan sebagai fungsi distribusi kumulatif hasil tangkapan (CPUE di atas rata-rata) yang dibobotkan. Fungsi indikator $l(x_i)$ memberikan nilai 1 jika ada nilai parameter oseanografis (seperti Chlo-a dan SST) yang berada di bawah atau sama dengan ambang batas t , dan nilai 0 jika sebaliknya. Selisih absolut maksimum antara $f(t)$ dan $g(t)$ untuk setiap nilai parameter dianalisis menggunakan metode Kolmogorov-Smirnov untuk menentukan signifikansi statistik. Jumlah observasi parameter oseanografis dinyatakan dengan n , nilai masing-masing parameter oseanografis (misalnya Chlo-a dan SST) dinyatakan dengan x_i , dan nilai tangkapan ikan dinyatakan dengan y_i . Observasi dimulai dari nilai terendah hingga tertinggi pada parameter oseanografis. Parameter $\bar{y}$ adalah nilai rata-rata CPUE keseluruhan dari seluruh pengamatan. Label "max" menunjukkan nilai maksimum dari data observasi Chlo-a atau SST yang menghasilkan perbedaan terbesar antara dua kurva $f(t)$ dan $g(t)$.

4.2.3.3 Model Melalui Random Forest

Random forest (Breiman, 2001) adalah metode ansambel, yang berarti didasarkan pada penggabungan beberapa model prediksi. Dalam hal ini, ini adalah kombinasi dari beberapa pohon keputusan, yang dibangun menggunakan subset data yang berbeda. Setiap pohon dipasang ke sampel bootstrap dari data (prosedur yang dikenal sebagai bagging), dan pada setiap pemisahan hanya subset acak dari variabel penjelas yang digunakan. Prediksi dari pohon-pohon ini kemudian dirata-rata untuk mendapatkan prediksi tunggal. Sementara masing-masing pohon cenderung memiliki kinerja yang agak buruk, random forest itu lebih baik daripada satu pohon keputusan yang menggunakan semua variabel.



Random forest memiliki parameter yang disebut 'mtry' yang menentukan jumlah variabel penjelas yang dipilih secara acak. Sebagai aturan praktis, 'mtry'

mendekati $\sqrt{p}$, di mana p adalah jumlah variabel penjelas dalam data, biasanya merupakan pilihan yang baik. Saat mencoba menemukan pilihan terbaik untuk 'mtry'. Random forest memiliki ukuran kepentingan variabel bawaan, yang didasarkan pada pengukuran seberapa jauh lebih buruk model ketika nilai setiap variabel diubah (Thulin, 2021).

Random forest selain digunakan untuk classifier, juga digunakan untuk regressor. Sebagai regressor, random forest digunakan untuk memperluas 'tree', sehingga masing-masing daun mempunyai tepat satu nilai. Breiman (2001) merekomendasikan regresi random forest melalui perluasan pohon secara acak.

4.2.3.4 Model Melalui Boosted Regression Tree (BRT)

Random forest dan decision tree adalah dua tipe algoritma supervised learning yang berbeda. Namun, random forest dapat memprediksi hasil dengan menggunakan decision tree yang memiliki keterkaitan (<https://algoritma.2022>). BRT adalah metode yang algoritma regression tree dan boosting (Hastie, Leathwick, & Elith, 2008).

Untuk membangun model BRT, langkah pertama adalah menginstal dan mengaktifkan library penting seperti gbm untuk fitting model gradient boosting dan caret untuk persiapan data (Friedman, 2001). Setelah library diinstal, data diimpor dari file CSV menggunakan fungsi read.csv, kemudian dilakukan eksplorasi awal dengan melihat beberapa baris pertama data, menampilkan ringkasan statistik, dan memeriksa dimensi dataset (Hastie et al., 2009). Dalam studi ini, variabel target yang dianalisis adalah CPUE, yang menggambarkan produktivitas penangkapan ikan. Sementara itu, variabel prediktor yang digunakan adalah parameter oseanografi, yaitu konsentrasi Chlo-a dan SST.

Langkah selanjutnya adalah membagi data menjadi dua bagian, yaitu data pelatihan (80%) dan data pengujian (20%), yang dilakukan menggunakan fungsi createDataPartition dari library caret. Data pelatihan digunakan untuk membangun model, sementara data pengujian digunakan untuk mengevaluasi akurasi model (Kuhn & Johnson, 2013).

Model BRT kemudian dibangun menggunakan fungsi gbm dengan parameter seperti distribusi data gaussian, shrinkage sebesar 0.01, jumlah pohon sebanyak 500, validasi silang 10-fold, dan minimum 10 observasi di setiap node. Setelah model dibuat, hasilnya dianalisis untuk memahami pentingnya variabel oseanografi seperti Chlo-a dan SST dalam memprediksi CPUE (Friedman, 2001). Model ini kemudian digunakan untuk membuat prediksi pada data pengujian, di mana hasil prediksi dibandingkan dengan data aktual untuk mengukur akurasi. Akurasi model dihitung menggunakan Root Mean Square Error (RMSE), yang menunjukkan seberapa dekat prediksi dengan data aktual, dan koefisien determinasi (R-squared), yang mengevaluasi kualitas model dalam menjelaskan variabilitas data (Elith et al., 2008).



Hasil prediksi divisualisasikan untuk membandingkan data aktual. Visualisasi ini biasanya dilakukan dengan menggunakan grafik untuk menunjukkan hubungan antara hasil model dan nilai aktual, garis untuk menunjukkan tren prediksi (Hastie et al., 2009).

Dengan fokus pada CPUE sebagai variabel target dan parameter oseanografi sebagai prediktor, proses ini memberikan wawasan menyeluruh tentang hubungan antara lingkungan laut dan produktivitas penangkapan ikan.

4.2.3.5 Klaster Model Melalui Maximun Entropy (MaxEnt)

Model machine learning, MaxEnt (Philips et al., 2006) sejauh ini dianggap sebagai model yang terbaik dan paling umum digunakan dalam memodelkan distribusi spesies (DBPEE KLHK, 2021). Model-model distribusi lainnya yang sering juga digunakan adalah Generalized Linear Model (GLM), yang kemudian dikembangkan menjadi GAM (Guisan et al., 2002). Beberapa model regresi fleksibel non-parametrik dari model machine learning adalah ANN, RF, BRT, SVM, termasuk MaxEnt (DBPEE KLHK, 2021).

Pemodelan Maximum Entropy pada bagian ini digunakan untuk melihat distribusi spesies (ikan madidihang) dan sebaran faktor-faktor lingkungannya, dalam hal ini Chlo-a, SST, arus, salinitas, dan kedalaman. Melalui model distribusi spesies MaxEnt ini, akan ditelaah kesesuaiannya menjadi klaster untuk area penangkapan ikan di WPP 714.

Data yang dibutuhkan untuk pemodelan menggunakan MaxEnt adalah data keberadaan spesies (presence only) dan variabel lingkungan dalam format raster (background). Data keberadaan spesies disimpan dalam format .csv yang terdiri dari 3 kolom: nama spesies, koordinat X, dan koordinat Y. Dalam satu kali 'run', dapat dimodelkan lebih dari satu spesies. Sistem koordinat data spesies dan lingkungan harus sama, misalnya keduanya UTM atau keduanya geographic CRS. Data tersebut kemudian diinput pada software MaxEnt.

Ada tiga format output untuk model MaxEnt, yakni: (i) raw; berupa model eksponensial MaxEnt, (ii) kumulatif; persentase distribusi MaxEnt dengan nilai raw paling banyak r . Jika ambang kumulatif c , prediksi biner yang dihasilkan memiliki tingkat penghilangan $c\%$ pada sampel yang diambil dari distribusi MaxEnt, dan (iii) logistik; jika c adalah eksponensial dari entropi distribusi maksimum, maka nilai logistik yang sesuai dengan nilai mentah r adalah $c \cdot r / (1 + c \cdot r)$.

Nilai raw merupakan fungsi eksponensial dari variabel lingkungan. Ketiga format output tersebut memiliki skala dan interpretasi yang berbeda. Output bawaannya (default) adalah logistik, berkisar antara 0 dan 1 probabilitas presensi. Penilaian kecocokan (model fit), menggunakan area di bawah kurva (AUC) (Phillips et al., 2006). Nilai raw merupakan output utama MaxEnt yang dapat diolah melalui Sistem Informasi Geografis (SIG) (Hidayat & Febriani, 2021).

Model MaxEnt digunakan untuk memprediksi distribusi ikan cakalang, madidihang, dan tuna mata besar di wilayah penelitian berdasarkan hubungan antara presensi spesies dan parameter lingkungan. Model ini menghasilkan nilai prediksi kumulatif untuk setiap titik, yang dinyatakan dengan rumus:

$$P_i = f(X_1, X_2, \dots, X_n),$$

di mana P_i adalah nilai prediksi untuk titik i , dan $X_1, X_2, \dots, X_n$ adalah variabel Chlo-a dan SST. MaxEnt telah diakui sebagai metode yang n memprediksi distribusi spesies berdasarkan data presensi, a absensi sulit diperoleh, karena model ini memaksimalkan g hasilkan distribusi yang paling seragam, terkecuali jika



dipengaruhi oleh data lingkungan yang tersedia (Phillips et al., 2006).

Data prediksi dibagi menjadi dua subset: data uji (P_{test}) dan data latih (P_{train}), masing-masing dinyatakan sebagai:

$$P_{test} = \{P_i : i \in \text{test set}\},$$

dan

$$P_{train} = \{P_i : i \in \text{train set}\}.$$

Selain itu, data background ($P_{background}$) yang merepresentasikan distribusi acak digunakan sebagai pembanding, dinyatakan dengan:

$$P_{background} = \{P_j : j \in \text{background points}\}.$$

Semua prediksi digabungkan dalam:

$$P_{combined} = P_{test} \cup P_{background},$$

dan setiap data diberi label 1 untuk presensi ($i \in P_{test}$) dan 0 untuk background ($i \in P_{background}$) (Elith et al., 2011).

Untuk mengevaluasi kinerja model dalam memprediksi distribusi spesies, kurva ROC dibuat berdasarkan True Positive Rate (TPR) dan False Positive Rate (FPR). TPR dihitung dengan rumus:

$$TPR = TP / (TP + FN),$$

di mana TP adalah jumlah prediksi presensi yang benar, dan FN adalah jumlah presensi aktual yang tidak terdeteksi. Sementara itu, FPR dihitung dengan:

$$FPR = FP / (FP + TN),$$

di mana FP adalah jumlah prediksi background yang salah sebagai presensi, dan TN adalah jumlah background yang benar terdeteksi. Kurva ROC menggambarkan hubungan antara TPR dan FPR pada berbagai threshold prediksi P_i (Fawcett, 2006).

Kinerja keseluruhan model diukur menggunakan Area Under Curve (AUC), yang didefinisikan sebagai:

$$AUC = \int_0^1 TPR(FPR) d(FPR).$$

Nilai AUC yang mendekati 1 menunjukkan bahwa model sangat baik dalam membedakan antara presensi dan background. Dalam konteks ini, model MaxEnt menunjukkan bahwa parameter lingkungan seperti Chlo-a dan SST memainkan peran penting dalam menentukan distribusi cakalang, madidihang, dan tuna mata besar. Hal ini konsisten dengan studi sebelumnya yang menunjukkan bahwa SST dan Chlo-a sangat menentukan pola distribusi spesies pelagis di perairan tropis (Zainuddin et al., 2023).

4.3. Hasil Penelitian

4.3.1 Klasterisasi area penangkapan ikan di WPP 714

4.3.1.1 Chlo-a

4.3.1.1.1 Ikan cakalang



asi optimal penangkapan ikan cakalang di WPP 714 dapat arkan nilai D, dengan membaginya dalam 4 kuartil sebagai

128 - 0.0170 (Sangat Baik); kategori ini mencakup nilai

parameter tertinggi, berada di atas kuartil 3 hingga nilai maksimum. Asosiasi terhadap CPUE pada kategori ini sangat kuat, menunjukkan area dengan potensi feeding yang sangat optimal. Kondisi lingkungan di area ini sangat mendukung aktivitas mencari makan bagi ikan Cakalang. Daerah dengan nilai parameter dalam kategori ini sangat mungkin menjadi hotspot bagi aktivitas perikanan.


2. Kategori 2: 0.00851 - 0.0128 (Baik); pada kategori ini, nilai parameter menunjukkan kondisi lingkungan yang semakin baik, dengan asosiasi yang lebih kuat terhadap CPUE. Area dengan nilai parameter dalam kategori ini diharapkan memiliki potensi feeding yang cukup tinggi. Secara statistik, nilai parameter berada di atas kuartil 2 hingga kuartil 3, menunjukkan kondisi lingkungan yang baik untuk mendukung aktivitas feeding ikan cakalang.
3. Kategori 3: 0.00425 - 0.00851 (Cukup Baik); kategori ini mencakup nilai parameter yang berada di atas kuartil 1 hingga kuartil 2. Meskipun kondisi lingkungan dalam kategori ini lebih baik dibandingkan kategori keempat, asosiasinya terhadap CPUE masih tergolong cukup. Artinya, area dengan nilai parameter dalam kisaran ini masih mendukung aktivitas feeding, namun tingkat keberhasilannya belum optimal.
4. Kategori 4: 0 - 0.00425 (Kurang Baik); pada kategori ini, nilai parameter berada dalam kisaran yang sangat rendah, dengan karakteristik asosiasi yang lemah terhadap CPUE. Area dengan nilai parameter di kisaran ini memiliki tingkat keberhasilan penangkapan yang rendah karena kondisi lingkungan yang kurang optimal untuk aktivitas feeding. Secara statistik, kategori ini mencakup nilai dari maksimum hingga kuartil 4 pada distribusi data.

Pembagian kategori di atas menunjukkan pengelompokan parameter lingkungan berdasarkan distribusi data empiris yang diperoleh menggunakan ECDF. Dengan pemahaman ini, pemetaan aktivitas makan ikan dapat dilakukan dengan lebih akurat untuk mengidentifikasi daerah-daerah yang memiliki potensi tinggi untuk kegiatan penangkapan ikan, khususnya di wilayah dengan nilai parameter lingkungan yang termasuk dalam kategori "Baik" dan "Sangat Baik." Pemetaan ini diharapkan dapat meningkatkan efisiensi penangkapan ikan dan mendukung pengelolaan perikanan yang lebih berkelanjutan di Wilayah Pengelolaan Perikanan (WPP) 714 (Hu et al., 2023).

Hasil subset terhadap kriteria-kriteria di atas menunjukkan bahwa nilai terendah, sedang, dan tertinggi Chlo-a pada kategori 1, berturut-turut adalah 0.178, 0.249, dan 0.280 (mg/m^3) dengan nilai 'D_CakalangChlo' berturut-turut adalah 0.0128, 0.0149, dan 0.0169. Nilai terendah, sedang, dan tertinggi Chlo-a pada kategori 2, berturut-turut adalah 0.171, 0.234, dan 0.269 (mg/m^3) dengan nilai 'D_CakalangChlo' berturut-turut adalah 0.00851, 0.0108, dan 0.0127. Pada kategori 3, berturut-turut adalah 0.163, 0.223, dan 0.639 (mg/m^3) dengan nilai 'D_CakalangChlo' berturut-turut adalah 0.00425, 0.00578, dan 0.00850. Adapun pada kategori 4 berturut-turut adalah 0.159, 0.528, dan 16.708 (mg/m^3) dengan nilai 'D_CakalangChlo' berturut-turut adalah 0.00425, 0.00160, dan 0.000.

antara nilai Chlo-a dan 'D_CakalangChlo' di atas ditunjukkan berikut.





Gambar 4.1 Hubungan antara Chlo-a dan 'D_CakalangChlo' untuk semua kategori

4.3.1.1.2 Ikan madidihiang


Potensi lokasi optimal penangkapan ikan madidihiang di WPP 714 dapat diklasifikasi berdasarkan nilai D pada Chlo-a, dengan membaginya dalam 4 kuartil ditunjukkan pada kategori berikut:

1. Kategori 1: 0.0273 - 0.0365 (Sangat Baik); rentang ini mencakup nilai parameter tertinggi yang terletak di atas kuartil ketiga hingga mencapai nilai maksimum. Terdapat hubungan yang sangat erat antara kategori ini dan CPUE, yang menandakan daerah dengan kondisi optimal untuk aktivitas feeding. Lingkungan di area ini sangat ideal untuk ikan Madidihiang dalam mencari makan. Daerah dengan nilai parameter pada kategori ini memiliki peluang besar untuk menjadi lokasi utama dalam aktivitas penangkapan ikan.
2. Kategori 2: 0.01823 - 0.0273 (Baik); kategori ini mencakup wilayah dengan nilai parameter yang mengindikasikan kondisi lingkungan yang semakin optimal, disertai korelasi yang lebih kuat dengan nilai CPUE. Area dalam rentang nilai ini diantisipasi memiliki potensi feeding yang relatif tinggi. Secara statistik, parameter ini berada di antara kuartil kedua dan ketiga, menunjukkan bahwa lingkungan tersebut cukup mendukung aktivitas feeding bagi spesies ikan madidihiang.
3. Kategori 3: 0.00911 - 0.0182 (Cukup Baik); kategori ini mencakup wilayah dengan nilai parameter yang terletak di antara kuartil pertama dan kuartil kedua. Walaupun kondisi lingkungan pada kategori ini lebih menguntungkan dibandingkan dengan kategori keempat, hubungan dengan CPUE masih rata. Dengan kata lain, area dengan nilai parameter dalam kategori ini mendukung aktivitas feeding, namun tingkat keberhasilannya level yang optimal.



4. Kategori 4: 0 - 0.00911 (Kurang Baik); kategori ini mencakup nilai parameter yang berada pada tingkat yang sangat rendah, menunjukkan korelasi yang minimal dengan CPUE. Area dengan parameter dalam rentang ini umumnya memiliki tingkat keberhasilan penangkapan yang rendah karena kondisi lingkungannya kurang mendukung untuk aktivitas feeding. Secara statistik, kategori ini meliputi nilai dari titik maksimum hingga kuartil 4 dalam distribusi data.

Hasil subset terhadap kriteria-kriteria di atas menunjukkan bahwa nilai terendah, sedang, dan tertinggi nilai Chlo-a pada kategori 1, berturut-turut adalah 0.196, 0.211, dan 0.242 (mg/m^3) dengan nilai 'D_MadidihangChlo' berturut-turut adalah 0.0365, 0.0313, dan 0.0273. Nilai terendah, sedang, dan tertinggi Chlo-a pada kategori 2, berturut-turut adalah 0.156, 0.162, dan 0.176 (mg/m^3) dengan nilai 'D_MadidihangChlo' berturut-turut adalah 0.0182, 0.0239, dan 0.0273. Pada kategori 3, nilai terendah, sedang, dan tertinggi Chlo-a, berturut-turut adalah 0.145, 0.312, dan 0.332 (mg/m^3) dengan nilai 'D_MadidihangChlo' berturut-turut adalah 0.0182, 0.0130, dan 0.00912. Adapun pada kategori 4, nilai terendah, sedang, dan tertinggi Chlo-a, berturut-turut adalah 0.323, 0.438, dan 16.708 (mg/m^3) dengan nilai 'D_MadidihangChlo' berturut-turut adalah 0.00911, 0.00678, dan 0.00. Hubungan antara nilai Chlo-a dan 'D_MadidihangChlo' di atas ditunjukkan pada Gambar 4.2 berikut.



Gambar 4.2 Hubungan antara Chlo-a dan 'D_MadidihangChlo' untuk semua kategori



mata besar

asi optimal penangkapan ikan tunamatabesar di WPP 714
lasarkan nilai D pada Chlo-a, dengan membaginya dalam 4

kuartil ditunjukkan pada kategori berikut:


1. Kategori 1: 0.0168 - 0.0223 (Sangat Baik); kategori ini mencakup nilai parameter tertinggi, berada di atas kuartil 3 hingga nilai maksimum. Asosiasi terhadap CPUE pada kategori ini sangat kuat, menunjukkan area dengan potensi feeding yang sangat optimal. Kondisi lingkungan di area ini sangat mendukung aktivitas mencari makan bagi ikan pelagis seperti Cakalang, Madidihang, dan Tuna Mata Besar. Daerah dengan nilai parameter dalam kategori ini sangat mungkin menjadi hotspot bagi aktivitas perikanan.
2. Kategori 2: 0.0112 - 0.0168 (Baik); pada kategori ini, nilai parameter menunjukkan kondisi lingkungan yang semakin baik, dengan asosiasi yang lebih kuat terhadap CPUE. Area dengan nilai parameter dalam kategori ini diharapkan memiliki potensi feeding yang cukup tinggi. Secara statistik, nilai parameter berada di atas kuartil 2 hingga kuartil 3, menunjukkan kondisi lingkungan yang baik untuk mendukung aktivitas feeding ikan pelagis.
3. Kategori 3: 0.00559 - 0.0112 (Cukup Baik); kategori ini mencakup nilai parameter yang berada di atas kuartil 1 hingga kuartil 2. Meskipun kondisi lingkungan dalam kategori ini lebih baik dibandingkan kategori keempat, asosiasinya terhadap CPUE masih tergolong cukup. Artinya, area dengan nilai parameter dalam kisaran ini mungkin masih mendukung aktivitas feeding, namun tingkat keberhasilannya belum optimal.
4. Kategori 4: 0 - 0.00559 (Kurang Baik); pada kategori ini, nilai parameter berada dalam kisaran yang sangat rendah, dengan karakteristik asosiasi yang lemah terhadap CPUE. Area dengan nilai parameter di kisaran ini memiliki tingkat keberhasilan penangkapan yang rendah karena kondisi lingkungan yang kurang optimal untuk aktivitas feeding. Secara statistik, kategori ini mencakup nilai dari minimum hingga kuartil 1 pada distribusi data.

Pembagian kategori di atas menggambarkan klusterisasi parameter lingkungan berdasarkan distribusi data empiris yang diukur melalui ECDF. Dengan pemahaman ini, pemetaan feeding dapat lebih akurat dalam menyoroti area yang memiliki potensi tinggi untuk aktivitas penangkapan ikan, terutama di daerah dengan nilai parameter yang termasuk dalam kategori "Baik" dan "Sangat Baik". Pemetaan ini akan berguna untuk meningkatkan efisiensi penangkapan dan membantu pengelolaan perikanan yang lebih berkelanjutan di WPP 714.

Hasil subset terhadap kriteria-kriteria di atas menunjukkan bahwa nilai terendah, sedang, dan tertinggi nilai Chlo-a pada kategori 1, berturut-turut adalah 0.144, 0.130, dan 0.133 (mg/m^3) dengan nilai 'D_TunaMataBesarChlo' berturut-turut adalah 0.0168, 0.0172, dan 0.0183. Nilai terendah, sedang, dan tertinggi Chlo-a pada kategori 2, berturut-turut adalah 0.125, 0.144, dan 0.202 (mg/m^3) dengan nilai 'D_TunaMataBesarChlo' berturut-turut adalah 0.0113, 0.0134, dan 0.0168. Pada kategori 3, nilai terendah, sedang, dan tertinggi Chlo-a, berturut-turut adalah 0.142, 0.163, dan 0.321 (mg/m^3) dengan nilai 'D_TunaMataBesarChlo' berturut-turut adalah 0.00559, 0.00740, dan 0.0112. Adapun pada kategori 4, nilai

dan tertinggi Chlo-a, berturut-turut adalah 0.151, 0.243, dan 0.321 (mg/m^3) dengan nilai 'D_TunaMataBesarChlo' berturut-turut adalah 0.00, 0.00559, dan 0.0112. Gambar 4.3 berikut adalah hubungan antara Chlo-a dan nilai penangkapan tuna mata besar.





Gambar 4.3 Hubungan antara Chlo-a dan 'D_TunaMataBesarChlo' untuk semua kategori

4.3.1.2 SST

4.3.1.2.1 Ikan cakalang

Potensi lokasi optimal penangkapan ikan cakalang di WPP 714 dapat diklasifikasi berdasarkan nilai D pada fungsi ECDF antara SST dan CPUE, dengan membaginya dalam 4 kuartil sebagai berikut:


1. Kategori 1: 0.0265 - 0.0354 (Sangat Baik); kategori ini meliputi nilai parameter tertinggi, yang berada di atas kuartil ketiga hingga mencapai nilai maksimum. Hubungan dengan CPUE dalam kategori ini sangat kuat, menunjukkan wilayah dengan potensi feeding yang sangat tinggi. Kondisi lingkungan di wilayah ini sangat mendukung aktivitas feeding bagi ikan cakalang. Area dengan nilai parameter dalam kategori ini memiliki kemungkinan besar menjadi hotspot utama untuk aktivitas perikanan.
2. Kategori 2: 0.0177 - 0.0265 (Baik); dalam kategori ini, nilai parameter mengindikasikan kondisi lingkungan yang semakin membaik, dengan korelasi yang lebih signifikan terhadap CPUE. Area dengan nilai parameter dalam rentang ini diperkirakan memiliki potensi feeding yang cukup tinggi. Berdasarkan analisis statistik, nilai parameter ini berada antara kuartil kedua dan ketiga, yang menunjukkan kondisi lingkungan yang mendukung aktivitas feeding ikan cakalang.
3. Kategori 3: 0.00885 - 0.0177 (Cukup Baik); kategori ini mencakup parameter yang terletak di antara kuartil pertama dan kuartil kedua. Meskipun kondisi lingkungan dalam kategori ini lebih menguntungkan dibandingkan kategori asosiasi dengan CPUE masih tergolong sedang. Dengan kata lain nilai parameter dalam rentang ini mungkin masih dapat mendukung aktivitas feeding, namun keberhasilannya belum sepenuhnya



4. Kategori 4: 0 - 0.00885 (Kurang Baik); kategori ini meliputi nilai parameter pada kisaran yang sangat rendah, dengan hubungan yang lemah terhadap CPUE. Wilayah dengan parameter di rentang ini memiliki kemungkinan rendah untuk berhasil dalam penangkapan karena kondisi lingkungannya kurang mendukung aktivitas feeding. Secara statistik, kategori ini mencakup nilai dari minimum hingga kuartil pertama dalam distribusi data.

Klasifikasi kategori yang disajikan di atas merefleksikan pengelompokan parameter lingkungan menggunakan distribusi data empiris yang dianalisis melalui ECDF. Dengan pendekatan ini, pemetaan lokasi makan ikan dapat dilakukan dengan lebih tepat untuk mengidentifikasi wilayah dengan potensi tinggi untuk aktivitas penangkapan ikan, khususnya di area yang memiliki parameter lingkungan dalam kategori "Sangat Baik" dan "Baik."

Pada kategori 1, nilai terendah, sedang, dan tertinggi (SST), berturut-turut adalah 30.570, 30.724, dan 30.997 ($^{\circ}\text{C}$). Nilai terendah, sedang, dan tertinggi SST pada penangkapan ikan cakalang kategori 2, berturut-turut adalah 28.276, 30.000, dan 30.998 ($^{\circ}\text{C}$) dengan nilai 'D_CakalangSST' berturut-turut adalah 0.0177, 0.0204, dan 0.0265. Pada kategori 2, nilai terendah, sedang, dan tertinggi (SST), berturut-turut adalah 28.488, 29.000, dan 31.051 ($^{\circ}\text{C}$). Adapun pada kategori 4, nilai terendah, sedang, dan tertinggi SST, berturut-turut adalah 31.073, 31.457, dan 32.000 ($^{\circ}\text{C}$) dengan nilai 'D_CakalangSST' berturut-turut adalah 0.00, 0.00413, dan 0.00883. Gambar 4.4 berikut adalah hubungan antara SST dan nilai D ECDF pada penangkapan cakalang.



Gambar 4.4 Hubungan antara SST dan 'D_CakalangSST' untuk semua kategori




dihang

asi terbaik untuk penangkapan ikan madidihiang di WPP 714 dengan menggunakan nilai D, yang dikelompokkan ke dalam 4 ut:

1. Kategori 1: 0.0272 - 0.0363 (Sangat Baik); kategori ini mencakup rentang nilai parameter tertinggi, yaitu di atas kuartil ketiga hingga mencapai nilai maksimum. Terdapat korelasi yang sangat kuat dengan CPUE dalam kategori ini, yang mengindikasikan area dengan potensi feeding yang sangat optimal. Kondisi lingkungan di daerah ini sangat mendukung aktivitas mencari makan bagi ikan pelagis seperti madidihiang, cakalang, dan tuna mata besar. Area dengan parameter dalam rentang ini kemungkinan besar menjadi hotspot utama untuk aktivitas perikanan.
2. Kategori 2: 0.0181 - 0.0272 (Baik); kategori ini meliputi nilai parameter yang menunjukkan perbaikan dalam kondisi lingkungan, dengan hubungan yang lebih kuat terhadap CPUE. Lokasi dengan parameter dalam kisaran ini diperkirakan memiliki potensi feeding yang cukup tinggi. Dari perspektif statistik, nilai ini berada di antara kuartil kedua dan ketiga, menandakan bahwa kondisi lingkungannya cukup baik untuk mendukung aktivitas feeding ikan pelagis.
3. Kategori 3: 0.00906 - 0.0181 (Cukup Baik); kategori ini meliputi nilai parameter yang berada di antara kuartil pertama dan kedua. Walaupun kondisi lingkungan dalam kategori ini lebih baik dibandingkan kategori pertama, tingkat korelasinya dengan CPUE masih dalam kategori sedang. Dengan kata lain, area dengan nilai parameter di kisaran ini masih mungkin mendukung aktivitas feeding, tetapi keberhasilannya tidak sepenuhnya optimal.
4. Kategori 4: 0 - 0.00906 (Kurang Baik); kategori ini meliputi nilai parameter yang sangat rendah, dengan hubungan yang lemah terhadap CPUE. Wilayah dengan nilai parameter di rentang ini cenderung memiliki tingkat keberhasilan penangkapan yang rendah karena kondisi lingkungannya kurang ideal untuk aktivitas feeding. Secara statistik, kategori ini mencakup rentang dari nilai minimum hingga kuartil pertama dalam distribusi data.

Hasil subset terhadap kriteria-kriteria di atas menunjukkan bahwa nilai terendah, sedang, dan tertinggi SST pada penangkapan ikan madidihiang kategori 1, berturut-turut adalah 28.527, 28.725, dan 28.841 (°C) dengan nilai D_MadidihiangSST berturut-turut adalah 0.0272, 0.0306, dan 0.0345. Nilai terendah, sedang, dan tertinggi SST pada penangkapan ikan madidihiang kategori 2, berturut-turut adalah 28.528, 29.000, dan 29.079 (°C) dengan nilai D_MadidihiangSST berturut-turut adalah 0.0182, 0.0218, dan 0.0272. Pada kategori 3, nilai terendah, sedang, dan tertinggi SST, berturut-turut adalah 26.927, 29.081, dan 29.289 (°C) dengan nilai D_MadidihiangSST berturut-turut adalah 0.00908, 0.0126, dan 0.0181. Adapun pada kategori 4, nilai terendah, sedang, dan tertinggi SST, berturut-turut adalah 29.386, 30.000, dan 32.654 (°C) dengan nilai D_MadidihiangSST berturut-turut adalah 0.00, 0.00634, dan 0.00905. Gambar 4.5 berikut adalah hubungan antara SST dan nilai D ECDF pada penangkapan madidihiang.





Gambar 4.5 Hubungan antara SST dan 'D_MadidihangSST' untuk semua kategori

4.3.1.1.3 Ikan tuna mata besar


Potensi lokasi optimal penangkapan ikan Tuna Mata Besar di Wilayah Pengelolaan Perikanan (WPP) 714 dapat dikategorikan berdasarkan nilai D yang dibagi menjadi empat kuartil sebagai berikut:

1. Kategori 1: 0.0741 - 0.0988 (Sangat Baik); kategori ini mencakup nilai parameter tertinggi, berada di atas kuartil 3 hingga nilai maksimum. Hubungannya dengan CPUE sangat kuat, menandakan area ini memiliki potensi feeding yang sangat optimal.
2. Kategori 2: 0.0494 - 0.0741 (Baik); dalam kategori ini, nilai parameter menunjukkan kondisi lingkungan yang baik dengan korelasi yang kuat terhadap CPUE. Area dengan nilai parameter dalam kategori ini diharapkan memiliki potensi feeding yang tinggi.
3. Kategori 3: 0.0247 - 0.0494 (Cukup Baik); kategori ini mencakup nilai parameter yang berada di atas kuartil 1 hingga kuartil 2. Meskipun lebih baik daripada kategori "Kurang Baik", asosiasi terhadap CPUE masih cukup memadai.
4. Kategori 4: 0 - 0.0247 (Kurang Baik); dalam kategori ini, nilai parameter sangat rendah dengan korelasi lemah terhadap CPUE. Area dengan nilai parameter di kisaran ini memiliki tingkat keberhasilan penangkapan yang rendah karena kondisi lingkungan yang kurang mendukung aktivitas feeding.

Hasil subset terhadap kriteria-kriteria di atas menunjukkan bahwa nilai dan tertinggi SST pada penangkapan ikan tuna mata besar -turut adalah 29.372, 29.528, dan 29.639 (°C) dengan nilai SST' berturut-turut adalah 0.0741, 0.0838, dan 0.0897. at data, nilai terendah, sedang, dan tertinggi SST pada



penangkapan ikan tuna mata besar kategori 2 berturut-turut adalah 28.589, 29.000, dan 29.915 (°C). Nilai 'D_TunaMataBesarSST' yang terkait dengan masing-masing suhu tersebut adalah 0.0494, 0.0565, dan 0.0740. Subset ini menunjukkan variasi SST dalam kategori tersebut yang dapat berpengaruh terhadap nilai D fungsi ECDF dalam penangkapan ikan tuna mata besar di WPP 714. Pada kategori 3, nilai terendah, sedang, dan tertinggi SST, berturut-turut adalah 27.000, 28.585, dan 30.660 (°C) dengan nilai 'D_TunaMataBesarSST' berturut-turut adalah 0.0247, 0.0368, dan 0.0492. Hal ini menunjukkan bahwa terdapat variasi nilai D_TunaMataBesarSST yang signifikan pada berbagai SST, yang terkait dengan distribusi dan kelimpahan ikan tuna mata besar di WPP 714. Adapun pada kategori 4, nilai terendah, sedang, dan tertinggi SST pada penangkapan ikan tuna mata besar, berturut-turut adalah 30.630, 30.000, dan 32.654 (°C) dengan nilai 'D_TunaMataBesarSST' berturut-turut adalah 0.00, 0.00470, dan 0.0247. Gambar 4.6 berikut adalah hubungan antara SST dan nilai D ECDF pada penangkapan tuna mata besar.



Gambar 4.6 Hubungan antara SST dan 'D_TunaMataBesarSST' untuk semua kategori

4.3.2 Fitting model RF pada CPUE – factor oseanografis

4.3.2.1 Ikan cakalang

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
model_rf <- randomForest(CPUE ~ Chlo + SST, data = CakalangCatch_ChloSST)
```

Hasil model RF tersebut ditunjukkan sebagai berikut:



```
ula = CPUE ~ Chlo + SST, data = CakalangCatch_ChloSST)
e of random forest: regression
Number of trees: 500
```

No. of variables tried at each split: 1

Mean of squared residuals: 79862.31
% Var explained: 2.31

Model Random Forest yang di atas adalah untuk regresi, yang berarti variabel target 'CPUE' adalah numerik dan memprediksi nilai kontinu darinya. Model ini dibangun dengan menggunakan 500 pohon. Lebih banyak pohon biasanya menghasilkan prediksi yang lebih baik tetapi membutuhkan lebih banyak waktu komputasi.

Dalam model ini, satu variabel dipertimbangkan untuk setiap pemisahan di setiap pohon. Rata-rata dari kuadrat residu dalam model ini adalah 79862.31. Residu adalah perbedaan antara nilai yang diamati dan nilai yang diprediksi oleh model, sehingga ini adalah ukuran kesalahan model. Model ini menjelaskan sekitar 2.31% dari variabilitas dalam variabel target 'CPUE', yang merupakan persentase varians yang dijelaskan oleh model.

Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_CakalangChloSST_without_outlier <- randomForest(CPUE ~ Chlo + SST,  
data = CakalangCatch_ChloSST_without_outlier)
```

Hasil pemodelan tanpa outlier:

```
Call:  
randomForest(formula = CPUE ~ Chlo + SST, data =  
CakalangCatch_ChloSST_without_outlier)  
Type of random forest: regression  
Number of trees: 500  
No. of variables tried at each split: 1  
  
Mean of squared residuals: 3777.232  
% Var explained: 12.7
```


Kontribusi variabel prediktor ditunjukkan sebagai berikut:

	IncNodePurity
Chlo	14637810
SST	9088207

Aspek "IncNodePurity" mengukur peningkatan kebersihan node yang dihasilkan oleh setiap variabel. Dengan kata lain, ini mengukur seberapa baik setiap variabel membagi data menjadi node-node yang lebih murni. Node yang "murni" berarti bahwa data di dalamnya lebih seragam dalam hal variabel target.

Dalam hal ini, Chlo-a (Chlo) memiliki nilai "IncNodePurity" tertinggi, yang berarti variabel ini paling penting dalam memprediksi CPUE menurut model Random Forest. Variabel SST juga penting, tetapi kurang penting dibandingkan Chlo-a. Gambar 4.7 berikut adalah Variabel Importance Plot pada penangkapan cakalang.





Gambar 4.7 Variabel Importance Plot – cakalang

Adapun proses optimasi parameter hiper `mtry` pada model Random Forest (cakalang) dalam menentukan jumlah variabel yang dipilih secara acak pada setiap pemisahan (split) dalam pohon keputusan, sebagai berikut.

```
mtry = 1 OOB error = 3773.415
Searching left ...
Searching right ...
mtry OOBError
1 1 3773.415

mtry = 7 OOB error = 3962.997
Searching left ...
mtry = 6 OOB error = 3965.306
-0.000582704 0.01
Searching right ...
mtry = 2 OOB error = 3952.839
0.002563177 0.01
mtry OOBError
2 2 3952.839
6 6 3965.306
7 7 3962.997
```

Hasil model di atas menunjukkan bahwa pada setiap split dalam pembuatan pohon, hanya satu variabel yang dipertimbangkan. Nilai `mtry` adalah jumlah variabel acak yang dipilih pada setiap split saat membangun pohon.

Nilai OOB error adalah 3,773.415. Ini adalah nilai kesalahan Out-of-Bag (OOB) untuk `mtry = 1`. OOB error adalah metode validasi silang internal untuk setiap pohon dibuat menggunakan sebagian dari sampel dan OOB error dihitung dengan menguji setiap pohon pada digunakan dalam pembuatan pohon tersebut (sampel “out-of-



Adapun Searching left ... dan Searching right ... adalah bagian dari proses pencarian untuk menemukan nilai optimal dari mtry. Algoritma ini mencoba nilai-nilai yang lebih rendah (Searching left) dan lebih tinggi (Searching right) dari nilai mtry saat ini. Tabel pada akhir output menunjukkan nilai mtry yang telah dicoba dan kesalahan OOB yang sesuai. Dalam hal ini, telah dicoba tujuh nilai mtry, nilai 1, memiliki kesalahan OOB terendah 3,773.415. Nilai mtry yang optimal adalah yang memberikan kesalahan OOB terendah. Gambar 4.8 berikut adalah OOB pada SST.

Gambar 4.8 OOB – SST

Grafik di atas menunjukkan bahwa hubungan antara OOB Error dan mtry. Dalam konteks ini, OOB Error adalah metrik yang digunakan dalam model random forest untuk mengukur seberapa baik model tersebut memprediksi data yang tidak pernah dilihat sebelumnya. Sedangkan mtry adalah parameter yang menentukan jumlah variabel yang dipertimbangkan pada setiap split dalam pembuatan pohon keputusan. Dari grafik tersebut nampak bahwa ada satu titik data yang menunjukkan nilai OOB Error paling kecil yakni 3,773.415 ketika mtry adalah 1. Gambar 4.9 berikut adalah Partial Dependence Chlo-a pada penangkapan cakalang.



Gambar 4.9 Partial Dependence Chlo-a (Chlo) – cakalang

Grafik di atas adalah plot dependensi parsial untuk variabel Chlo-a dari model yang tidak ditentukan. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah Chlo-a dan sumbu y adalah 'yhat', yang merupakan prediksi dari model.

Plot ini menunjukkan bagaimana perubahan dalam Chlo-a memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 40 dan 80 saat Chlo-a meningkat dari 0 hingga sekitar 15. Ini menunjukkan bahwa peningkatan Chlo-a memiliki efek fluktuatif pada 'yhat', dengan beberapa puncak dan lembah sebelum stabil di sekitar nilai 80. Ini menunjukkan bahwa nilai Chlo-a yang lebih tinggi memiliki dampak yang lebih besar pada variabel target. Gambar 4.10 berikut adalah Partial Dependence SST pada penangkapan cakalang.



Gambar 4.10 Partial Dependence SST – cakalang

Grafik di atas adalah plot dependensi parsial untuk variabel SST dari model RF. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik tersebut, sumbu x adalah SST dan sumbu y adalah 'yhat', yang merupakan prediksi dari model.

Plot tersebut menunjukkan bagaimana perubahan dalam SST memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 40 dan 80 saat SST meningkat dari 26 hingga sekitar 32. Ini menunjukkan bahwa peningkatan SST memiliki efek fluktuatif pada 'yhat', dengan beberapa puncak dan lembah sebelum stabil di sekitar nilai 40. Ini menunjukkan bahwa nilai SST yang lebih tinggi memiliki dampak yang lebih besar pada variabel target.

4.3.2.2 Ikan Madidihang

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
model_rf <- randomForest(CPUE ~ Chlo + SST, data =  
MadidihangCatch_ChloSST)
```

Adapun hasil model RF tersebut ditunjukkan sebagai berikut:

```
Call:  
randomForest(formula = CPUE ~ Chlo + SST, data = MadidihangCatch_ChloSST)  
Type of random forest: regression  
Number of trees: 500  
ried at each split: 1  
squared residuals: 13331.98  
% Var explained: 7.39
```



Model Random Forest di atas adalah regresi, merupakan variabel target CPUE adalah numerik dan memprediksi nilai kontinu darinya. Model ini dibangun dengan menggunakan 500 pohon. Lebih banyak pohon biasanya menghasilkan prediksi yang lebih baik tetapi membutuhkan lebih banyak waktu komputasi.

Dalam model ini, satu variabel dipertimbangkan untuk setiap pemisahan di setiap pohon. Rata-rata dari kuadrat residu dalam model ini adalah 13,331.98. Residu adalah perbedaan antara nilai yang diamati dan nilai yang diprediksi oleh model, sehingga ini adalah ukuran kesalahan model. Model ini menjelaskan sekitar 7.39% dari variabilitas dalam variabel target CPUE, yang merupakan persentase varians yang dijelaskan oleh model.

Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_MadidihangChloSST_without_outlier <- randomForest(CPUE ~ Chlo + SST, data = MadidihangCatch_ChloSST_without_outlier)
```

Hasil pemodelan tanpa outlier:

```
Call:
randomForest(formula = CPUE ~ Chlo + SST, data = MadidihangCatch_ChloSST_without_outlier)
Type of random forest: regression
Number of trees: 500
No. of variables tried at each split: 1

Mean of squared residuals: 737.2607
% Var explained: 17.35
```


Kontribusi variabel prediktor ditunjukkan sebagai berikut:

	IncNodePurity
Chlo	2698044
SST	1897339

Nilai “IncNodePurity” mengukur peningkatan kebersihan node yang dihasilkan oleh setiap variabel. Dengan kata lain, ini mengukur seberapa baik setiap variabel membagi data menjadi node-node yang lebih murni. Node yang “murni” berarti bahwa data di dalamnya lebih seragam dalam hal variabel target.

Dalam hal ini, Chlo-a memiliki nilai “IncNodePurity” tertinggi, yang berarti variabel ini paling penting dalam memprediksi CPUE menurut model Random Forest. Variabel SST juga penting, tetapi kurang penting dibandingkan Chlo-a. Gambar 4.11 berikut adalah Variabel Importance Plot pada penangkapan madidihang.





Gambar 4.11 Variabel Importance Plot – madidihang

Adapun proses optimasi parameter hiper `mtry` pada model Random Forest (madidihang) dalam menentukan jumlah variabel yang dipilih secara acak pada setiap pemisahan (split) dalam pohon keputusan, sebagai berikut.

```
mtry = 0 OOB error = 737.9694
Searching left ...
mtry = 1 OOB error = 736.9766
0.001345266 0.01
Searching right ...
  mtry OOBError
0      0 737.9694
1      1 736.9766
```

Hasil model di atas menunjukkan bahwa pada setiap split dalam pembuatan pohon, hanya satu variabel yang dipertimbangkan. Nilai `mtry` adalah jumlah variabel acak yang dipilih pada setiap split saat membangun pohon. Nilai OOB error adalah 736.976. Ini adalah nilai kesalahan Out-of-Bag (OOB) untuk `mtry` = 1. OOB error adalah metode validasi silang internal untuk Random Forest. Setiap pohon dibuat menggunakan sebagian dari sampel (bootstrap sample), dan OOB error dihitung dengan menguji setiap pohon pada sampel yang tidak digunakan dalam pembuatan pohon tersebut (sampel “out-of-bag”).

Tabel pada akhir output menunjukkan nilai `mtry` yang telah dicoba dan kesalahan OOB yang sesuai. Dalam hal ini, dua nilai `mtry` yang telah dicoba, yaitu 0 dan 1, dengan kesalahan OOB masing-masing sebesar 737.969 dan 736.977. Nilai `mtry` optimal adalah yang memberikan kesalahan OOB terendah. Nilai optimal adalah OOB SST pada penangkapan madidihang.



Gambar 4.12 OOB – SST

Grafik di atas menunjukkan hubungan antara OOB Error dan mTry. Dalam konteks ini, OOB Error (Out-of-Bag Error) adalah metrik yang digunakan dalam model random forest untuk mengukur seberapa baik model tersebut memprediksi data yang tidak pernah dilihat sebelumnya. Sedangkan mTry adalah parameter yang menentukan jumlah variabel yang dipertimbangkan pada setiap split dalam pembuatan pohon keputusan. Dari grafik tersebut nampak bahwa ada satu titik data yang menunjukkan nilai OOB Error sekitar 737.0 ketika mTry adalah 1. Gambar 4.13 berikut adalah Partial Dependence Chlo-a pada penangkapan madidihang.



Gambar 4.13 Partial Dependence Chlo-a – madidihang

Grafik di atas adalah plot dependensi parsial untuk variabel Chlo-a. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah Chlo-a dan sumbu y adalah 'yhat', yang merupakan prediksi dari model. Plot ini menunjukkan bagaimana perubahan dalam Chlo-a memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 40 dan 80 saat Chlo-a meningkat dari 0 hingga sekitar 15. Ini menunjukkan bahwa peningkatan Chlo-a memiliki efek fluktuatif pada 'yhat', dengan beberapa puncak dan lembah sebelum stabil di sekitar nilai 80. Ini menunjukkan bahwa nilai Chlo-a yang lebih tinggi memiliki dampak yang lebih besar pada variabel target. Gambar 4.14 berikut adalah Partial Dependence SST pada penangkapan madidihang.



Gambar 4.14 Partial Dependence SST – madidihang

Grafik di atas adalah plot dependensi parsial untuk variabel SST dari model RF. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik tersebut, sumbu x adalah SST dan sumbu y adalah 'yhat', yang merupakan prediksi dari model.

Plot tersebut menunjukkan bagaimana perubahan dalam SST memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 20 dan 50 saat SST meningkat dari 26 hingga sekitar 32. Ini menunjukkan bahwa peningkatan SST memiliki efek menurun pada 'yhat', dengan penurunan yang konsisten seiring dengan peningkatan SST. Ini menunjukkan bahwa nilai SST yang lebih tinggi memiliki dampak negatif pada variabel target.

4.3.2.3 Ikan Tuna Mata Besar

Pembuatan model Random Forest dengan menggunakan outlier dibuat sebagai berikut:

```
model_rf <- randomForest(CPUE ~ Chlo + SST, data =  
TunaMataBesarCatch_ChloSST)
```

Adapun hasil model RF tersebut ditunjukkan sebagai berikut:

```
Call:  
randomForest(formula = CPUE ~ Chlo + SST, data =  
TunaMataBesarCatch_ChloSST)  
Type of random forest: regression  
Number of trees: 500  
ried at each split: 1  
  
squared residuals: 3886.253  
% Var explained: 18.89
```



Model Random Forest yang di atas adalah untuk regresi, yang berarti variabel target 'CPUE' adalah numerik dan memprediksi nilai kontinu darinya. Model ini dibangun dengan menggunakan 500 pohon. Lebih banyak pohon biasanya menghasilkan prediksi yang lebih baik tetapi membutuhkan lebih banyak waktu komputasi.

Dalam model ini, satu variabel dipertimbangkan untuk setiap pemisahan di setiap pohon. Rata-rata dari kuadrat residu dalam model ini adalah 3886.253. Residu adalah perbedaan antara nilai yang diamati dan nilai yang diprediksi oleh model, sehingga ini adalah ukuran kesalahan model. Model ini menjelaskan sekitar 18.89% dari variabilitas dalam variabel target 'CPUE', yang merupakan persentase varians yang dijelaskan oleh model.

Untuk pemodelan tanpa menggunakan outlier ditunjukkan sebagai berikut:

```
modelrf_TunaMataBesarChloSST_without_outlier <- randomForest(CPUE ~ Chlo + SST, data = TunaMataBesarCatch_ChloSST_without_outlier)
```

Hasil pemodelan tanpa outlier:

```
Call:
randomForest(formula = CPUE ~ Chlo + SST, data = 
TunaMataBesarCatch_ChloSST_without_outlier)
Type of random forest: regression
Number of trees: 500
No. of variables tried at each split: 1

Mean of squared residuals: 744.7896
% Var explained: 0.53
```


Kontribusi variabel prediktor ditunjukkan sebagai berikut:

	IncNodePurity
Chlo	937364.3
SST	505598.3

Parameter "IncNodePurity" mengukur peningkatan kebersihan node yang dihasilkan oleh setiap variabel. Dengan kata lain, ini mengukur seberapa baik setiap variabel membagi data menjadi node-node yang lebih murni. Node yang "murni" berarti bahwa data di dalamnya lebih seragam dalam hal variabel target.

Dalam hal ini, Chlo-a memiliki nilai "IncNodePurity" tertinggi, yang berarti variabel ini paling penting dalam memprediksi CPUE menurut model Random Forest. Variabel SST juga penting, tetapi kurang penting dibandingkan Chlo-a. Gambar 4.15 berikut adalah Variabel Importance Plot pada penangkapan tuna mata besar.





Gambar 4.15 Variabel Importance Plot – tuna mata besar

Adapun proses optimasi parameter hiper `mtry` pada model Random Forest (tuna mata besar) dalam menentukan jumlah variabel yang dipilih secara acak pada setiap pemisahan (split) dalam pohon keputusan, sebagai berikut.

```
mtry = 0 OOB error = 764.6545
Searching left ...
mtry = 1 OOB error = 745.2969
0.02531543 0.01
Searching right ...
  mtry OOBError
0     0 764.6545
1     1 745.2969
```

Hasil model di atas menunjukkan bahwa pada setiap split dalam pembuatan pohon, hanya satu variabel yang dipertimbangkan. Nilai `mtry` adalah jumlah variabel acak yang dipilih pada setiap split saat membangun pohon.

Nilai OOB error adalah 745.2969. Ini adalah nilai kesalahan Out-of-Bag (OOB) untuk `mtry = 1`. OOB error adalah metode validasi silang internal untuk Random Forest. Setiap pohon dibuat menggunakan sebagian dari sampel (bootstrap sample), dan OOB error dihitung dengan menguji setiap pohon pada sampel yang tidak digunakan dalam pembuatan pohon tersebut (sampel “out-of-bag”).

Searching left ... dan Searching right ... adalah bagian dari proses pencarian untuk menemukan nilai optimal dari `mtry`. Algoritma ini mencoba nilai-nilai yang lebih rendah (Searching left) dan lebih tinggi (Searching right) dari nilai



akhir output menunjukkan nilai `mtry` yang telah dicoba dan yang sesuai. Dalam hal ini, dua nilai `mtry` yang telah dicoba, yaitu kesalahan OOB masing-masing sebesar 764.654 dan 745.297.

Nilai $mtry$ yang optimal adalah yang memberikan kesalahan OOB terendah. Gambar 4.16 berikut adalah OOB SST pada penangkapan tuna mata besar.

Gambar 4.16 OOB – SST

Grafik di atas menunjukkan hubungan antara OOB Error dan $mTry$. Dalam konteks ini, OOB Error (Out-of-Bag Error) adalah metrik yang digunakan dalam model random forest untuk mengukur seberapa baik model tersebut memprediksi data yang tidak pernah dilihat sebelumnya. Sedangkan $mTry$ adalah parameter yang menentukan jumlah variabel yang dipertimbangkan pada setiap split dalam pembuatan pohon keputusan. Dari grafik tersebut nampak bahwa ada satu titik data yang menunjukkan nilai OOB Error sekitar 750 ketika $mTry$ adalah 1. Gambar 4.17 berikut adalah Partial Dependence Chlo-a pada penangkapan tuna mata besar.



Gambar 4.17 Partial Dependence Chlo-a – tuna mata besar

Grafik di atas adalah plot dependensi parsial untuk variabel Chlo-a dari model yang tidak ditentukan. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik ini, sumbu x adalah Chlo-a dan sumbu y adalah 'yhat', yang merupakan prediksi dari model.

Plot ini menunjukkan bagaimana perubahan dalam Chlo-a memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 0 dan sekitar 20 saat Chlo-a meningkat dari 0 hingga sekitar 1, lalu stabil di sekitar nilai 5 setelah Chlo-a lebih dari 1. Ini menunjukkan bahwa peningkatan awal dalam Chlo-a memiliki efek fluktuatif pada 'yhat', tetapi setelah mencapai titik tertentu, dampaknya menjadi konstan. Ini menunjukkan bahwa nilai Chlo-a yang lebih tinggi memiliki dampak yang lebih besar pada variabel target. Gambar 4.18 berikut adalah Partial Dependence SST pada penangkapan tuna mata besar.



Gambar 4.18 Partial Dependence SST – tuna mata besar

Grafik di atas adalah plot dependensi parsial untuk variabel SST dari model RF. Plot dependensi parsial ini digunakan untuk memahami efek variabel tertentu pada prediksi model. Dalam grafik tersebut, sumbu x adalah SST dan sumbu y adalah 'yhat', yang merupakan prediksi dari model.

Plot tersebut menunjukkan bagaimana perubahan dalam SST memengaruhi prediksi model ('yhat'). Nilai 'yhat' berfluktuasi antara 5 dan 15 saat SST meningkat dari 26 hingga sekitar 32. Ini menunjukkan bahwa peningkatan SST memiliki efek fluktuatif pada 'yhat', dengan beberapa puncak dan lembah sebelum stabil di sekitar nilai 5. Ini menunjukkan bahwa nilai SST yang lebih tinggi memiliki dampak yang lebih besar pada variabel target.

4.3.3 Fitting model BRT pada CPUE – factor oseanografis


4.3.3.1 Ikan cakalang

Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtCakalangChloSST_outlier <- gbm(CPUE ~ Chlo + SST,  
    data = CakalangCatch_ChloSST,  
    distribution = "gaussian",  
    n.trees = 100,  
    interaction.depth = 3,  
    shrinkage = 0.01)
```

Output dari model tersebut sebagaimana ditunjukkan pada Gambar 4.19 < BRT relative influence pada penangkapan ikan cakalang.






Gambar 4.19 Grafik relative influence BRT - cakalang (outlier)

Grafik di atas menunjukkan pengaruh relatif dari dua variabel: SST dan Chlo-a. Variabel SST memiliki pengaruh relatif tertinggi, dengan nilai melebihi 50. Ini berarti bahwa variabel SST memiliki pengaruh paling signifikan dalam model. Sedangkan variabel Chlo-a memiliki pengaruh relatif sekitar 40, yang berarti pengaruhnya lebih rendah dibandingkan dengan SST tetapi masih cukup signifikan. Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtCakalangChloSST_outlier <- gbm(CPUE ~ Chlo + SST
                                         + alat_tangkap,
                                         data = CakalangCatch_ChloSST_without_outlier,
                                         distribution = "gaussian",
                                         n.trees = 100,
                                         interaction.depth = 3,
                                         shrinkage = 0.01)
```

Hasil model dengan menggunakan outlier ditunjukkan sebagaimana ditunjukkan pada Gambar 4.20 berikut adalah grafik relative influence pada Model BRT di atas ditunjukkan sebagai berikut.






Gambar 4.20 Grafik relative influence - cakalang tanpa outlier

Grafik ini menunjukkan pengaruh relatif dari dua variabel yang berbeda. Variabel Chlo-a memiliki pengaruh relatif tertinggi, diikuti oleh variabel SST. Variabel Chlo-a memiliki pengaruh relatif tertinggi, dengan nilai mencapai lebih dari 40. Ini berarti bahwa variabel ini memiliki pengaruh paling signifikan dalam model. Variabel SST memiliki pengaruh relatif mendekati 30.

Secara keseluruhan, grafik ini menunjukkan bahwa variabel Chlo-a adalah variabel paling penting dalam model ini, diikuti oleh variabel SST. Untuk memahami seberapa penting variabel Chlo-a dalam model dan bagaimana hubungan antara Chlo-a dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel Chlo-a memengaruhi prediksi model, sebagaimana Gambar 4.21 berikut.






Gambar 4.21 Grafik hubungan variabel Chlo-a dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel Chlo-a dan 'y'. Dari grafik, dapat dilihat bahwa nilai 'y' mengalami penurunan tajam dari sekitar 62 ke 52 ketika Chlo-a berkisar dari 0 hingga sekitar 5. Setelah itu, nilai 'y' tetap konstan pada sekitar 52 meskipun Chlo-a terus meningkat. Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi negatif antara Chlo-a dan 'y' ketika Chlo-a kurang dari 5.

Pada grafik hubungan antara variabel SST dan respons model BRT ditunjukkan sebagaimana Gambar 4.22 berikut.





Gambar 4.22 Grafik hubungan antara variabel SST dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel SST dan 'y'. Dari grafik, kita dapat melihat bahwa nilai 'y' mengalami peningkatan dari sekitar 54 ke sekitar 62 ketika SST meningkat dari 26 ke sekitar 28. Setelah itu, nilai 'y' mengalami fluktuasi dan akhirnya menurun tajam ke sekitar 54 ketika SST mencapai 32. Ini menunjukkan bahwa ada hubungan positif antara SST dan 'y' hingga SST mencapai sekitar 28, setelah itu hubungan tersebut menjadi tidak stabil.


4.3.3.2 Ikan Madidihang

Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtMadidihangChloSST_outlier <- gbm(CPUE ~ Chlo + SST,
  data = MadidihangCatch_ChloSST,
  distribution = "gaussian",
  n.trees = 100,
  interaction.depth = 3,
  shrinkage = 0.01)
```

Output dari model tersebut sebagaimana ditunjukkan pada Gambar 4.23 berikut adalah grafik BRT relative influence pada penangkapan ikan Madidihang.






Gambar 4.23 Grafik relative influence BRT - Madidihang dengan outlier

Grafik ini menunjukkan pengaruh relatif dari dua variabel yang berbeda. Variabel SST memiliki pengaruh relatif tertinggi, diikuti oleh variabel Chlo-a. Variabel SST memiliki pengaruh relatif tertinggi, dengan nilai mencapai lebih dari 50. Ini berarti bahwa variabel ini memiliki pengaruh paling signifikan dalam model. Variabel Chlo-a memiliki pengaruh relatif lebih dari 40. Secara keseluruhan, grafik ini menunjukkan bahwa variabel SST adalah variabel paling penting dalam model ini, diikuti oleh variabel Chlo-a. Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtMadidihangChloSST_outlier <- gbm(CPUE ~ Chlo + SST
+ alat_tangkap,
data = MadidihangCatch_ChloSST_without_outlier,
distribution = "gaussian",
n.trees = 100,
interaction.depth = 3,
shrinkage = 0.01)
```

Hasil model dengan menggunakan outlier ditunjukkan sebagaimana Gambar 4.24 berikut.






Gambar 4.24 Grafik relative influence - Ikan Madidihang Tanpa Outlier

Grafik ini menunjukkan pengaruh relatif dari dua variabel yang berbeda. Variabel SST memiliki pengaruh relatif tertinggi, diikuti oleh variabel Chlo-a. Variabel SST memiliki pengaruh relatif tertinggi, dengan nilai mencapai lebih dari 70. Ini berarti bahwa variabel ini memiliki pengaruh paling signifikan dalam model. Variabel Chlo-a memiliki pengaruh relatif mendekati 30. Secara keseluruhan, grafik ini menunjukkan bahwa variabel SST adalah variabel paling penting dalam model ini, diikuti oleh variabel Chlo-a.

Untuk memahami seberapa penting variabel Chlo-a dalam model dan bagaimana hubungan antara Chlo-a dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel Chlo-a memengaruhi prediksi model, sebagaimana Gambar 4.25 berikut.






Gambar 4.25 Grafik hubungan variabel Chlo-a dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel Chlo-a dan 'y'. Dari grafik, dapat dilihat bahwa nilai 'y' mengalami penurunan tajam dari sekitar 23.4 ke 22.6 ketika Chlo-a berkisar dari 0 hingga sekitar 5. Setelah itu, nilai 'y' tetap konstan pada sekitar 22.6 meskipun Chlo-a terus meningkat hingga lebih dari 15. Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi negatif antara Chlo-a dan 'y' ketika Chlo-a kurang dari 5. Pada grafik hubungan antara variabel SST dan respons model BRT ditunjukkan sebagaimana Gambar 4.26 berikut.





Gambar 4.26 Grafik hubungan variabel SST dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel SST dan 'y'. Dari grafik, kita dapat melihat bahwa nilai 'y' mengalami peningkatan dari sekitar 22 ke sekitar 28 ketika SST meningkat dari 26 ke sekitar 28. Setelah itu, nilai 'y' mengalami fluktuasi dan akhirnya menurun tajam ke sekitar 22 ketika SST mencapai 32. Ini menunjukkan bahwa ada hubungan positif antara SST dan 'y' hingga SST mencapai sekitar 28, setelah itu hubungan tersebut menjadi tidak stabil.


4.3.3.3 Ikan tuna mata besar

Tuning model BRT dimulai dengan menyusun model yang terdapat outlier menggunakan model sebagai berikut:

```
model_brtTunaMataBesarchlosSST_outlier <- gbm(CPUE ~ Chlo + SST,
  data = TunaMataBesarCatch_ChloSST,
  distribution = "gaussian",
  n.trees = 100,
  interaction.depth = 3,
  shrinkage = 0.01)
```

Output dari model tersebut sebagaimana ditunjukkan pada Gambar 4.27 berikut adalah grafik BRT relative influence pada penangkapan ikan Tuna Mata Besar.





Gambar 4.27 Grafik relative influence – tuna mata besar dengan outlier


Grafik ini menunjukkan pengaruh relatif dari dua variabel: Chlo-a dan SST. Variabel Chlo-a memiliki pengaruh relatif tertinggi, dengan nilai melebihi 60. Ini berarti bahwa variabel Chlo-a memiliki pengaruh paling signifikan dalam model. Sedangkan variabel SST memiliki pengaruh relatif kurang dari 40, yang berarti pengaruhnya lebih rendah dibandingkan dengan Chlo-a tetapi masih cukup signifikan.

Pada model tanpa outlier dibuat sebagai berikut.

```
model_brtTunaMataBesarchloSST_outlier <- gbm(CPUE ~ Chlo + SST
+ alat_tangkap,
data = TunaMataBesarCatch_ChloSST_without_outlier,
distribution = "gaussian",
n.trees = 100,
interaction.depth = 3,
shrinkage = 0.01)
```

Hasil model dengan menggunakan outlier ditunjukkan sebagaimana Gambar 4.28 berikut.






Gambar 4.28 Grafik relative influence BRT – tuna mata besar (tanpa outlier)

Grafik ini menunjukkan pengaruh relatif dari dua variabel yang berbeda. Variabel Chlo-a memiliki pengaruh relatif tertinggi, diikuti oleh variabel SST. Variabel Chlo-a memiliki pengaruh relatif tertinggi, dengan nilai melebihi 60. Ini berarti bahwa variabel ini memiliki pengaruh paling signifikan dalam model. Variabel SST memiliki pengaruh relatif mendekati 40. Secara keseluruhan, grafik ini menunjukkan bahwa variabel Chlo-a adalah variabel paling penting dalam model ini, diikuti oleh variabel SST.

Untuk memahami seberapa penting variabel Chlo-a dalam model dan bagaimana hubungan antara Chlo-a dan variabel target, dapat dilihat melalui grafik yang dihasilkan menunjukkan bagaimana perubahan dalam variabel Chlo-a memengaruhi prediksi model, sebagaimana Gambar 4.29 berikut.






Gambar 4.29 Grafik hubungan variable Chlo-a dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel Chlo-a dan 'y'. Dari grafik, dapat dilihat bahwa nilai 'y' mengalami peningkatan tajam dari sekitar 7 ke hampir 10 ketika Chlo-a berkisar dari 0 hingga sekitar 0.5. Setelah itu, nilai 'y' mengalami penurunan drastis ke sekitar 7.5 ketika Chlo-a meningkat ke sekitar 1. Nilai 'y' kemudian tetap konstan pada sekitar 7.5 meskipun Chlo-a terus meningkat hingga 3. Secara keseluruhan, grafik ini menunjukkan bahwa ada korelasi positif antara Chlo-a dan 'y' ketika Chlo-a kurang dari 0.5 dan korelasi negatif ketika Chlo-a lebih dari 0.5.

Pada grafik hubungan antara variabel SST dan respons model BRT ditunjukkan sebagaimana Gambar 4.30 berikut.





Gambar 4.30 Grafik hubungan antara variabel SST dan respons model BRT

Grafik ini menunjukkan hubungan antara variabel SST dan 'y'. Dari grafik, kita dapat melihat bahwa nilai 'y' mengalami peningkatan tajam dari sekitar 5 ke sekitar 20 ketika SST meningkat dari 26 ke sekitar 27. Setelah itu, nilai 'y' mengalami penurunan drastis ke sekitar 5 ketika SST berada di antara 27 dan 28. Nilai 'y' kemudian mengalami fluktuasi dengan puncak kedua yang lebih rendah pada SST sekitar 29 dan akhirnya menurun kembali ke sekitar 5 ketika SST mencapai 32. Ini menunjukkan bahwa ada hubungan positif yang sangat kuat antara SST dan 'y' hingga SST mencapai sekitar 27, setelah itu hubungan tersebut menjadi sangat tidak stabil.

4.3.7 Fitting GAM dan ECDF pada hubungan CPUE dan faktor oseanografis

Model GAM pada faktor oseanografi ini terbagi dalam tiga bagian, yakni: (1) Model GAM pada ikan cakalang, (2) Model GAM pada ikan madidihang, dan (3) Model GAM pada ikan tuna mata besar. Adapun faktor oseanografi yang digunakan pada model ini disesuaikan dengan kolom faktor oseanografi yang tersedia pada dataframe, dalam hal ini adalah Chlo-a mewakili Chlo-a dan SST mewakili temperatur permukaan laut. Dalam pemodelan ini juga digunakan model ECDF untuk mendapatkan nilai signifikan dan optimal untuk setiap parameter.

4.3.7.1 Model GAM pada aktivitas penangkapan cakalang

Model yang digunakan adalah:



```
M dengan keseluruhan data
<- gam(CPUE ~ s(Chlo) + s(SST), data =
SST)
i AIC
```

```
aiccakalangChloSST_with_outlier <- AIC(model_with_outlier)
```

Hasil pemodelan GAM tersebut ditunjukkan pada nilai berikut.

```
[1] 246900.3

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(Chlo) + s(SST)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   125.20      2.16    57.95  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df    F p-value
s(Chlo)    4.096  4.984 1.444  0.204
s(SST)    8.826  8.989 6.639 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.0037   Deviance explained = 0.443%
GCV = 81519   Scale est. = 81454       n = 17453
```

Model di atas menggunakan data yang mengandung outlier, yang dapat memengaruhi hasil analisis. Model GAM yang digunakan menjelaskan variabel CPUE sebagai fungsi smooth dari Chlo-a dan SST. Nilai Akaike Information Criterion (AIC) adalah 246,900.3, menunjukkan tingkat kesesuaian model. Fungsi smooth dalam GAM memungkinkan hubungan non-linear antara variabel penjelas dan variabel respon, memberikan fleksibilitas lebih dalam model. Intersep model adalah 125.20 dengan standar error 2.16. Nilai t sebesar 57.95 dan p-value sangat kecil (<2e-16) menunjukkan bahwa intersep ini sangat signifikan secara statistik.

Fungsi smooth s(Chlo) memiliki derajat kebebasan efektif (edf) sebesar 4.096 dan nilai F sebesar 1.444 dengan p-value 0.204, yang berarti variabel ini tidak signifikan pada tingkat signifikansi 5%. Sebaliknya, fungsi smooth s(SST) memiliki edf sebesar 8.826 dan nilai F sebesar 6.639 dengan p-value yang sangat kecil (<2e-16), menunjukkan bahwa SST sangat signifikan dalam model ini.

Goodness of Fit dari model ini ditunjukkan oleh nilai R-squared yang disesuaikan sebesar 0.0037, yang mengindikasikan model hanya menjelaskan sekitar 0.37% dari variabilitas dalam CPUE. Selain itu, deviance yang dijelaskan hanya sebesar 0.443%, yang menunjukkan model ini hanya mampu menjelaskan sebagian kecil dari variabilitas data.

Pemeriksaan lebih lanjut dilakukan untuk menilai struktur data, apakah terdapat outlier atau skewness yang ekstrem yang dapat memengaruhi estimasi model. Visualisasi data dilakukan menggunakan fungsi 'ggplot' untuk mengidentifikasi potensi anomali atau ketidaksesuaian dalam distribusi data.



```
istik
tch_chloSST$chlo)
tch_chloSST$SST)

ribusi data dengan histogram
ch_chloSST, aes(x = chlo)) +
```

```

geom_histogram(binwidth = 1, fill = "blue", alpha = 0.5) +
  labs(title = "Distribusi Chlo", x = "Chlo", y = "Frekuensi")

# visualisasi distribusi data dengan boxplot
ggplot(CakalangCatch_ChloSST, aes(y = Chlo)) +
  geom_boxplot(width = 0.1, fill = "red", alpha = 0.5) +
  labs(title = "Boxplot Chlo", x = "", y = "Chlo")


# visualisasi distribusi data dengan histogram
ggplot(CakalangCatch_ChloSST, aes(x = SST)) +
  geom_histogram(binwidth = 1, fill = "blue", alpha = 0.5) +
  labs(title = "Distribusi SST", x = "SST", y = "Frekuensi")

# visualisasi distribusi data dengan boxplot
ggplot(CakalangCatch_ChloSST, aes(y = SST)) +
  geom_boxplot(width = 0.1, fill = "red", alpha = 0.5) +
  labs(title = "Boxplot SST", x = "", y = "SST")

# Cek skewness
library(e1071)
skewness(CakalangCatch_ChloSST$Chlo)
skewness(CakalangCatch_ChloSST$SST)


```

Hasil formula di atas ditunjukkan pada gambar 4.31 berikut (Gambar selengkapnya Terlampir 2.1). Nampak bahwa terdapat outlier pada kolom Chlo-a dan SST.



(a)





(b)

Gambar 4.31 Outlier variabel oseanografi cakalang: (a) distribusi Chlo-a, dan (c) distribusi SST

Untuk memastikan bagaimana pengaruh outlier pada data di atas, maka dibuat model yang mengabaikan outlier, sebagai berikut.


```
# Mendapatkan nilai AIC
AICcakalang_withoutoutlier <- AIC(modelgam_cakalangChloSST_without_outlier)

# Menampilkan nilai AIC
print(AICcakalang_withoutoutlier)

# Cek performa model tanpa outlier
summary(modelgam_cakalangChloSST_without_outlier)
rsquaredgam_cakalangChloSST_without_outlier <-
summary(modelgam_cakalangChloSST_without_outlier)$r.squared
```

Sebelum melakukan pemodelan tanpa outlier, terlebih dahulu dilakukan simulasi nilai ambang batas outlier, dari $n = 1$ s.d. 7. Hasil simulasi tersebut ditunjukkan pada gambar 4.32 sebagai berikut:





Gambar 4.32 Metrik simulasi threshold outlier model GAM cakalang

Pada model di atas nampak bahwa, penambahan nilai n menyebabkan peningkatan Std. Error, dan penurunan nilai R-sq. (adj) dan Deviance explained. Sehingga dipilih nilai n = 1 yang dianggap terbaik. Adapun hasil pemodelan tanpa outlier tersebut adalah sebagai berikut.

```
[1] 128618.3
Family: gaussian
Link function: identity

Formula:
CPUE ~ s(chlo) + s(SST)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  33.0716    0.3125   105.8   <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df    F p-value
s(chlo)  7.143   8.089  7.488  <2e-16 ***
s(SST)   8.952   8.999 28.949  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.0229   Deviance explained = 2.41%
GCV = 1260.6   Scale est. = 1258.9    n = 12891
```

Perbedaan metrik antara model dengan outliers dan tanpa outliers ditunjukkan pada Tabel 4.1 berikut.



Metrik model dengan dan tanpa outlier (cakalang)

No Outliers	With Outliers	Difference
128,618.3	246,900.3	-118,281.9

R-sq.(adj)	0.0229	0.0037	0.0192
(Intercept)	33.07	125.20	92.13
Std. Error	0.31	2.16	-1,85
Deviance explained	2.41%	0.443%	1,97%
GCV	1,260.6	81,519	-80,258.4
Scale est.	1,258.9	81,454	-80,195.1
N	12,891	17,453	-4,562
MSE Cho	1,080.48	15,634.70	-14,554.22
MSE SST	39.81	9,426.06	-9,386.25

Selain melakukan perbandingan model di atas, juga dilakukan pengecekan multikolineritas. Multikolineritas akan terjadi jika dua variabel prediktor atau lebih sangat berkorelasi. Uji tersebut dilakukan dengan menggunakan fungsi `vif()` dari paket 'car' untuk memeriksa ini.


```
library(car)
library(carbata)
vif(modelgam_cakalang_outlier)
```

Hasil uji multikolineritas di atas ditunjukkan sebagai berikut.

```
      GVIF  Df  GVIF^(1/(2*Df))
Chlo 8.7162e+20  0             Inf
SST  8.7162e+20  0             Inf
```

Hasil uji multikolineritas menunjukkan bahwa variabel Chlo-a dan SST memiliki nilai Generalized Variance Inflation Factor (GVIF) yang sangat tinggi, yaitu 8.7162e+20 dan tak terhingga (Inf) untuk $GVIF^{1/(2 \cdot Df)}$. Hal ini menunjukkan adanya multikolineritas yang sangat kuat antara variabel-variabel tersebut. Multikolineritas adalah kondisi di mana beberapa variabel prediktor dalam model regresi berkorelasi kuat satu sama lain, yang dapat menyebabkan ketidakstabilan estimasi koefisien regresi dan meningkatkan kesalahan standar. Adapun hubungan antara Chlo-a dan CPUE ditunjukkan pada gambar 4.33 berikut.





Gambar 4.33 Plot scatter CPUE cakalang dan prediktor: (a) Chlo-a dan (b) SST



Grafik (a) di atas adalah scatter plot yang menggambarkan hubungan 'CPUE'. Sumbu x mewakili variabel Chlo-a, sementara sumbu y etiap titik pada grafik menunjukkan satu observasi, di mana out menggambarkan nilai Chlo-a dan 'CPUE' untuk observasi ata Chlo-a pada data ini adalah 0.248. Sumbu x menampilkan

nilai Chlo-a dari 0 hingga lebih dari 15, sedangkan sumbu y menunjukkan 'CPUE' dari 0 hingga 150. Sebaran titik yang padat di sebelah kiri grafik menunjukkan banyaknya data dengan nilai Chlo-a rendah dan 'CPUE' tinggi. Kurva biru melengkung di bagian bawah grafik menunjukkan tren penurunan 'CPUE' seiring dengan peningkatan Chlo-a, yang mengindikasikan adanya korelasi negatif antara kedua variabel ini.

Grafik (b) menggambarkan hubungan antara SST dan 'CPUE'. Nilai rata-rata SST pada data ini adalah 29.675. Sumbu x menunjukkan nilai SST yang berkisar antara 24 hingga 32, sementara sumbu y menunjukkan nilai 'CPUE' dari 0 hingga lebih dari 150. Titik-titik hitam di seluruh grafik menggambarkan observasi individual, sedangkan garis biru melengkung merepresentasikan tren rata-rata data tersebut. Grafik ini menunjukkan bahwa seiring peningkatan SST, 'CPUE' juga cenderung meningkat meskipun terdapat fluktuasi.

Hubungan antara setiap variabel prediktor dan variabel target ('CPUE') divisualisasikan dalam scatter plot dan dimodelkan dengan menggunakan GAM. Model ini mengeksplorasi hubungan antara variabel target dan prediktor, seperti yang terlihat pada perbandingan model tunggal (misalnya, 'CPUE ~ s(Chlo)' dan 'CPUE ~ s(SST)') dan model gabungan (misalnya, 'CPUE ~ s(Chlo) + s(SST)'). Lebih banyak titik data terkumpul dalam rentang nilai menengah data SST, menunjukkan distribusi data yang lebih padat di area tersebut. Perbandingan untuk semua model GAM ditunjukkan pada Tabel 4.2 berikut.

Tabel 4.2 Model GAM antara prediktor tunggal dan gabungan (cakalang)

Parameter	Model 1 (CPUE ~ s(Chlo))	Model 2 (CPUE ~ s(SST))	Model 3 (CPUE ~ s(Chlo) + s(SST))
Intercept Estimate	33.072	33.072	33.072
Std. Error	0.316	0.313	0.313
t value	104.8	105.6	105.8
EDF	5.681	8.937	(s(Chlo)) = 7.143, (s(SST)) = 8.952
Ref.df	6.69	8.999	(s(Chlo)) = 8.089, (s(SST)) = 8.999
F	6.918	27.69	(s(Chlo)) = 7.488, (s(SST)) = 28.949
p-value	<2e-16	<2e-16	(s(Chlo)) = <2e-16, (s(SST)) = <2e-16
R-sq.(adj)	0.00345	0.0185	0.0229
Deviance	0.389%	1.92%	2.41%
	1,284.6	1,265.6	1,260.6
	1,283.9	1,264.6	1,258.9
	12,891	12,891	1,2891



AIC	128,861.4	128,668.9	128,618.3
-----	-----------	-----------	-----------

Berdasarkan analisis komparatif terhadap ketiga model, Model 3 (CPUE ~ s(Chlo) + s(SST)) menunjukkan performa yang paling unggul. Hal ini terlihat dari nilai Intercept Estimate yang sama pada ketiga model, namun Model 3 memiliki Standar Error paling rendah (0.313), menunjukkan estimasi parameter yang lebih presisi. Selain itu, Model 3 juga memiliki nilai t tertinggi (105.8), yang menunjukkan bahwa intersep dalam model ini lebih signifikan dibandingkan dengan Model 1 (104.8) dan Model 2 (105.6). Dengan dua nilai EDF (Effective Degrees of Freedom) dan Ref.df untuk s(Chlo) dan s(SST), Model 3 lebih mampu menangkap variasi data yang kompleks.


Model 3 juga menunjukkan nilai F-statistic tertinggi (28.949 untuk s(SST) dan 7.488 untuk s(Chlo)), yang berarti bahwa variabel prediktor dalam model ini lebih signifikan. P-value yang sangat kecil ($<2e-16$) pada semua model menunjukkan bahwa variabel prediktor signifikan, namun Model 3 unggul dalam hal R-squared yang disesuaikan (0.0229) dan Deviance Explained (2.41%), yang berarti model ini lebih mampu menjelaskan variasi data dibandingkan Model 1 (R-squared yang disesuaikan 0.00345, Deviance Explained 0.389%) dan Model 2 (R-squared yang disesuaikan 0.0185, Deviance Explained 1.92%).

Selain itu, Model 3 memiliki nilai Generalized Cross Validation (GCV) terendah (1,260.6) dan estimasi skala terendah (1,258.9), yang menunjukkan performa prediksi yang lebih baik dan estimasi skala yang lebih akurat. Dengan jumlah observasi yang sama pada ketiga model (12,891), Model 3 memiliki Akaike Information Criterion (AIC) terendah (128,618.3), mengindikasikan bahwa model ini paling baik dalam keseimbangan antara kompleksitas model dan kesesuaian data. Oleh karena itu, dapat disimpulkan bahwa Model 3 adalah model terbaik dibandingkan Model 1 dan Model 2, memberikan hasil yang lebih akurat dan signifikan dalam analisis data CPUE. Ketiga model di atas divisualisasikan pada Gambar 4.34 berikut.

(a)

(b)





(c)

Gambar 4.34 Grafik 'EDF' variabel oseanografi cakalang: (a) model tunggal Chlo-a, (b) SST, dan (c) model gabungan

Gambar (a) menunjukkan hasil model CPUE yang diprediksi berdasarkan variabel $s(\text{Chlo})$ (Chlo-a). Dalam grafik tersebut, kurva hitam menunjukkan kecocokan model smoothing spline, dan area abu-abu mewakili interval kepercayaan. Kurva fit yang hampir mendatar dengan interval kepercayaan yang konsisten menunjukkan bahwa variasi dalam konsentrasi Chlo-a tidak memiliki pengaruh signifikan terhadap CPUE. Ini mengindikasikan bahwa Chlo-a bukan prediktor kuat untuk CPUE dalam model ini, karena adanya variabel lain yang lebih berpengaruh atau karena data tidak cukup variatif untuk menangkap hubungan yang ada.


Gambar (b) memperlihatkan hasil model CPUE yang diprediksi berdasarkan variabel $s(\text{SST})$. Kurva hitam menggambarkan kecocokan model smoothing spline, dan area abu-abu menunjukkan interval kepercayaan. Kurva ini menunjukkan fluktuasi signifikan dalam CPUE seiring perubahan SST, dengan beberapa puncak dan lembah yang mengindikasikan hubungan non-linear antara SST dan CPUE. Interval kepercayaan yang lebih lebar pada beberapa bagian menunjukkan ketidakpastian yang lebih tinggi dalam estimasi model pada rentang SST tertentu. Grafik ini menunjukkan bahwa SST memiliki pengaruh yang lebih kompleks dan signifikan terhadap CPUE dibandingkan dengan Chlo-a, dengan variasi SST yang memengaruhi fluktuasi CPUE secara non-linear.

Gambar (c) menunjukkan hasil model CPUE yang diprediksi berdasarkan dua variabel, $s(\text{Chlo})$ dan $s(\text{SST})$, dengan dua panel terpisah untuk masing-masing variabel. Kurva hitam menunjukkan kecocokan model smoothing spline untuk setiap variabel, sementara area abu-abu menunjukkan interval kepercayaan. Pada panel kiri, hubungan antara CPUE dan Chlo-a tampak mendatar dengan interval kepercayaan yang lebih lebar, mengindikasikan ketidakpastian tinggi dan pengaruh yang lemah terhadap CPUE. Pada panel kanan, hubungan antara CPUE dan SST menunjukkan fluktuasi kecil dengan interval kepercayaan yang lebih sempit.




yang relatif sempit, menunjukkan pengaruh SST yang lebih signifikan namun kompleks terhadap CPUE.

Menurut hasil pemodelan GAM, kinerja model secara statistik masih rendah, ditunjukkan oleh nilai Std. Error > 0,05 dan deviasi yang dijelaskan < 50%. Hal ini dapat disebabkan oleh kekurangan data atau sampel yang tidak mewakili, model yang terlalu sederhana atau tidak sesuai dengan kompleksitas data, multikolinearitas tinggi antara variabel prediktor, dan kemungkinan adanya data yang hilang. Model GAM menghasilkan formula $CPUE = 33.07 + s(Chlo, edf=7.14, Ref.df=8.09) + s(SST, edf=8.95, Ref.df=8.99)$, dengan nilai signifikan untuk Chlo-a sebesar 0.58 mg/m^3 dan SST sebesar 28.26°C , serta nilai CPUE tertinggi adalah 51.84. Untuk mengatasi masalah ini, penentuan nilai optimal Chlo-a dan SST dilakukan dengan Model ECDF untuk menghindari bias akibat asumsi hubungan fungsional antara variabel respons dan variabel prediktor dalam Model GAM. Adapun hubungan antara nilai ECDF dan Chlo-a serta SST pada ikan cakalang ditunjukkan pada Gambar 4.35 berikut.



(a)





(b)

Gambar 4.35 Variabel oseanografi – ECDF cakalang: (a) Chlo-a, (b) SST

Grafik (a) adalah grafik ECDF untuk tiga perhitungan berbeda: $f_{\text{CakalangChlo}}(t)$, $g_{\text{CakalangChlo}}(t)$, dan $D_{\text{CakalangChlo}}(t)$, yang diplot terhadap variabel Chlo-a. Sumbu X mewakili nilai Chlo-a yang berkisar dari 0 hingga sekitar 15, sementara sumbu Y menunjukkan nilai fungsi ECDF yang berkisar dari 0 hingga 1. Garis merah mewakili $f_{\text{CakalangChlo}}(t)$, yang meningkat tajam di sekitar Chlo-a = 0 dan mencapai plateau di Value = 1, menunjukkan bahwa sebagian besar data terkonsentrasi dalam rentang ini. Garis hijau horizontal di Value = 0 menggambarkan $g_{\text{CakalangChlo}}(t)$, sementara garis putus-putus hitam vertikal di sekitar Chlo-a = 2 menunjukkan $D_{\text{CakalangChlo}}(t)$. Grafik ini mengilustrasikan distribusi kumulatif empiris dari data, yang menggambarkan probabilitas kumulatif terkait dengan titik data tertentu. Berdasarkan grafik, nilai ECDF Chlo-a sebesar 0.280 menunjukkan bahwa nilai Chlo-a yang signifikan untuk penangkapan ikan cakalang di WPP 714 adalah 0.280.


Grafik (b) adalah grafik ECDF untuk tiga dataset berbeda, yaitu $f_{\text{CakalangSST}}(t)$, $g_{\text{CakalangSST}}(t)$, dan $D_{\text{CakalangSST}}(t)$. Sumbu X menampilkan nilai SST dari sekitar 24 hingga 32, sementara sumbu Y menunjukkan nilai fungsi ECDF dari 0 hingga 1. Garis merah, biru, dan hijau masing-masing mewakili $f_{\text{CakalangSST}}(t)$, $g_{\text{CakalangSST}}(t)$, dan $D_{\text{CakalangSST}}(t)$. Garis-garis ini dimulai dari nol dan berakhir di dekat satu, menunjukkan distribusi kumulatif sepanjang rentang nilai SST. Garis putus-putus ST = 30 membagi grafik menjadi dua bagian, yang menandai ambang yang signifikan.


Ilmogorov-Smirnov menunjukkan bahwa nilai p untuk Chlo-a dan untuk SST adalah $4.45e-14$ ($p < 0,05$), menunjukkan



perbedaan yang sangat signifikan antara distribusi $f(t)$ dan $g(t)$ pada $\text{Chlo-a} = 0.280 \text{ mg/m}^3$, dan $\text{SST} = 30.57^\circ\text{C}$. Dengan demikian, nilai signifikan untuk Chlo-a adalah 0.280 mg/m^3 dan untuk SST adalah 30.57°C .

Untuk menentukan nilai optimal dari Chlo-a dan SST , digunakan metode elbow, yang menunjukkan bahwa titik siku untuk Chlo-a dan SST masing-masing berada pada kluster 4. Metode ini membantu menentukan jumlah kluster yang tepat dalam analisis kluster, yang penting untuk memaksimalkan perbedaan antar kelompok dalam dataset. Titik-titik 'elbow' tersebut lalu dimasukkan ke dalam persamaan fungsi 'kmeans', sebagaimana Gambar 4.36 berikut.





Gambar 4.36 Grafik kluster optimum variabel oseanografi cakalang: (a) Chlo-a, (b) SST

4.3.7.2 Model GAM pada aktivitas penangkapan madidihang

Model yang digunakan adalah untuk memodelkan GAM pada penangkapan ikan Madidihang adalah sebagai berikut:

```
# Membuat model GAM dengan keseluruhan data
model_with_outlier <- gam(CPUE ~ s(chlo) + s(SST), data =
MadidihangCatch_ChloSST)

# Mendapatkan nilai AIC
aicmadidihangChloSST_with_outlier <- AIC(model_with_outlier)
```

Hasil pemodelan GAM tersebut ditunjukkan pada nilai berikut.

```
[1] 165922.5

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(chlo) + s(SST)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  47.028      1.035   45.43  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Incidence of smooth terms:
      df      F p-value
60  1.538    0.154
63  6.411  <2e-16 ***
'***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```



```
R-sq.(adj) = 0.00472   Deviance explained = 0.57%  
GCV = 14344   Scale est. = 14329   n = 13371
```

Hasil model GAM menunjukkan bahwa variabel CPUE dijelaskan sebagai fungsi smooth (smooth function) dari Chlo-a (Chlo) dan SST. Fungsi smooth ini memungkinkan hubungan antara variabel penjelas dan variabel respon untuk bersifat non-linear. Intersep model memiliki koefisien sebesar 47.28 dengan standar error 1.035. Nilai t adalah 45.43 dengan p-value yang sangat kecil ($<2e-16$).


Fungsi smooth $s(\text{Chlo})$ memiliki derajat kebebasan efektif (EDF) sebesar 4.443 dan nilai F sebesar 1.538. P-value untuk variabel ini adalah 0.154, yang berarti bahwa Chlo-a tidak signifikan pada tingkat signifikansi 5%. Di sisi lain, fungsi smooth $s(\text{SST})$ memiliki EDF sebesar 8.665 dan nilai F sebesar 6.411 dengan p-value yang sangat kecil ($<2e-16$).

Dari segi Goodness of Fit, nilai R-squared yang disesuaikan adalah 0.00472, menunjukkan bahwa model ini hanya menjelaskan sekitar 0.47% dari variabilitas dalam CPUE. Deviansi yang dijelaskan adalah 0.57%, yang juga menunjukkan bahwa model ini hanya mampu menjelaskan sebagian kecil dari variabilitas dalam data. Nilai Generalized Cross Validation (GCV) dan estimasi skala juga disediakan untuk penilaian dan seleksi model. Pemeriksaan lebih lanjut diperlukan untuk mengetahui apakah model ini memiliki outlier atau skewness yang ekstrem yang dapat memengaruhi estimasi model, yang dapat dilakukan menggunakan visualisasi seperti 'ggplot'.


```
# Cek summary statistik  
summary(MadidihangCatch_ChloSST$Chlo)  
summary(MadidihangCatch_ChloSST$SST)  
  
# Visualisasi distribusi data dengan histogram  
ggplot(MadidihangCatch_ChloSST, aes(x = Chlo)) +  
  geom_histogram(binwidth = 1, fill = "blue", alpha = 0.5) +  
  labs(title = "Distribusi Chlo", x = "Chlo", y = "Frekuensi")  
  
# Visualisasi distribusi data dengan boxplot  
ggplot(MadidihangCatch_ChloSST, aes(y = Chlo)) +  
  geom_boxplot(width = 0.1, fill = "red", alpha = 0.5) +  
  labs(title = "Boxplot Chlo", x = "", y = "Chlo")  
  
# Visualisasi distribusi data dengan histogram  
ggplot(MadidihangCatch_ChloSST, aes(x = SST)) +  
  geom_histogram(binwidth = 1, fill = "blue", alpha = 0.5) +  
  labs(title = "Distribusi SST", x = "SST", y = "Frekuensi")  
  
# Visualisasi distribusi data dengan boxplot  
ggplot(MadidihangCatch_ChloSST, aes(y = SST)) +  
  geom_boxplot(width = 0.1, fill = "red", alpha = 0.5) +  
  labs(title = "Boxplot SST", x = "", y = "SST")  
  
# Cek skewness  
library(e1071)  
skewness(MadidihangCatch_ChloSST$Chlo)  
skewness(MadidihangCatch_ChloSST$SST)
```



Ilustrasi di atas ditunjukkan pada Gambar 4.37 berikut (Gambar mpir 2.2). Nampak bahwa terdapat outlier pada kolom Chlo-a



(a)



(b)

Gambar 4.37 Outlier variabel oseanografi madidihiang: (a) distribusi Chlo-a, dan (b) distribusi SST



$a = 0$, dengan frekuensi lebih dari 12.00, yang menunjukkan bahwa sebagian besar data memiliki nilai Chlo-a yang mendekati nol. Batang berikutnya, pada nilai Chlo-a sekitar 1, memiliki frekuensi yang jauh lebih rendah, kurang dari 4.00. Hal ini menunjukkan bahwa nilai Chlo-a yang lebih tinggi kurang umum dalam data.

Gambar (c) menunjukkan histogram distribusi SST, di mana sebagian besar data SST berada pada rentang suhu 29-31 °C. Puncak frekuensi terjadi di sekitar suhu 30 °C, menunjukkan bahwa suhu ini paling sering muncul dalam dataset. Histogram ini memiliki distribusi yang miring ke kiri (negatively skewed), menandakan bahwa sebagian besar data berada pada nilai yang lebih tinggi.


Gambar (d) adalah boxplot yang memperlihatkan distribusi SST dengan lebih rinci, termasuk median, kuartil, serta adanya outlier. Median SST berada di sekitar 30 °C, dengan rentang antar kuartil (IQR) mencakup suhu dari sekitar 29 hingga 31 °C. Boxplot juga mengidentifikasi beberapa nilai outlier yang terletak di bawah batas bawah sekitar 26 °C, menunjukkan adanya data SST yang secara signifikan lebih rendah dari yang lain. Model kemudian dibuat dengan mengabaikan outlier untuk memastikan bagaimana pengaruhnya terhadap hasil analisis, sebagai berikut:

```
# Handle outlier dengan metode pencapaian ambang (threshold)
threshold_gamMadidihang <- 3 # Atur ambang sesuai kebutuhan
outliers_gamMadidihang <- residuals(modelMadidihang_with_outlier) >
                           threshold_gamMadidihang

# Buat model tanpa outlier
modelgam_MadidihangChloSST_without_outlier <- gam(CPUE ~ s(Chlo) + s(SST),
data
MadidihangCatch_ChloSST[!outliers_gamMadidiha
ng, ])
```

Sebelum melakukan pemodelan tanpa outlier, terlebih dahulu dilakukan simulasi nilai ambang batas outlier, dari $n = 1$ s.d. 7. Hasil simulasi tersebut ditunjukkan pada Gambar 4.38 sebagai berikut.





Gambar 4.38 Metrik simulasi threshold outlier model GAM madidihang

Pada model di atas nampak bahwa, penambahan nilai n menyebabkan peningkatan Std. Error, dan penurunan nilai R-sq. (adj) dan Deviance explained. Sehingga dipilih nilai $n = 1$ yang dianggap terbaik. Adapun hasil pemodelan tanpa outlier tersebut adalah sebagai berikut.

```
[1] 80165.51

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(Chlo) + s(SST)

Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   10.76      0.12    89.67  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df    F p-value
s(Chlo)  5.923   7.006  7.798  <2e-16 ***
s(SST)   8.881   8.995 37.558  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

R-sq.(adj) =  0.036   Deviance explained = 3.74%
GCV = 147.59   Scale est. = 147.36    n = 10235
```

Dari kedua model yang dibandingkan, terlihat bahwa nilai R-squared untuk model dengan outlier adalah 0.00472, sedangkan untuk model tanpa outlier, nilai R-squared menjadi 0.036. Selain itu, nilai Akaike Information Criterion (AIC) pertama (dengan outlier) adalah 165,922.5, lebih besar dari nilai AIC model kedua (tanpa outlier) yaitu 80,165.51.



Perbedaan metrik antara model dengan outliers dan tanpa outliers ditunjukkan pada Tabel 4.3 berikut.

Tabel 4.3 Metrik model dengan dan tanpa outlier (madidihang)

Parameter	No Outliers	With Outliers	Difference
AIC	80,165.51	165,922.5	-85,757
R-sq.(adj)	0.036	0.00472	0.031
(Intercept)	10.76	47.028	-36.268
Std. Error	0.12	1.035	-0.915
Deviance explained	3.74%	0.57%	3.17%
GCV	147.59	14,344	-14,196.4
Scale est.	147.36	14,329	-14,181.6
N	10,235	13,371	-3,136
MSE Chlo	2,191.948	111,356	2,080.592
MSE SST	375.040	366.453	8.587

Selain melakukan perbandingan model, pengecekan multikolinearitas juga dilakukan untuk memastikan bahwa variabel prediktor tidak berkorelasi terlalu tinggi satu sama lain. Multikolinearitas terjadi ketika dua atau lebih variabel prediktor dalam model regresi memiliki korelasi yang sangat tinggi, yang dapat menyebabkan ketidakstabilan dalam estimasi koefisien regresi dan standar error yang lebih besar. Uji untuk mendeteksi multikolinearitas dilakukan menggunakan fungsi Variance Inflation Factor (VIF) dari paket 'car'.


```
library(car)
library(carData)
vif(modelMadidihang_with_outlier)
```

Hasil uji multikolinearitas di atas ditunjukkan sebagai berikut.


```
          GVIF Df GVIF^(1/(2*Df))
Chlo 1.489398e+23 0          Inf
SST 1.489398e+23 0          Inf
```

Hasil uji multikolinearitas menunjukkan bahwa variabel Chlo-a (Chlo-a) dan SST memiliki nilai Generalized Variance Inflation Factor (GVIF) yang sangat tinggi, yaitu 1.489e+23, dan tak terhingga (Inf) untuk $GVIF^{1/(2 \cdot Df)}$. Hubungan antara Chlo-a dan CPUE ditunjukkan pada Gambar 4.39 berikut.





(a)



(b)

Gambar 4.39 Plot scatter CPUE madidihang dan predictor: (a) Chlo-a, dan (b) SST



as menunjukkan hubungan antara variabel Chlo-a dan CPUE. il) mewakili nilai-nilai Chlo-a yang berkisar dari 0 hingga lebih sumbu Y (vertikal) menunjukkan nilai-nilai CPUE yang berkisar

dari 0 hingga 60. Titik-titik hitam pada grafik merepresentasikan data observasi, yang sebagian besar terkonsentrasi di sekitar nilai Chlo-a dan CPUE yang rendah.

Grafik lainnya menunjukkan hubungan antara SST dan CPUE. Garis biru yang melengkung melalui titik-titik hitam menunjukkan tren atau pola umum dalam data. Grafik ini menunjukkan bahwa CPUE meningkat pada suhu sekitar 28-29 °C, kemudian menurun setelah suhu ini tercapai. Konsentrasi titik hitam yang lebih tinggi di sekitar suhu 28-29 °C menunjukkan peningkatan CPUE pada rentang suhu tersebut, yang menunjukkan bahwa pada SST ini, upaya penangkapan ikan lebih sukses.

Dari grafik ini, dapat disimpulkan bahwa ada hubungan antara SST dan CPUE, dengan peningkatan CPUE pada suhu sekitar 28-29 °C. Namun, hubungan ini tidak konstan dan terdapat variasi yang signifikan dalam data, menunjukkan bahwa faktor lain selain SST juga memengaruhi CPUE. Hubungan antara setiap variabel prediktor dan variabel target dinyatakan dalam model GAM. Perbandingan untuk semua model GAM ditunjukkan pada Tabel 4.4 berikut.

Tabel 4.4 Model GAM antara prediktor tunggal dan gabungan (madidihang)

Parameter	Model 1 (CPUE ~ s(Chlo))	Model 2 (CPUE ~ s(SST))	Model 3 (CPUE ~ s(Chlo) + s(SST))
Intercept Estimate	10.760	10.760	10.760
Std. Error	0.122	0.120	0.120
t value	88.23	89.44	89.67
EDF	4.899	8.872	s(Chlo) = 5.92, s(SST) = 8.88
Ref.df	5.867	8.995	s(Chlo) = 7.01, s(SST) = 8.99
F	7.582	36.66	s(Chlo) = 7.79, s(SST) = 37.56
p-value	<2e-16	<2e-16	s(Chlo) = <2e-16, s(SST) = <2e-16
R-sq.(adj)	0.0043	0.031	0.036
Deviance Explained	0.477%	3.18%	3.74%
GCV	152.3	148.27	147.59
Scale est.	152.21	148.13	147.36
N	10,235	10,235	10,235
AIC	80,487.11	80,213.05	80,165.51


Berdasarkan analisis komparatif terhadap ketiga model, Model 3 (CPUE ~ s(Chlo) + s(SST)) menunjukkan performa yang paling unggul. Model ini memiliki estimasi intersep yang sama dengan kedua model lainnya, tetapi memiliki standar error (Std. Error) yang sedikit lebih rendah (0.12), yang menunjukkan estimasi parameter yang lebih presisi. Selain itu, Model 3 memiliki nilai t tertinggi (89.67), yang menunjukkan bahwa intersep dalam model ini lebih signifikan dibandingkan Model 1 (88.23) dan Model 2 (89.44).

Selain itu, Model 3 menunjukkan nilai F-statistik tertinggi (37.56 untuk s(SST) + s(Chlo)), yang berarti variabel prediktor dalam model ini lebih signifikan.



signifikan. P-value yang sangat kecil ($<2e-16$) pada semua model menunjukkan bahwa variabel prediktor signifikan, tetapi Model 3 unggul dalam hal R-squared yang disesuaikan (0.036) dan Deviance Explained (3.74%), yang berarti model ini lebih mampu menjelaskan variasi data dibandingkan dengan Model 1 (R-sq.(adj) 0.0043, Deviance Explained 0.477%) dan Model 2 (R-sq.(adj) 0.031, Deviance Explained 3.18%).

Selain itu, Model 3 memiliki nilai Generalized Cross-Validation (GCV) terendah (147.59) dan estimasi skala (Scale est.) terendah (147.36), menunjukkan performa prediksi yang lebih baik dan estimasi skala yang lebih akurat. Dengan jumlah observasi yang sama pada ketiga model (10,235), Model 3 memiliki nilai Akaike Information Criterion (AIC) terendah (80,165.51), menegaskan bahwa model ini paling baik dalam keseimbangan antara kompleksitas model dan kecocokan data. Oleh karena itu, dapat disimpulkan bahwa Model 3 adalah model terbaik dibandingkan Model 1 dan Model 2, memberikan hasil yang lebih akurat dan signifikan dalam analisis data CPUE. Ketiga model di atas divisualisasikan pada Gambar 4.40 berikut.



(c)
k 'EDF' variabel oseanografi madidihang: (a) model tunggal
n (c) model gabungan

Gambar (a) menampilkan hasil model CPUE yang diprediksi berdasarkan variabel $s(\text{Chlo})$ (Chlo-a), di mana kurva hitam menggambarkan kecocokan model smoothing spline dan area abu-abu menunjukkan interval kepercayaan. Kurva yang hampir mendatar serta interval kepercayaan yang konsisten menunjukkan bahwa variasi dalam konsentrasi Chlo-a tidak memiliki pengaruh signifikan terhadap CPUE.

Gambar (b) menunjukkan hasil model CPUE yang diprediksi berdasarkan variabel $s(\text{SST})$, dengan kurva hitam menunjukkan kecocokan model smoothing spline dan area abu-abu menunjukkan interval kepercayaan. Kurva ini menunjukkan fluktuasi signifikan dalam CPUE seiring perubahan SST, dengan beberapa puncak dan lembah yang menunjukkan hubungan non-linear antara SST dan CPUE. Area dengan interval kepercayaan yang lebih lebar di beberapa bagian mengindikasikan ketidakpastian yang lebih tinggi dalam estimasi model pada rentang SST tertentu.


Gambar (c) menggambarkan hasil model CPUE yang diprediksi berdasarkan dua variabel, $s(\text{Chlo})$ (Chlo-a) dan $s(\text{SST})$, dengan dua panel terpisah untuk masing-masing variabel. Kurva hitam menunjukkan kecocokan model smoothing spline untuk setiap variabel, sementara area abu-abu menunjukkan interval kepercayaan. Pada panel kiri, hubungan antara CPUE dan Chlo-a tampak mendatar dengan interval kepercayaan yang lebih lebar, menunjukkan ketidakpastian tinggi dan pengaruh Chlo-a yang lemah terhadap CPUE. Pada panel kanan, hubungan antara CPUE dan SST menunjukkan fluktuasi kecil dengan interval kepercayaan yang relatif sempit, menunjukkan pengaruh SST yang lebih signifikan namun kompleks terhadap CPUE.

Menurut hasil pemodelan GAM, kinerja model secara statistik masih rendah, ditunjukkan oleh nilai Standard Error (Std. Error) > 0.05 dan deviasi yang dijelaskan $< 50\%$. Hal ini dapat disebabkan oleh beberapa faktor seperti kurangnya data atau sampel yang tidak representatif, model yang terlalu sederhana atau tidak sesuai dengan kompleksitas data, multikolinearitas tinggi antara variabel prediktor, dan kemungkinan adanya data yang hilang. Model GAM menghasilkan formula $\text{CPUE} = 10.76 + s(\text{Chlo}, \text{edf} = 5.92, \text{Ref.df} = 7.01) + s(\text{SST}, \text{edf} = 8.88, \text{Ref.df} = 8.99)$, dengan nilai signifikan untuk Chlo-a sebesar 0.196 mg/m^3 dan SST sebesar 28.841°C , serta nilai CPUE tertinggi adalah 66.67.


Mengingat rendahnya kinerja model GAM, penentuan nilai optimal Chlo-a dan SST dilakukan dengan menggunakan Model ECDF untuk menghindari bias akibat asumsi hubungan fungsional antara variabel respons dan variabel prediktor dalam Model GAM. ECDF memiliki beberapa kelebihan, termasuk kebebasan dari asumsi distribusi dan kemampuan mendeteksi outlier ekstrem.

Uji Kolmogorov-Smirnov dua variabel ($\text{CPUE} \sim \text{Chlo}$ dan $\text{CPUE} \sim \text{SST}$) dilakukan untuk menilai kesesuaian antara sampel data dan distribusi yang telah ditentukan. Plot ECDF menunjukkan nilai maksimum untuk Chlo-a sebesar 0.196 mg/m^3 dan SST sebesar 28.841°C . Adapun hubungan antara nilai ECDF dan Chlo-an cakalang ditunjukkan pada Gambar 4.41 berikut.





(a)



(b)

Gambar 4.41 Variabel oseanografi – ECDF madidihang: (a) Chlo-a, dan (b) SST




i) di atas adalah grafik ECDF yang menampilkan tiga beda: $f_MadidihangChlo(t)$, $g_MadidihangChlo(t)$, dan t , yang diplot terhadap variabel Chlo-a. Sumbu X

menunjukkan nilai-nilai dari variabel Chlo-a dengan rentang 0 hingga sekitar 15, sementara sumbu Y menunjukkan nilai fungsi ECDF yang berkisar dari 0 hingga 1. Garis merah mewakili $f_MadidihangChlo(t)$, yang menunjukkan peningkatan tajam di sekitar Chlo-a = 0 dan mencapai plateau pada Value = 1, menandakan bahwa sebagian besar data terkonsentrasi dalam rentang ini. Garis hijau horizontal pada Value = 0 menggambarkan $g_MadidihangChlo(t)$, sedangkan garis hitam putus-putus vertikal di sekitar Chlo-a = 2 merepresentasikan $D_MadidihangChlo(t)$. Grafik ini memberikan gambaran distribusi kumulatif empiris data, menunjukkan probabilitas kumulatif yang terkait dengan titik data tertentu. Nilai ECDF Chlo-a adalah 0.196, menunjukkan bahwa nilai Chlo-a yang signifikan untuk penangkapan ikan cakalang di WPP 714 adalah 0.196.

Gambar (b) menampilkan fungsi ECDF untuk tiga dataset yang berbeda: $f_MadidihangSST(t)$, $g_MadidihangSST(t)$, dan $D_MadidihangSST(t)$. Sumbu X menunjukkan variabel SST dengan rentang nilai dari sekitar 26 hingga 32, sementara sumbu Y menunjukkan nilai fungsi ECDF dari 0,00 hingga 1,00. Terdapat tiga garis yang mewakili masing-masing fungsi: $f_MadidihangSST(t)$ (merah), $g_MadidihangSST(t)$ (biru), dan $D_MadidihangSST(t)$ (hijau). Garis-garis ini dimulai dari nol dan mencapai satu, menunjukkan distribusi kumulatif sepanjang rentang nilai SST. Sebuah garis putus-putus vertikal pada nilai SST sekitar 29 membagi grafik menjadi dua bagian, menunjukkan titik ambang tertentu.

Hasil uji Kolmogorov-Smirnov menunjukkan bahwa nilai p untuk Chlo-a adalah $1.620e-11$ dan untuk SST adalah $5.016e-11$ ($p < 0,05$), yang menunjukkan perbedaan signifikan antara distribusi $f(t)$ dan $g(t)$ pada Chlo-a = 0.196 mg/m^3 , dan SST = 28.841°C . Dengan demikian, nilai signifikan untuk Chlo-a adalah 0.196 mg/m^3 , dan SST adalah 28.84°C . Untuk menentukan nilai optimal Chlo-a dan SST, metode "elbow" digunakan. Gambar menunjukkan bahwa titik siku untuk Chlo-a berada pada kluster 4, sedangkan untuk SST berada pada kluster 3. Titik-titik 'elbow' tersebut lalu dimasukkan ke dalam persamaan fungsi 'kmeans'. Hasil pemodelan menunjukkan rentang nilai optimal $0,0748 \text{ mg}\cdot\text{m}^{-3}$ hingga $0.334 \text{ mg}\cdot\text{m}^{-3}$ untuk Chlo-a, dan nilai optimal SST berada pada rentang nilai 28.68°C hingga 30.30°C , sebagaimana ditunjukkan pada Gambar 4.42 berikut.





Gambar 4.42 Grafik kluster optimum variabel oseanografi madidihang: (a) Chlo-a, dan (b) SST



13.3 Model GAM pada aktivitas penangkapan tuna mata besar

Model yang digunakan adalah untuk memodelkan GAM pada penangkapan ikan sebagai berikut:

Model dengan keseluruhan data

```
model_with_outlier <- gam(CPUE ~ s(gt_kapal) + alat_tangkap +
s(hari_laut), data = TunaMataBesarCatch_ChloSST)

# Mendapatkan nilai AIC
aicTunaMataBesarChloSST_with_outlier <- AIC(model_with_outlier)
```

Hasil pemodelan GAM tersebut ditunjukkan pada nilai berikut.

```
[1] 38984.36

Family: gaussian
Link function: identity

Formula:
CPUE ~ s(chlo) + s(SST)


Parametric coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   14.165      1.168   12.12  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:
              edf Ref.df    F  p-value
s(chlo)  5.134   6.242  4.571 9.99e-05 ***
s(SST)   8.522   8.926  5.657 1.23e-06 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


R-sq.(adj) =  0.0175   Deviance explained = 2.14%
GCV = 4728.6   Scale est. = 4708.5       n = 3450
```

Penelitian ini memanfaatkan dua parameter oseanografi, yaitu konsentrasi Chlo-a dan SST, untuk mengkaji dampaknya terhadap ekosistem laut. Sebelum membangun model prediktif, penting untuk mengidentifikasi outlier dalam data Chlo-a dan SST karena outlier dapat memengaruhi hasil analisis statistik. Proses ini dilakukan menggunakan pustaka 'e1071' dalam perangkat lunak statistik. Hasil penelitian menunjukkan adanya outlier dalam variabel prediktor, seperti yang ditunjukkan dalam Gambar 4.43 di bawah ini (Gambar selengkapnya Terlampir 2.3).





(a)



(b)

Gambar 4.43 Outlier variabel oseanografi tuna mata besar: (a) distribusi Chlo-a, dan (b) distribusi SST

Identifikasi dan penanganan outlier dapat dilakukan menggunakan metode ambang batas yang efektif, seperti yang diterapkan dalam penelitian ini. Penggunaan nilai ambang batas terbaik ($n = 1$) menghasilkan nilai Standard Error sebesar 0.062 dan deviasi tertinggi yang dijelaskan sebesar 4.5 dengan model yang menggunakan outlier dan tanpa outlier tabel 4.5 di bawah ini.



Tabel 4.5 Metrik model dengan dan tanpa outlier (tuna mata besar)

Parameter	Dengan Outlier	Tanpa outliers	Perbedaan
AIC	38,984.36	15,248.46	23,735.9
(Intercept)	14.17	2.86	11.31
R-sq.(adj)	0.018	0.068	-0.05
Deviance Explained	2.14%	7.23%	-5.09
GCV	4,728.60	11.12	4,717.48
Scale est.	4,708.50	11.06	4,697.44
N	3,450	2,906	544

Berdasarkan matriks perbandingan model, perbedaan yang signifikan dapat diamati antara model dengan outlier dan model tanpa outlier. Salah satu perbedaan yang paling mencolok adalah nilai Akaike Information Criterion (AIC), di mana model tanpa outlier memiliki nilai AIC yang jauh lebih rendah (15.248,46) dibandingkan dengan model yang mengandung outlier (38.984,36). Hal ini menunjukkan bahwa model tanpa outlier lebih efisien dalam menangkap pola data. Selain itu, nilai intersep juga berbeda antara kedua set model, di mana model dengan outlier memiliki nilai intersep yang lebih tinggi (14.17) dibandingkan dengan model tanpa outlier (2.86).

Dalam hal adjusted R-squared, model tanpa outlier menunjukkan nilai yang lebih tinggi (0.068) dibandingkan dengan model dengan outlier (0.018), yang menunjukkan bahwa model tanpa outlier lebih baik dalam menjelaskan variabilitas dalam data. Metrik deviance explained juga menunjukkan tren serupa, di mana model tanpa outlier menjelaskan persentase deviasi yang lebih tinggi (7.23%) dibandingkan dengan model dengan outlier (2.14%).

Demikian pula, nilai Generalized Cross-Validation (GCV) mendukung keunggulan model tanpa outlier, dengan model tanpa outlier memiliki nilai GCV yang jauh lebih rendah (11.06) dibandingkan dengan model dengan outlier (4,728.60). Ini menunjukkan kualitas model yang lebih baik dalam kondisi tanpa outlier.


Selain membandingkan model di atas, dilakukan pemeriksaan multikolinearitas menggunakan paket 'car'. Multikolinearitas terjadi ketika ada korelasi tinggi antara dua atau lebih variabel prediktor, yang membuat sulit untuk menentukan pengaruh individu dari setiap variabel dalam menjelaskan variabel dependen.

	Ch1o	3.072908e+22	0	GVIF	Df	GVIF^(1/(2Df))
SST	3.072908e+22	0				Inf




Hubungan antara setiap variabel prediktor dan variabel target dinyatakan dalam hal ini, variabel target adalah CPUE. Hubungan tersebut am grafik plot sebar berikut pada Gambar 9.38. Fungsi utama adalah untuk mengidentifikasi dan mengilustrasikan korelasi

atau pola antara tingkat Chlo-a dan SST terhadap CPUE.



(a)



(b)

scatter CPUE tuna mata besar dan predictor: (a) Chlo-a, dan (b)

di atas, sumbu x mewakili variabel Chlo-a dan SST, sementara



sumbu y mewakili nilai CPUE. Setiap titik pada grafik mencerminkan satu pengamatan data, di mana koordinat titik tersebut menunjukkan nilai Chlo-a, SST, dan CPUE untuk masing-masing pengamatan. Rata-rata nilai Chlo-a, SST, dan CPUE pada dataset tersebut adalah 0.24, 29.62, dan 2.86. Grafik yang menunjukkan hubungan antara Chlo-a dan CPUE menunjukkan bahwa ukuran tangkapan per unit cenderung menurun seiring dengan meningkatnya konsentrasi Chlo-a. Sebaliknya, grafik yang menggambarkan hubungan antara SST dan CPUE menunjukkan bahwa nilai CPUE berfluktuasi dengan perubahan SST.

Penelitian ini mengonfirmasi bahwa konsentrasi Chlo-a dan SST adalah parameter oseanografi penting yang memengaruhi distribusi dan hasil tangkapan ikan di wilayah perairan. Perbandingan untuk semua model GAM ditunjukkan pada Tabel 4.6.

Tabel 4.6 Model GAM - prediktor tunggal dan gabungan (tuna mata besar)

Parameter	CPUE ~ s(Chlo) (Model 1)	CPUE ~ s(SST) (Model 2)	CPUE ~ s(Chlo) + s(SST) (Model 3)
Intercept Estimate	2.86	2.86	2.86
Std. Error	0.064	0.062	0.062
t value	44.84	46.05	46.41
EDF	7.24	8.83	(s(Chlo)) = 5.81, (s(SST)) = 8.83
Ref.df	8.25	8.99	(s(Chlo)) = 6.98, (s(SST)) = 8.99
F	1.023	18.66	(s(Chlo)) = 5.69, (s(SST)) = 23.51
p-value	<2e-16	<2e-16	(s(Chlo)) = 3.11e-07, (s(SST)) = < 2e-16
R-sq.(adj)	0.0013	0.053	0.068
Deviance Explained	0.38%	5.63%	7.23%
GCV	11.88	12.27	11.12
Scale est.	11.85	11.23	11.06
N	2,906	2,906	2,906
AIC	15,440.84	15,286.65	15,248.46

Model 3 yang mengasumsikan hubungan "CPUE ~ s(Chlo) + s(SST)" menggambarkan variasi CPUE berdasarkan variabel Chlo-a dan SST. Nilai t yang tinggi (46.41) mengindikasikan bahwa intersep memiliki signifikansi statistik, dan nilai p yang sangat rendah untuk kedua variabel (<2e-16) menunjukkan bahwa efek Chlo-a dan SST terhadap CPUE signifikan. Model ini memiliki R-squared sebesar 0.068, yang berarti model ini menjelaskan sekitar 7.23% dari variasi CPUE. Selain itu, model ini memiliki nilai Generalized Cross Validation (GCV) sebesar 11.12, perkiraan skala sebesar 11.06, dan Akaike Information Criterion (AIC) sebesar 15,248.46. Secara keseluruhan, Model 3 memberikan penjelasan variasi CPUE karena memiliki R-squared yang lebih baik, deviasi lebih tinggi, dan AIC yang lebih rendah dibandingkan dengan



Untuk menilai kompleksitas dan fleksibilitas masing-masing model dalam menjelaskan variasi CPUE, diperlukan pertimbangan Effective Degrees of Freedom (EDF). EDF menjelaskan fleksibilitas model dalam menangkap pola data yang kompleks. Gambar 4.45 menunjukkan kompleksitas masing-masing model, mengilustrasikan bagaimana Chlo-a dan SST.

(a)

(b)

(c)

Gambar 4.45 Grafik 'EDF' variabel oseanografi tuna mata besar: (a) model tunggal Chlo-a, (b) SST, dan (c) model gabungan Chlo-a dan SST


Berdasarkan grafik fungsi penghalusan Effective Degrees of Freedom (EDF) di atas, Model 3 menunjukkan prediktor yang cukup kompleks untuk Chlo-a dengan nilai EDF sebesar 5.81 dan sangat kompleks untuk SST dengan EDF sebesar 8.83. Sementara itu, Model 1 memperlihatkan grafik EDF untuk Chlo-a dan SST dengan kompleksitas yang lebih tinggi (EDF = 7.24), dan Model 2 menunjukkan grafik EDF SST dengan kompleksitas tinggi yang sama (EDF = 8.83). Hasil pemodelan GAM menunjukkan bahwa kinerja model masih rendah secara statistik, ditunjukkan oleh nilai Standard Error lebih besar dari 0.05 dan deviasi yang dijelaskan kurang dari 50%.

Formula model GAM yang dihasilkan adalah $CPUE = 2.86 + s(Chlo, edf = 5.81, Ref.df = 6.98) + s(SST, edf = 8.83, Ref.df = 8.99)$, dengan nilai signifikan ar 0.542 mg/m³ dan untuk SST sebesar 30.03 °C, serta nilai ah 5.26.




F digunakan untuk melihat distribusi data setiap parameter, ang memberikan perbedaan maksimum antara dua fungsi.

Hubungan signifikan antara Chlo-a dan SST dengan CPUE di Tuna mata besar ditunjukkan pada Gambar 4.46, dengan plot ECDF mengungkapkan bahwa nilai maksimum untuk Chlo-a adalah 0.133 mg/m³ dan untuk SST adalah 29.64°C. Uji Kolmogorov-Smirnov dua variabel ($CPUE \sim Chlo$ dan $CPUE \sim SST$) dilakukan untuk menguji kesesuaian antara sampel data dan distribusi yang telah ditentukan. Hasil uji menunjukkan bahwa nilai-p untuk Chlo-a adalah 0.29 ($p > 0.05$), sehingga tidak signifikan, sementara nilai-p untuk SST sangat kecil ($9.27e-21$), menunjukkan perbedaan yang sangat signifikan antara distribusi $f(t)$ dan $g(t)$ pada $SST = 29.64$. Selanjutnya, analisis segmentasi pengelompokan k-means dilakukan untuk memilih nilai Chlo-a yang signifikan dan optimal dalam dataset.



(a)





(b)

Gambar 4.46 Variabel oseanografi – ECDF tuna mata besar: (a) Chlo-a, (b) SST

Hasil pengelompokan diuji menggunakan Analisis Varians (ANOVA), yang menghasilkan nilai $Pr(>F) < 2e-16$, menunjukkan signifikansi yang sangat tinggi. Uji ANOVA digunakan untuk menentukan apakah terdapat perbedaan signifikan antara rata-rata beberapa kelompok atau perlakuan dalam sampel. Selain itu, uji Tukey's Honestly Significant Difference (HSD), dengan nilai p adj sebesar 0, menunjukkan perbedaan yang signifikan antara kluster yang dibandingkan (nilai- $p < 0.05$). Uji Tukey HSD sangat berguna untuk menentukan perbedaan yang signifikan antar kluster setelah dilakukan uji ANOVA (Nanda et al., 2021). Dari Tabel 4.7, kluster 2 dipilih sebagai kluster terbaik karena memiliki nilai rata-rata CPUE tertinggi (12.11). Nilai Chlo-a yang signifikan adalah median Chlo-a sebesar 0.201 mg/m^3 , yang menunjukkan distribusi data yang miring karena adanya outlier.


Tabel 4.7 Ringkasan kluster

Cluster	mean_chlo	median_chlo	mean_CPUE	median_CPUE
1	0.246	0.177	1.169	0.925
2	0.261	0.201	13.469	12.111
3	0.226	0.166	5.375	5.000



Metode Elbow digunakan untuk menentukan kisaran nilai optimal Chlo-a tangkapan tuna mata besar. Metode ini membantu dalam kluster optimal berdasarkan model yang dibuat, dalam hal ini bel Chlo-a dan SST. Nilai kluster optimal untuk Chlo-a dan SST Gambar 4.47 di bawah ini. Gambar (a) menunjukkan titik 'elbow'

pada grafik Chlo-a di klaster ke-3, sedangkan Gambar (b) menunjukkan titik 'elbow' untuk SST di klaster ke-4. Menurut persamaan ini, kisaran nilai optimal untuk Chlo-a dalam penangkapan tuna mata besar di Laut Banda dan sekitarnya adalah antara 0.087 mg/m³ hingga 0.30 mg/m³. Kisaran nilai optimal untuk SST adalah antara 29.35°C hingga 30.45°C.



(b)
 < klaster optimum variabel oseanografi tuna mata besar: (a)

ebelumnya menunjukkan bahwa hasil tangkapan optimal tuna

mata besar bervariasi berdasarkan kondisi lingkungan, seperti Chlo-a dan SST. Beberapa penelitian melaporkan bahwa nilai optimal Chlo-a berkisar antara 0.04 – 0.16 mg/m³ dan SST antara 24°C – 27.5°C, sementara penelitian lain menunjukkan rentang 0.05 mg/m³ - 0.17 mg/m³ untuk Chlo-a dan 24.8°C – 28.7°C untuk SST.

4.3.8 Model MaxEnt

4.3.8.1 Ikan cakalang

Penelitian ini bertujuan menerapkan teknik komputasi menggunakan model MaxEnt pada platform R Studio untuk memodelkan distribusi spasial ikan cakalang di perairan Laut Banda dan sekitarnya. Data variabel lingkungan seperti konsentrasi Chlo-a dan SST digunakan untuk mengidentifikasi faktor-faktor yang memengaruhi distribusi spasial ikan cakalang di wilayah ini. Hasil penelitian ini diharapkan dapat memberikan informasi yang berguna untuk pengelolaan sumber daya perikanan yang lebih efektif dan berkelanjutan di perairan Laut Banda dan sekitarnya.

Dengan penerapan model MaxEnt ini, diharapkan dapat dihasilkan peta prediksi distribusi spasial yang akurat, yang mendukung pengambilan keputusan dalam pengelolaan perikanan dan mendorong praktik perikanan yang lebih berkelanjutan di wilayah penelitian ini. Model ini juga dapat membantu mengidentifikasi habitat potensial bagi ikan cakalang dan menyediakan informasi yang diperlukan untuk memantau dan mengelola perikanan secara berkelanjutan dengan mempertimbangkan variabilitas lingkungan seperti SST dan konsentrasi.

4.3.8.1.1 Evaluasi model

Kinerja model MaxEnt dalam memprediksi distribusi spasial ikan cakalang di perairan Laut Banda dan sekitarnya dievaluasi menggunakan kurva ROC dan metrik AUC. Nilai AUC yang diperoleh dari model dianalisis untuk menilai akurasi dan keandalan model dalam memprediksi distribusi spesies. Nilai metrik model MaxEnt untuk berbagai bulan ditampilkan pada Tabel 4.8 berikut.


Tabel 4.8 Evaluasi kinerja model MaxEnt - cakalang

Bulan	n_presences	n_absences	AUC	Cor	max_TPR+TNR_at
January	1,903	1,000	0.69	0.38	0.43
February	2,011	1,000	0.76	0.44	0.57
March	2,215	1,000	0.74	0.39	0.58
April	1,409	1,000	0.67	0.30	0.55
May	893	1,000	0.82	0.57	0.56
June	925	1,000	0.74	0.42	0.50
July	990	1,000	0.76	0.46	0.59
August	1,027	1,000	0.74	0.43	0.57
September	1,399	1,000	0.70	0.35	0.52
October	1,749	1,000	0.67	0.30	0.63
	544	1,000	0.72	0.38	0.62
	353	1,000	0.73	0.39	0.64




ditunjukkan pada Gambar 4.48 berikut (Gambar selengkapnya

Terlampir 3.1).




(a)



(b)





(c)

Gambar 4.48 Visualisasi nilai AUC untuk distribusi spasial ikan cakalang: (a) Februari; (b) May; and (c) Juli

Metrik yang digunakan dalam Tabel 4.8 di atas mencakup jumlah keberadaan ($n_{\text{presences}}$) dan ketidakhadiran (n_{absences}) data, AUC, korelasi, dan $\text{max_TPR} + \text{TNR_at}$. AUC merupakan metrik utama yang menunjukkan kemampuan model untuk membedakan lokasi keberadaan dan ketidakhadiran. Nilai AUC yang mendekati 1 menunjukkan akurasi prediksi yang tinggi, sedangkan nilai yang mendekati 0.5 menunjukkan prediksi acak. Nilai AUC yang lebih tinggi (dalam hal ini, 0.82 pada bulan Mei) menunjukkan kinerja model yang baik. Korelasi mengukur hubungan linier antara prediksi model dan data observasi, di mana nilai yang lebih tinggi menunjukkan kesesuaian yang lebih baik. $\text{Max_TPR} + \text{TNR_at}$ mengombinasikan TPR (True Positive Rate) dan TNR (True Negative Rate) untuk menentukan ambang batas prediksi yang optimal, dengan nilai tertinggi pada bulan Oktober (0.63), menunjukkan keseimbangan terbaik antara deteksi keberadaan dan ketidakhadiran spesies.


4.3.8.1.2 Prediksi Distribusi Spasial Bulanan

Dalam penelitian ini, prediksi distribusi spasial ikan cakalang dilakukan menggunakan model MaxEnt untuk setiap bulan dari tahun 2014 hingga 2022, seperti yang ditunjukkan pada Gambar 4.49 (Gambar peta selengkapnya Terlampir 2.2). Data distribusi yang dihasilkan menunjukkan area potensial cakalang di perairan Laut Banda dan sekitarnya berdasarkan yaitu konsentrasi Chlo-a dan SST. Pola distribusi bulanan mengidentifikasi variasi musiman dan tren distribusi ikan cakalang.




Area dengan probabilitas keberadaan ikan cakalang yang tinggi berhasil diidentifikasi, menunjukkan kemampuan model untuk menangkap pola ekologi signifikan yang dipengaruhi oleh kondisi lingkungan.

Pred. Distribution of SKJ Feb




(a)

Pred. Distribution of SKJ May



(b)





(c)

Gambar 4.49 Prediksi distribusi ikan cakalang di perairan Laut Banda dan sekitarnya: (a) Februari; (b) Mei; dan (c) Juli

Dari Januari hingga Desember, prediksi distribusi spasial ikan cakalang di perairan Laut Banda dan sekitarnya menggunakan model MaxEnt menunjukkan variasi probabilitas keberadaan di berbagai wilayah dengan nilai yang berfluktuasi sepanjang tahun. Pada bulan Januari, wilayah dengan probabilitas tinggi (0.8) tersebar luas, terutama di bagian utara dan tengah, namun menurun sedikit dari Februari hingga April, dengan probabilitas tertinggi mencapai sekitar 0.6. Dari Mei hingga Juli, distribusi dengan probabilitas tinggi menjadi lebih terfragmentasi, dan dominasi warna merah muda (0.2) meningkat, menunjukkan probabilitas keberadaan ikan cakalang yang rendah. Dari Agustus hingga Oktober, distribusi mulai meningkat kembali, dengan nilai probabilitas sekitar 0.6 hingga 0.8 di beberapa wilayah. Pada bulan November, probabilitas tersebar lebih merata, dengan nilai berkisar antara 0.2 hingga 0.8, sementara pada bulan Desember, terjadi peningkatan wilayah dengan probabilitas tinggi, terutama di bagian utara dan timur, dengan nilai mencapai 0.8, menunjukkan konsentrasi ikan cakalang yang lebih besar di wilayah tersebut menjelang akhir tahun.

Prediksi distribusi spasial bulanan ikan cakalang di perairan Laut Banda menunjukkan pola musiman dengan konsentrasi utama di bagian utara pada awal tahun (Januari-Maret) dan akhir tahun (November-Desember), serta pergerakan ke arah timur dan selatan pada pertengahan tahun (April-Oktober). Wilayah tinggi terutama berada di antara 122° hingga 130° bujur timur, yang dipengaruhi oleh kondisi lingkungan seperti suhu air dan distribusi ini mencerminkan adaptasi ikan cakalang terhadap sebanografi di perairan Laut Banda sepanjang tahun.





4.3.8.1.3 Variabilitas Temporal dan Distribusi Ikan

Dalam hal variabilitas temporal pada kondisi lingkungan dan distribusi ikan, terlihat bahwa dari Januari hingga Desember, konsentrasi Chlo-a dan SST menunjukkan variasi yang signifikan. Pada bulan Januari, konsentrasi Chlo-a berkisar antara 0.12-2.29 mg/m³ dan SST 27.73-31.48°C; pada Februari, Chlo-a 0.11-2.67 mg/m³ dan SST 28.14-31.78°C; pada Maret, Chlo-a 0.11-4.08 mg/m³ dan SST 28.39-31.54°C; pada April, Chlo-a 0.068-2.39 mg/m³ dan SST 28.85-31.28°C; pada Mei, Chlo-a 0.084-1.79 mg/m³ dan SST 28.87-32.26°C; pada Juni, Chlo-a 0.12-1.86 mg/m³ dan SST 28.25-32.21°C; pada Juli, Chlo-a 0.13-1.59 mg/m³ dan SST 26.54-30.30°C; pada Agustus, Chlo-a 0.19-2.70 mg/m³ dan SST 26.19-29.73°C; pada September menunjukkan puncak Chlo-a tertinggi, 0.084-6.93 mg/m³, dan SST 26.82-32.54°C; pada Oktober, Chlo-a 0.10-1.35 mg/m³ dan SST 28.60-31.90°C; pada November, Chlo-a 0.076-1.44 mg/m³ dan SST 27.69-31.96°C; dan pada Desember, Chlo-a 0.032-1.90 mg/m³ dan SST 28.45-31.93°C. Variasi ini mencerminkan perubahan kondisi lingkungan laut sepanjang tahun, dengan puncak Chlo-a terjadi pada bulan September dan fluktuasi SST menunjukkan pola musiman.



4.3.8.1.4 Respon Model terhadap Variabel Lingkungan

Untuk memahami lebih dalam, analisis dilakukan terhadap respon model MaxEnt terhadap setiap variabel lingkungan dan pengaruhnya terhadap distribusi spasial ikan cakalang. Kurva respon yang dihasilkan oleh fungsi *response()* dari paket *dismo* menggambarkan bagaimana probabilitas prediksi keberadaan ikan cakalang berubah dengan tingkat Chlo-a dan SST yang bervariasi. Kurva ini menunjukkan nilai ambang batas dan rentang optimal untuk setiap variabel, di mana di luar rentang tersebut, probabilitas keberadaan ikan cakalang menurun. Respon model ini divisualisasikan pada Gambar 4.50 berikut (Gambar selengkapnya Terlampir 3.3).






(a)



(b)





(c)

Gambar 4.50 Respon model MaxEnt terhadap setiap variabel lingkungan: (a) Februari, (b) Mei, dan (Juli)

Pada grafik di atas, terlihat bahwa dari Januari hingga Desember, respon model MaxEnt terhadap variabel lingkungan Chlo-a (layer.1) dan SST (layer.2) menunjukkan berbagai pola yang memengaruhi prediksi distribusi spasial ikan cakalang. Untuk variabel Chlo-a, respon model cenderung menunjukkan peningkatan prediksi keberadaan ikan pada nilai sekitar 5 hingga 10, seperti yang terlihat pada lonjakan tajam di bulan Februari, April, dan Desember. Sebaliknya, model menunjukkan penurunan prediksi pada konsentrasi Chlo-a yang lebih rendah (sekitar -5 hingga 0), yang terjadi secara konsisten sepanjang tahun. Untuk variabel SST, respon model lebih kompleks, dengan penurunan signifikan dalam prediksi keberadaan ikan pada rentang suhu 30-35°C, terutama pada bulan Maret, Juni, Agustus, dan Desember, menunjukkan ketidaksesuaian suhu untuk keberadaan ikan cakalang. Sebaliknya, suhu yang lebih rendah sekitar 20-25°C pada bulan Juli menunjukkan peningkatan prediksi keberadaan ikan. Pola respon ini menggambarkan bahwa baik konsentrasi Chlo-a maupun SST memiliki pengaruh yang signifikan dan berbeda terhadap distribusi spasial ikan cakalang sepanjang tahun.

4.3.8.1.5 Nilai signifikansi model



Untuk memahami potensi keberadaan ikan cakalang sepanjang tahun, an baik untuk Chlo-a maupun SST. Pada Januari, nilai modus dan 0.14 mg/m³ dengan SST 29.48°C; Februari menunjukkan sar 0.12 mg/m³ dan SST 29.67-29.71°C; Maret memiliki modus 1-0.12 mg/m³ dan SST 30.08-30.23°C; April dengan modus

Chlo-a sebesar 0.094-0.10 mg/m³ dan SST 30.30°C; Mei menunjukkan modus Chlo-a sebesar 0.11-0.14 mg/m³ dan SST 29.71°C; Juni dengan modus Chlo-a sebesar 0.13 mg/m³ dan SST 29.86°C; Juli menunjukkan variasi modus Chlo-a sebesar 0.15-0.31 mg/m³ dan SST 28.22-28.68°C; Agustus memiliki modus Chlo-a sebesar 0.20-0.39 mg/m³ dan SST 27.19°C; September menunjukkan modus Chlo-a sebesar 0.14-0.20 mg/m³ dan SST 28.14°C; Oktober dengan modus Chlo-a sebesar 0.12 mg/m³ dan SST 30.19°C; November dengan modus Chlo-a sebesar 0.12 mg/m³ dan SST 31.21°C; dan Desember dengan modus Chlo-a sebesar 0.066-0.087 mg/m³ dan SST 31°C. Nilai-nilai ini menunjukkan bahwa potensi keberadaan ikan cakalang cenderung lebih tinggi pada bulan-bulan dengan konsentrasi Chlo-a yang lebih tinggi dan SST yang lebih dingin, seperti pada bulan Juli dan Agustus.

4.3.8.1.6 Pengaruh Variabel Lingkungan pada Model

Metrik Variable Contribution dan Permutation Importance digunakan untuk mengevaluasi pengaruh variabel lingkungan Chlo-a dan SST dalam model MaxEnt dari Januari hingga Desember. Variable Contribution mengukur seberapa sering dan seberapa besar setiap variabel meningkatkan "gain" model selama pelatihan, seperti yang terlihat pada bulan Desember, di mana Chlo-a memberikan kontribusi tertinggi sebesar 81.01%. Sebaliknya, Permutation Importance mengukur pengaruh kritis suatu variabel terhadap akurasi prediksi model dengan menghitung degradasi kinerja saat nilai variabel diacak; misalnya, SST menunjukkan nilai tertinggi pada bulan Juni sebesar 96.09%. Rata-rata kontribusi variabel Chlo-a adalah 32.70%, sedangkan SST adalah 67.31%. Rata-rata Permutation Importance untuk Chlo-a adalah 32.95%, dan SST adalah 67.05%. Kedua metrik ini digunakan untuk memahami peran dan pengaruh relatif variabel dalam model. Variable Contribution memberikan wawasan tentang bagaimana model memprioritaskan variabel selama pelatihan, sedangkan Permutation Importance menunjukkan pentingnya variabel-variabel tersebut dalam prediksi akurasi setelah pelatihan. Metrik ini ditampilkan pada Tabel 4.9 berikut.

Tabel 4.9 Variable Contribution dan Permutation Importance

Month	Chlo Contribution (%)	SST Contribution (%)	Chlo Permutation Importance (%)	SST Permutation Importance (%)
January	14.92	85.08	24.68	75.32
February	63.96	36.04	56.59	43.41
March	62.64	37.36	56.28	43.72
April	66.69	33.31	63.98	36.02
May	33.06	66.94	21.79	78.21
June	2.88	97.12	3.91	96.09
July	18.49	81.51	23.23	76.77
August	2.93	97.07	3.74	96.26
	7.73	92.27	11.90	88.10
	35.09	64.91	37.24	62.76
	2.95	97.05	5.30	94.70
	81.01	18.99	74.63	25.37



Penelitian ini menggunakan model MaxEnt untuk memprediksi distribusi spasial ikan cakalang di perairan Laut Banda dan sekitarnya dengan memanfaatkan data lingkungan seperti konsentrasi Chlo-a dan SST. Hasil model menunjukkan adanya variasi signifikan dalam distribusi spasial ikan cakalang yang dipengaruhi oleh perubahan kondisi lingkungan sepanjang tahun.

Nilai AUC dari model MaxEnt menunjukkan variasi prediksi distribusi ikan cakalang setiap bulan, dengan nilai tertinggi pada bulan Mei (0.82) dan terendah pada bulan April (0.67). Hal ini mengindikasikan adanya fluktuasi kinerja model akibat variabilitas lingkungan atau kekurangan data observasi.

Selain itu, pengukuran kontribusi variabel melalui "Variable Contribution" dan "Permutation Importance" menunjukkan peran penting kedua variabel lingkungan tersebut dalam model. Kontribusi Chlo-a mencapai nilai tertinggi sebesar 81.01% pada bulan Desember, sedangkan SST memberikan kontribusi terbesar pada bulan Juni sebesar 96.09%. Di sisi lain, bulan dengan kontribusi variabel yang lebih rendah, seperti Januari dengan kontribusi Chlo-a sebesar 14.92%, menunjukkan bahwa variabilitas parameter lingkungan pada beberapa periode dapat memengaruhi akurasi prediksi model.

4.3.8.2 Ikan madidihang

Pemodelan distribusi spasial madidihang sangat penting untuk memahami faktor-faktor lingkungan yang memengaruhi habitatnya. Salah satu metode yang banyak digunakan dalam pemodelan distribusi spesies adalah Maximum Entropy (MaxEnt) karena kemampuannya memprediksi area distribusi potensial berdasarkan data keberadaan dan variabel lingkungan yang relevan.

4.3.8.2.1 Evaluasi model

Kinerja model MaxEnt dalam memprediksi distribusi spasial madidihang di Laut Banda dan perairan sekitarnya dievaluasi menggunakan kurva ROC, metrik AUC, jumlah keberadaan (n_presences) dan ketidakhadiran (n_absences) spesies untuk setiap bulan, korelasi prediktif (cor), dan nilai maksimum TPR+TNR (max_TPR+TNR_at). Metrik model MaxEnt untuk berbagai bulan disajikan dalam Tabel 4.10 di bawah ini.



Tabel 4.10 Evaluasi kinerja model MaxEnt - madidihang


Month	n_presences	n_absences	Cor	max_TPR+TNR_at
January	1,156	1,000	0.28	0.60
February	1,281	1,000	0.30	0.60
March	1,681	1,000	0.20	0.61
April	1,097	1,000	0.18	0.61
May	701	1,000	0.36	0.64
		1,000	0.31	0.60
		1,000	0.37	0.52
		1,000	0.20	0.64
	10	1,000	0.17	0.61



October	1,527	1,000	0.26	0.62
November	1,389	1,000	0.30	0.67
December	1,157	1,000	0.16	0.62

Nilai AUC ditunjukkan pada Gambar 4.51 berikut (Gambar selengkapnya Terlampir 3.4).





(c)

Gambar 4.51 Visualisasi nilai AUC untuk distribusi spasial madidihang: (a) Februari; (b) Mei; dan (c) Juli

Metrik yang disajikan dalam Tabel 4.10 di atas mencakup jumlah keberadaan ($n_{\text{presences}}$) dan ketidakhadiran (n_{absences}) dalam dataset, nilai AUC, korelasi, dan max_TPR+TNR_at . AUC berfungsi sebagai metrik utama untuk menilai seberapa baik model membedakan antara lokasi keberadaan dan ketidakhadiran spesies. Nilai AUC yang mendekati 1 mencerminkan akurasi prediktif yang tinggi, sedangkan nilai yang mendekati 0.5 menunjukkan prediksi yang bersifat acak. Nilai AUC yang lebih tinggi, seperti 0.71 yang diamati pada bulan Mei, menunjukkan kinerja model yang kuat. Korelasi mencerminkan hubungan linear antara prediksi model dan nilai yang diamati, di mana nilai yang lebih besar menunjukkan kesesuaian yang lebih baik. Metrik max_TPR+TNR_at merepresentasikan kombinasi TPR dan TNR, yang bertujuan mengidentifikasi ambang batas prediksi optimal; nilai puncak yang dicatat pada bulan Mei dan Agustus (0.64) menunjukkan keseimbangan ideal dalam mendeteksi keberadaan dan ketidakhadiran spesies.


4.3.8.2.2 Prediksi Distribusi Spasial Bulanan

Penelitian ini menggunakan model MaxEnt untuk memprediksi distribusi spasial bulanan madidihang dari tahun 2014 hingga 2022, seperti ditunjukkan pada gambar peta selengkapnya (Terlampir 3.5). Peta distribusi yang akan area potensial keberadaan madidihang di Laut Banda dan sekitarnya, dengan mempertimbangkan faktor lingkungan seperti suhu permukaan laut dan SST. Analisis pola distribusi bulanan dilakukan untuk




mengidentifikasi variasi musiman dan tren distribusi madidihang. Area dengan probabilitas tinggi keberadaan madidihang berhasil diidentifikasi, yang menunjukkan kemampuan model dalam menangkap pola ekologis yang dipengaruhi oleh kondisi lingkungan.

Pred. Distribution of YFT Feb




(a)

Pred. Distribution of YFT May



(b)





(c)

Gambar 4.52 Prediksi distribusi madidihiang di Laut Banda dan perairan sekitarnya: (a) Februari; (b) Mei; dan (c) Juli

Dari Januari hingga Desember, prediksi distribusi spasial madidihiang di Laut Banda dan wilayah sekitarnya, menggunakan model MaxEnt, menunjukkan variasi probabilitas keberadaan di berbagai area dengan nilai yang berfluktuasi sepanjang tahun. Pada bulan Januari, area dengan probabilitas tinggi (0.7) sebagian besar ditemukan di bagian utara, sedikit meningkat pada Februari dengan probabilitas tertinggi mencapai sekitar 0.8 di barat laut. Antara Maret hingga April, distribusi probabilitas menjadi lebih merata, dengan nilai puncak berkisar antara 0.6 hingga 0.7. Selama Mei hingga Juli, area dengan probabilitas tinggi lebih terfragmentasi dan tersebar, didominasi oleh warna hijau muda dan merah muda (0.2–0.4), yang menunjukkan rendahnya kemungkinan keberadaan madidihiang di sebagian besar wilayah. Dari Agustus hingga Oktober, probabilitas keberadaan kembali meningkat, mencapai nilai sekitar 0.6 hingga 0.7 di area tertentu. Pada bulan November, distribusi probabilitas menjadi lebih merata, dengan nilai berkisar antara 0.2 hingga 0.7, sedangkan pada Desember, terjadi peningkatan di area dengan probabilitas tinggi, terutama di bagian barat laut dan wilayah tengah, mencapai hingga 0.8, yang mengindikasikan konsentrasi keberadaan madidihiang lebih tinggi menjelang akhir tahun.



Is Temporal dan Distribusi Ikan



temporal dalam kondisi lingkungan dan distribusi ikan terlihat hingga Desember, dengan perubahan signifikan pada dan SST. Pada bulan Januari, konsentrasi Chlo-a berkisar

antara 0.11-8.29 mg/m³ dan SST antara 27.73-31.24°C; pada Februari, Chlo-a berkisar antara 0.099-1.48 mg/m³ dan SST antara 27.56-32.41°C; pada Maret, Chlo-a adalah 0.10-4.39 mg/m³ dengan SST berkisar antara 28.05-32.13°C; April menunjukkan Chlo-a antara 0.073-2.10 mg/m³ dan SST antara 28.78-31.21°C; pada Mei, Chlo-a adalah 0.10-1.79 mg/m³ dan SST 28.87-32.26°C; pada Juni, konsentrasi Chlo-a adalah 0.010-4.71 mg/m³ dengan SST berkisar antara 28.25-31.75°C; Juli menunjukkan Chlo-a pada 0.11-1.43 mg/m³ dan SST antara 26.03-30.68°C; pada Agustus, Chlo-a adalah 0.11-1.92 mg/m³ dan SST berkisar antara 26.16-29.59°C; sedangkan pada September, Chlo-a mencapai nilai tertinggi sebesar 0.086-6.93 mg/m³ dengan SST antara 26.82-31.65°C; Oktober mencatat Chlo-a pada 0.10-2.02 mg/m³ dan SST antara 28.60-32.95°C; pada November, Chlo-a adalah 0.067-1.39 mg/m³ dengan SST berkisar antara 27.99-32.17°C; dan pada Desember, konsentrasi Chlo-a adalah 0.085-2.27 mg/m³ dengan SST antara 28.39-32.52°C. Variasi ini mencerminkan perubahan dinamis dalam kondisi lingkungan laut sepanjang tahun, dengan puncak konsentrasi Chlo-a terjadi pada Januari dan September, serta fluktuasi SST yang mengikuti pola musiman yang memengaruhi distribusi ikan madidihang.



4.3.8.2.4 Respon Model terhadap Variabel Lingkungan

Untuk mendapatkan pemahaman yang lebih mendalam, dilakukan analisis tentang bagaimana model MaxEnt merespons setiap variabel lingkungan yang memengaruhi distribusi spasial ikan madidihang. Kurva respons yang dihasilkan oleh fungsi *response()* dari paket *dismo* menunjukkan bagaimana probabilitas prediksi keberadaan madidihang berubah pada berbagai tingkat Chlo-a dan SST. Kurva ini mengungkapkan nilai ambang dan rentang optimal untuk setiap variabel, di mana di luar rentang tersebut, probabilitas keberadaan tuna cenderung menurun. Visualisasi respons model ditampilkan pada Gambar 4.53 di bawah ini (Gambar selengkapnya Terlampir 3.6).






(a)



(b)





(c)

Gambar 4.53 Respons model MaxEnt terhadap setiap variabel lingkungan: (a) Februari; (b) Mei; dan (c) Juli

Pada grafik di atas, terlihat bahwa dari Januari hingga Desember, respons model MaxEnt terhadap variabel lingkungan seperti Chlo-a (*layer.1*) dan SST (SST, *layer.2*) menunjukkan pola yang berbeda yang memengaruhi prediksi distribusi spasial ikan madidiang. Untuk variabel Chlo-a, respons model secara umum menunjukkan peningkatan prediksi keberadaan ikan pada nilai sekitar 5 hingga 10, seperti yang terlihat pada lonjakan tajam di bulan Februari, Mei, dan Desember. Sebaliknya, model menunjukkan penurunan prediksi pada konsentrasi Chlo-a yang lebih rendah (sekitar -5 hingga 0), yang terjadi secara konsisten sepanjang tahun. Sementara itu, untuk variabel SST, respons model menunjukkan variasi yang lebih luas, dengan peningkatan signifikan prediksi keberadaan ikan pada rentang suhu 30-35°C, terutama pada Januari, Juni, dan Oktober. Di sisi lain, suhu yang lebih rendah sekitar 20-25°C pada Juli dan Agustus menunjukkan penurunan prediksi keberadaan ikan. Pola ini menunjukkan bahwa konsentrasi Chlo-a dan SST memiliki pengaruh yang signifikan terhadap distribusi spasial ikan madidiang sepanjang tahun.

4.3.8.2.5 Nilai signifikansi model

Untuk memahami potensi keberadaan ikan madidiang sepanjang tahun, nilai modulus untuk Chlo-a dan SST digunakan. Pada bulan Januari, nilai modulus berkisar antara 0.10 hingga 0.11 mg/m³ dengan SST sebesar 29.53°C; Februari menunjukkan berkisar antara 0.10 hingga 0.11 mg/m³ dengan SST sebesar 29.75°C; Maret, modulus Chlo-a adalah 0.11 mg/m³ dan SST sebesar 29.75°C; April, modulus Chlo-a antara 0.092 hingga 0.095 mg/m³ dengan SST



sebesar 30.58°C; Mei menunjukkan modus Chlo-a sebesar 0.11 mg/m³ dan SST sebesar 29.71°C; pada Juni, modus Chlo-a berkisar antara 0.10 hingga 0.13 mg/m³ dengan SST sebesar 29.86°C; Juli menunjukkan variasi modus Chlo-a antara 0.18 hingga 0.34 mg/m³ dengan SST sebesar 28.22°C; pada Agustus, modus Chlo-a mencapai 0.19 hingga 0.33 mg/m³, dengan SST turun menjadi 27.25°C; September menunjukkan nilai modus Chlo-a sebesar 0.17 mg/m³ dan SST antara 28.12 hingga 28.14°C; Oktober memiliki modus Chlo-a sebesar 0.11 mg/m³ dengan SST sebesar 30.19°C; November menunjukkan modus Chlo-a antara 0.078 hingga 0.11 mg/m³ dengan SST sebesar 31.10°C; dan pada Desember, nilai modus Chlo-a berkisar antara 0.094 hingga 0.098 mg/m³ dengan SST sebesar 31.25°C. Nilai-nilai ini menunjukkan bahwa potensi keberadaan ikan madidihang cenderung lebih tinggi pada bulan-bulan dengan konsentrasi Chlo-a yang lebih besar dan SST yang lebih rendah, seperti pada bulan Juli dan Agustus.

4.3.8.2.6 Pengaruh variabel lingkungan pada model

Untuk menilai pengaruh variabel lingkungan Chlo-a dan SST dalam model MaxEnt dari Januari hingga November, metrik Variable Contribution dan Permutation Importance digunakan. Chlo-a memberikan kontribusi tertinggi pada bulan April sebesar 83.03%, sedangkan SST menunjukkan kontribusinya tertinggi pada bulan Juni sebesar 87.11%. Untuk Permutation Importance, Chlo-a mencapai nilai puncaknya pada bulan Februari sebesar 68.79%, sementara SST memiliki nilai tertinggi pada bulan Januari sebesar 77.35%.

Kedua metrik ini digunakan untuk memahami peran dan dampak dari setiap variabel dalam model, di mana Variable Contribution menunjukkan prioritas variabel selama proses pelatihan model, sedangkan Permutation Importance mengukur pengaruh variabel terhadap akurasi prediksi setelah pelatihan. Metrik ini disajikan dalam Tabel 4.11 di bawah ini.

Tabel 4.11 Variable contribution dan permutation importance

Month	Chlorophyll-a Contribution (%)	SST Contribution (%)	Chlorophyll-a Permutation Importance (%)	SST Permutation Importance (%)
January	28.54	71.46	22.65	77.35
February	65.97	34.03	68.79	31.21
March	81.05	18.95	63.77	36.23
April	83.02	16.98	83.64	16.36
May	32.94	67.06	25.86	74.14
June	12.89	87.11	17.30	82.70
July	42.54	57.46	44.59	55.41
August	45.94	54.06	32.52	67.48
September	18.13	81.87	35.15	64.85
	28	45.72	47.16	52.84
	36	82.34	15.42	84.58
	26	60.74	47.46	52.54



Penelitian ini menerapkan model MaxEnt untuk memprediksi distribusi spasial ikan madidihang di Laut Banda dan perairan sekitarnya dengan memanfaatkan data lingkungan seperti konsentrasi Chlo-a dan SST. Hasil pemodelan menunjukkan variasi signifikan dalam distribusi spasial madidihang yang dipengaruhi oleh perubahan kondisi lingkungan sepanjang tahun. Nilai AUC dari model MaxEnt untuk memprediksi distribusi madidihang bervariasi setiap bulan, dengan nilai tertinggi pada Juli (0.72) dan nilai terendah pada April, September, dan Desember (0.60).

Berdasarkan tabel "Variable Contribution and Permutation Importance", pengukuran kontribusi variabel menyoroti peran signifikan dari kedua variabel lingkungan, Chlo-a dan SST, dalam model prediksi distribusi madidihang. Chlo-a menunjukkan kontribusi tertinggi sebesar 83.02% pada bulan April, sedangkan SST memberikan kontribusi terbesar pada bulan November, dengan nilai 82.35%. Sebaliknya, bulan-bulan dengan kontribusi variabel yang lebih rendah, seperti Juni di mana Chlo-a hanya berkontribusi 12.89%, menunjukkan bahwa variabilitas parameter lingkungan selama periode tertentu dapat memengaruhi akurasi prediksi model.

4.3.8.3 Ikan tuna mata besar

Tuna Mata Besar adalah spesies tuna pelagis dengan nilai ekonomi tinggi yang tersebar luas di Samudra Hindia, Pasifik, dan Atlantik. Spesies ini memainkan peran penting dalam ekosistem laut sebagai predator tingkat trofik menengah, yang keberadaannya sangat penting untuk menjaga keseimbangan ekosistem laut.

Penelitian ini bertujuan untuk mengembangkan model distribusi spasial tuna mata besar di perairan Laut Banda menggunakan model MaxEnt dan data penginderaan jauh, serta mengevaluasi kontribusi variabel lingkungan seperti Chlo-a dan SST terhadap prediksi zona penangkapan. Dengan mengisi kesenjangan pengetahuan ini, penelitian diharapkan dapat memberikan kontribusi signifikan untuk pengelolaan perikanan yang lebih efektif dan berkelanjutan di Indonesia. Pertanyaan utama dalam penelitian ini adalah apakah model MaxEnt yang menggunakan variabel lingkungan seperti Chlo-a dan SST dapat secara akurat memprediksi distribusi spasial tuna mata besar di Laut Banda.

4.3.8.3.1 Evaluasi model

Kinerja model MaxEnt dalam memprediksi distribusi spasial tuna mata besar di perairan Laut Banda dan sekitarnya dievaluasi menggunakan kurva ROC dan metrik AUC. Nilai AUC yang diperoleh dari model dianalisis untuk menilai akurasi dan keandalan model dalam memprediksi distribusi spesies. Nilai metrik model MaxEnt untuk berbagai bulan ditunjukkan pada Tabel 4.12 di bawah ini.


Tabel 4.12 Evaluasi kinerja model MaxEnt - madidihang

n presences	n absences	Cor	max TPR TNR at
1	1,000	0.11	0.55
1	1,000	0.25	0.60




Maret	556	1,000	0.23	0.74
April	416	999	0.25	0.69
Mei	221	1,000	0.36	0.66
Juni	207	1,000	0.32	0.50
Juli	170	1,000	0.42	0.60
Agustus	96	1,000	0.05	0.66
September	141	1,000	0.13	0.61
Oktober	248	1,000	0.20	0.69
November	240	1,000	0.13	0.53
Desember	336	1,000	0.21	0.59

Nilai AUC ditunjukkan pada Gambar 4.45 berikut (Gambar selengkapnya Terlampir 3.7).




(a)





(b)



(c)

Gambar 4.54 Visualisasi nilai AUC untuk distribusi spasial tuna mata besar: (a) Mei, (b) Juni dan (c) Juli




digunakan pada Tabel 4.12 di atas mencakup keberadaan dan
 a, AUC, korelasi, dan max_TPR+TNR_at. AUC merupakan

metrik utama yang menunjukkan kemampuan model untuk membedakan lokasi keberadaan dan ketidakhadiran spesies. Nilai AUC yang mendekati 1 menunjukkan akurasi prediksi model yang tinggi, sedangkan nilai yang mendekati 0.5 menunjukkan prediksi acak. Nilai AUC yang lebih tinggi (dalam hal ini, 0.83 pada bulan Juli) menunjukkan kinerja model yang sangat baik dalam mendeteksi keberadaan dan ketidakhadiran tuna mata besar. Korelasi mengukur hubungan linier antara prediksi model dan data observasi, di mana nilai yang lebih tinggi menunjukkan kesesuaian yang lebih baik. Tabel ini mencatat korelasi tertinggi pada bulan Juli (0.42), yang menunjukkan bahwa prediksi model secara bulanan sejalan dengan data observasi. Max_TPR+TNR_at mengombinasikan True Positive Rate (TPR) dan True Negative Rate (TNR) untuk menentukan ambang batas prediksi yang optimal. Nilai tertinggi untuk metrik ini terlihat pada bulan Maret (0.74), yang menunjukkan keseimbangan terbaik antara deteksi keberadaan dan ketidakhadiran spesies pada bulan tersebut.

4.3.8.3.2 Prediksi Distribusi Spasial Bulanan


Dalam penelitian ini, prediksi distribusi spasial ikan tuna mata besar dilakukan menggunakan model MaxEnt untuk setiap bulan dari tahun 2014 hingga 2022, seperti yang ditunjukkan pada Gambar 4.55 (Gambar peta selengkapnya Terlampir 3.8). Peta distribusi yang dihasilkan menunjukkan area potensial keberadaan tuna mata besar di perairan Laut Banda dan sekitarnya, berdasarkan faktor lingkungan, yaitu konsentrasi Chlo-a dan SST. Pola distribusi bulanan dianalisis untuk mengidentifikasi variasi musiman dan tren distribusi tuna mata besar. Area dengan probabilitas keberadaan tuna mata besar yang tinggi berhasil diidentifikasi, menunjukkan kemampuan model untuk menangkap pola ekologis signifikan yang dipengaruhi oleh kondisi lingkungan.

Pred. Distribution of BET May




(a)

Pred. Distribution of BET Jun



(b)

Pred. Distribution of BET Jul



(c)

Gambar 4.55 Prediksi distribusi tuna mata besar di perairan Laut Banda dan sekitarnya: (a) Mei; (b) Juni; dan (c) Juli



i hingga Desember, prediksi distribusi spasial tuna mata besar
da dan sekitarnya menggunakan model MaxEnt menunjukkan

variasi probabilitas keberadaan di berbagai wilayah dengan nilai yang berfluktuasi sepanjang tahun. Pada bulan Januari, area dengan probabilitas tinggi (0.7) tersebar terutama di bagian tengah wilayah. Pada bulan Februari, probabilitas tertinggi mencapai sekitar 0.8 di bagian tengah. Pada bulan Maret, probabilitas tertinggi mencapai 0.8, sementara pada April, probabilitas tersebar merata dengan nilai tertinggi mencapai 0.6. Dari Mei hingga Juni, distribusi dengan probabilitas tinggi menjadi lebih terfragmentasi, dengan dominasi warna hijau muda dan merah muda (0.2-0.6), yang menunjukkan probabilitas rendah keberadaan tuna mata besar di sebagian besar wilayah. Pada bulan Juli, probabilitas tertinggi mencapai 0.6, sedangkan pada Agustus dan September, distribusi mulai meningkat kembali dengan nilai sekitar 0.7 hingga 0.9 di beberapa wilayah. Pada Oktober, probabilitas tertinggi mencapai 0.7. Bulan November menunjukkan distribusi yang lebih merata dengan nilai berkisar antara 0.3 hingga 0.9, sementara pada Desember, terjadi peningkatan area dengan probabilitas tinggi hingga 0.8, terutama di bagian barat laut dan tengah, menunjukkan konsentrasi tuna mata besar yang lebih besar di wilayah tersebut menjelang akhir tahun.

4.3.8.3.3 Variabilitas Temporal dan Distribusi Ikan


Dalam hal variabilitas temporal pada kondisi lingkungan dan distribusi tuna mata besar, konsentrasi Chlo-a dan SST menunjukkan variasi signifikan dari Januari hingga Desember. Pada bulan Januari, konsentrasi Chlo-a berkisar antara 0.08-2.16 mg/m³ dan SST 27.73-33.34°C; pada Februari, Chlo-a 0.059-0.72 mg/m³ dan SST 27.44-33.25°C; pada Maret, Chlo-a 0.061-1.83 mg/m³ dan SST 28.31-32.86°C; pada April, Chlo-a 0.082-8.39 mg/m³ dan SST 28.85-31.18°C; pada Mei, Chlo-a 0.075-3.07 mg/m³ dan SST 28.87-32.31°C; pada Juni, Chlo-a 0.068-2.98 mg/m³ dan SST 27.93-30.32°C; pada Juli, Chlo-a 0.15-1.26 mg/m³ dan SST 26.43-29.97°C; pada Agustus, Chlo-a 0.14-1.68 mg/m³ dan SST 26.20-30.53°C; pada September menunjukkan puncak Chlo-a tertinggi dengan kisaran 0.14-7.81 mg/m³ dan SST 26.89-30.51°C; pada Oktober, Chlo-a 0.058-1.63 mg/m³ dan SST 28.43-32.78°C; pada November, Chlo-a 0.044-1.72 mg/m³ dan SST 29.86-32.03°C; dan pada Desember, Chlo-a 0.090-4.42 mg/m³ dan SST 27.68-33.67°C. Variasi ini mencerminkan perubahan kondisi lingkungan laut sepanjang tahun, dengan puncak Chlo-a terjadi pada bulan April dan September, serta fluktuasi SST yang menunjukkan pola musiman yang memengaruhi distribusi tuna mata besar di wilayah ini.

4.3.8.3.4 Respon Model terhadap Variabel Lingkungan


Untuk memahami lebih dalam, analisis dilakukan terhadap respon model MaxEnt terhadap setiap variabel lingkungan dan pengaruhnya terhadap distribusi spasial tuna mata besar. Kurva respon yang dihasilkan oleh fungsi response() dari paket dismo menggambarkan bagaimana probabilitas prediksi keberadaan tuna mata besar dengan tingkat Chlo-a dan SST yang bervariasi. Kurva ini akan menunjukkan ambang batas dan rentang optimal untuk setiap variabel, dan pada akhirnya, probabilitas keberadaan tuna mata besar menurun.



Respon model ini divisualisasikan pada Gambar 4.56 berikut (Gambar selengkapnya Terlampir 3.9).




(a)



(b)





(c)

Gambar 4.56 Respon model MaxEnt terhadap setiap variabel lingkungan: (a) Mei; (b) Juni; dan (c) Juli

Grafik di atas menunjukkan bahwa dari Januari hingga Desember, respon model MaxEnt terhadap variabel lingkungan Chlo-a (*layer.1*) dan SST (*layer.2*) memperlihatkan berbagai pola yang memengaruhi prediksi distribusi spasial tuna mata besar. Untuk variabel Chlo-a, respon model menunjukkan peningkatan prediksi keberadaan ikan pada konsentrasi sekitar 0 hingga 5, seperti terlihat pada lonjakan tajam di bulan Februari, April, dan November. Sebaliknya, model menunjukkan penurunan prediksi pada konsentrasi Chlo-a yang lebih rendah (sekitar -10 hingga -5), yang terjadi secara konsisten sepanjang tahun, terutama pada bulan Maret, Juni, dan Desember. Untuk variabel SST, respon model lebih bervariasi, dengan peningkatan signifikan prediksi keberadaan ikan pada rentang suhu 25-30°C, terutama pada bulan Februari, Mei, dan Agustus. Sebaliknya, suhu yang lebih tinggi sekitar 35-40°C di bulan April dan November menunjukkan penurunan prediksi keberadaan ikan. Beberapa bulan seperti Januari dan September menunjukkan pola di mana respon model tetap tinggi pada SST yang lebih rendah (sekitar 20-25°C), kemudian mengalami penurunan prediksi pada suhu yang lebih tinggi. Pola ini menunjukkan bahwa konsentrasi Chlo-a dan SST secara signifikan memengaruhi distribusi spasial tuna mata besar sepanjang tahun, dengan respon model bervariasi berdasarkan fluktuasi bulanan kedua variabel lingkungan tersebut.



ikansi model

ahami potensi keberadaan tuna mata besar sepanjang tahun, can untuk variabel Chlo-a dan SST. Pada bulan Januari, nilai

modus Chlo-a berkisar antara 0.12-0.14 mg/m³ dengan SST 29.58-29.63°C; Februari menunjukkan modus Chlo-a sebesar 0.098-0.15 mg/m³ dan SST 30.02°C; Maret memiliki modus Chlo-a sebesar 0.082-0.093 mg/m³ dan SST 30.04°C; April dengan modus Chlo-a sebesar 0.098 mg/m³ dan SST 30.05-30.44°C; Mei menunjukkan modus Chlo-a sebesar 0.11-0.12 mg/m³ dan SST 29.71°C; Juni dengan modus Chlo-a 0.11-0.13 mg/m³ dan SST 29.86-30.22°C; Juli menunjukkan modus Chlo-a sebesar 0.19 mg/m³ dan SST 27.6°C; Agustus memiliki modus Chlo-a sebesar 0.23 mg/m³ dan SST 27.24°C; September menunjukkan modus Chlo-a sebesar 0.17-0.19 mg/m³ dan SST 28.18°C; Oktober dengan modus Chlo-a sebesar 0.089-0.14 mg/m³ dan SST 30.37-30.66°C; November dengan modus Chlo-a sebesar 0.092 mg/m³ dan SST 31.09-31.10°C; dan Desember dengan modus Chlo-a sebesar 0.096-0.12 mg/m³ dan SST 31.33°C. Nilai-nilai ini menunjukkan bahwa potensi keberadaan tuna mata besar cenderung lebih tinggi pada bulan-bulan dengan konsentrasi Chlo-a yang lebih tinggi dan SST yang lebih dingin, terutama pada bulan Juli dan Agustus.

4.3.8.3.6 Pengaruh Variabel Lingkungan pada Model

Metrik Variable Contribution dan Permutation Importance digunakan untuk mengevaluasi pengaruh variabel lingkungan Chlo-a dan SST dalam model MaxEnt dari Januari hingga Desember. Variabel Chlo-a memberikan kontribusi tertinggi pada bulan Februari sebesar 96.18%, sedangkan SST memberikan kontribusi terbesar pada bulan September sebesar 84.70%. Untuk Permutation Importance, Chlo-a menunjukkan nilai tertinggi pada bulan Mei sebesar 90.84%, sedangkan SST memiliki nilai tertinggi pada bulan Januari sebesar 69.35%. Rata-rata kontribusi variabel Chlo-a adalah 67.91%, sedangkan SST adalah 32.09%. Rata-rata Permutation Importance untuk variabel Chlo-a adalah 61.86%, sedangkan SST adalah 38.14%. Kedua metrik ini digunakan untuk memahami peran dan pengaruh variabel dalam model, di mana Variable Contribution menunjukkan prioritas variabel selama pelatihan model, sedangkan Permutation Importance menggambarkan pengaruh variabel terhadap akurasi prediksi setelah pelatihan. Metrik ini ditampilkan pada Tabel 4.13 di bawah ini.

Tabel 4.13 Kontribusi variabel dan Permutation Importance

Month	Chlo Contribution (%)	SST Contribution (%)	Chlo Permutation Importance (%)	SST Permutation Importance (%)
January	28.82	71.18	30.65	69.35
February	96.18	3.82	88.87	11.13
March	46.08	53.92	41.34	58.66
April	95.52	4.48	80.98	19.02
May	85.85	14.15	90.84	9.16
June	69.40	30.60	55.00	45.00
July	31.10	68.90	37.64	62.36
August	70.34	29.66	58.06	41.94



September	15.30	84.70	24.65	75.35
October	92.57	7.43	62.84	37.16
November	95.05	4.95	90.34	9.66
December	88.73	11.27	82.99	17.01

Penelitian ini menggunakan model MaxEnt untuk memprediksi distribusi spasial tuna mata besar di Laut Banda, dengan variabel lingkungan utama yang digunakan adalah konsentrasi Chlo-a dan SST. Hasil evaluasi menunjukkan nilai AUC tertinggi sebesar 0.83 pada bulan Juli. Selain itu, probabilitas keberadaan tuna mata besar mencapai 0.9 di beberapa wilayah pada bulan-bulan tertentu, dengan korelasi tertinggi 0.42 juga tercatat pada bulan Juli.

4.4 Pembahasan

4.4.1 Klasterisasi area penangkapan ikan dengan nilai D ECDF

Penelitian ini memanfaatkan parameter oseanografi, khususnya konsentrasi klorofil-a (Chlo-a) dan Suhu Permukaan Laut (SST), untuk memetakan habitat potensial ikan di Wilayah Pengelolaan Perikanan (WPP) 714. Parameter tersebut menjadi dasar dalam penyusunan peta kluster area penangkapan ikan, yang diklasifikasikan ke dalam kategori Sangat Baik, Baik, Cukup Baik, dan Kurang Baik berdasarkan performansi model-model prediktif seperti GAM, ECDF, Random Forest, BRT, k-means (elbow method), dan MaxEnt (Bahri et al., 2017).

Setiap model memberikan gambaran karakteristik oseanografi yang berbeda dalam hubungannya dengan CPUE. Model GAM dan ECDF digunakan untuk melihat hubungan non-linear antara Chlo-a dan SST terhadap CPUE, sementara Random Forest dan BRT memperlihatkan kekuatan prediksi berbasis ensemble learning. K-means dengan metode elbow membantu menentukan jumlah kluster optimal berdasarkan variabilitas parameter lingkungan, sedangkan MaxEnt mengidentifikasi distribusi spasial habitat potensial ikan. Penentuan nilai optimal untuk masing-masing kriteria dilakukan dengan mengidentifikasi irisan spasial-temporal dari parameter-parameter ini, yang kemudian digabungkan menggunakan metode multifactor classification untuk menghasilkan peta final area tangkapan ikan yang optimal.

Pembuatan peta akhir dilakukan dengan metode multifactor classification, yang mengintegrasikan hasil klasterisasi parameter oseanografi. Teknik feature engineering digunakan untuk mengonversi data kontinu Chlo-a dan SST menjadi kategori diskrit menggunakan fungsi klorofil_to_kategori dan SST_to_kategori. Dataset ini kemudian digabungkan menggunakan ID unik, dan variabel baru Kategori_Baru dibentuk dengan menggabungkan kategori Chlo-a dan SST berdasarkan aturan klasifikasi berbasis logika (rule-based classification).

Hasil klasifikasi ini divisualisasikan secara spasial menggunakan ggplot2, memperlihatkan distribusi geografis dari kategori habitat ikan. Peta akhir menunjukkan irisan optimum dari parameter Chlo-a dan SST, yang didefinisikan sebagai area tangkapan ikan yang sangat baik. Temuan ini menunjukkan bahwa data oseanografi melalui pendekatan multifaktor dapat meningkatkan aktivitas penangkapan ikan dan mendukung pengelolaan



perikanan yang berkelanjutan di WPP 714. Pendekatan ini tidak hanya memperkuat analisis ekologis tetapi juga menyediakan dasar ilmiah yang kuat untuk pengambilan keputusan dalam pengelolaan sumber daya perikanan.

Klasifikasi nilai D dalam ECDF berperan penting dalam mengidentifikasi area dengan potensi tinggi untuk aktivitas feeding ikan pelagis. Nilai D yang tinggi mengindikasikan adanya perbedaan signifikan antara distribusi empiris data lapangan dengan distribusi referensi, yang dalam konteks ini diinterpretasikan sebagai area dengan kondisi lingkungan yang mendukung aktivitas feeding (Elepathage & Tang, 2019). Penggunaan metode ECDF dalam pemetaan area feeding memberikan fleksibilitas yang lebih besar dibandingkan model statistik berbasis asumsi teoritis, karena ECDF memanfaatkan distribusi empiris yang lebih sesuai dengan kondisi nyata di lapangan (He et al., 2021).

Salah satu keunggulan utama metode ECDF adalah kemampuannya untuk mengelompokkan data lingkungan seperti konsentrasi klorofil-a (Chlo-a) dan suhu permukaan laut (SST) dalam rentang optimal yang mendukung aktivitas *feeding* ikan pelagis (Putri et al., 2021). Area dengan nilai D tinggi menunjukkan kombinasi optimal antara parameter oseanografi tersebut, yang mencerminkan habitat ideal untuk spesies seperti cakalang dan madidihiang (Hidayat et al., 2021). Metode ini juga memiliki keunggulan dalam hal kesederhanaan implementasi dan interpretasi hasil, yang memungkinkan para peneliti dan praktisi perikanan untuk dengan mudah mengidentifikasi area dengan potensi tinggi untuk penangkapan ikan (Elepathage & Tang, 2019).

Selain kesederhanaannya, ECDF menunjukkan keunggulan dalam fleksibilitas analisis. Metode ini dapat diterapkan pada berbagai jenis data lingkungan, seperti Chlo-a dan SST, tanpa memerlukan asumsi awal mengenai distribusi data (Ma et al., 2022). Hal ini membuat ECDF lebih responsif terhadap perubahan kondisi lingkungan laut yang dinamis, menjadikannya alat yang efektif dalam pengelolaan perikanan yang berbasis data (Hidayat et al., 2021). Dengan mempertimbangkan berbagai parameter lingkungan dalam penghitungan nilai D, ECDF mampu meningkatkan akurasi dalam mengidentifikasi zona *feeding* yang optimal, mendukung perencanaan operasional perikanan yang lebih efisien (Putri et al., 2021).

Penggunaan ECDF dalam pemetaan area tangkapan ikan pelagis tidak hanya meningkatkan akurasi, tetapi juga memungkinkan integrasi data multisumber seperti SST dan Chlo-a. Integrasi ini sangat penting dalam menentukan area dengan kondisi optimal untuk aktivitas *feeding*, karena ikan pelagis sangat dipengaruhi oleh perubahan suhu dan ketersediaan fitoplankton (Schickele et al., 2020). Selain itu, metode ini memperkuat pengelolaan perikanan dengan menyediakan peta area tangkapan yang lebih terfokus dan representatif, sehingga dapat mengoptimalkan hasil tangkapan sambil menjaga kelestarian sumber daya laut (Hidayat et al., 2021).

Secara keseluruhan, metode ECDF memberikan pendekatan yang akurat, dan akurat dalam pemetaan area *feeding* ikan pelagis. menjadikannya alat yang efektif dalam pengelolaan perikanan dengan potensi besar untuk diterapkan dalam berbagai konteks yang dinamis dan kompleks (Hoffman et al., 2017; Wang & Bäck,



2018).

4.4.1.1 Chlo-a

Nilai D dalam ECDF digunakan untuk mengukur perbedaan antara distribusi empiris data sampel dan distribusi teoritis, sering diterapkan dalam Uji Kolmogorov-Smirnov untuk menilai kesesuaian distribusi data (Awan & Wang, 2022). Dalam analisis perikanan pelagis, nilai D membantu mengidentifikasi area dengan potensi penangkapan tinggi.

Pada ikan cakalang, klasterisasi berdasarkan nilai D menunjukkan bahwa konsentrasi Chlo-a yang tinggi berkorelasi dengan peningkatan aktivitas penangkapan. Chlo-a berfungsi sebagai indikator kesuburan perairan, karena berhubungan dengan kelimpahan fitoplankton yang mendukung populasi zooplankton sebagai pakan utama ikan pelagis (Tangke et al., 2021). Scatter plot menunjukkan variasi konsentrasi Chlo-a lebih tinggi pada nilai D_CakalangChlo yang rendah, sedangkan konsentrasi menjadi lebih seragam pada nilai D yang lebih tinggi. Pola ini mencerminkan dinamika lingkungan yang memengaruhi produktivitas primer dan distribusi ikan cakalang di perairan WPP 714 (Guo et al., 2021; Wang et al., 2023).

Pada ikan madidihiang, kategori dari ECDF membantu memetakan area penangkapan potensial di WPP 714, dengan fokus pada wilayah yang dikategorikan "Baik" dan "Sangat Baik" (Ferreira et al., 2022). Analisis menunjukkan bahwa peningkatan konsentrasi Chlo-a berkorelasi dengan potensi penangkapan ikan madidihiang, karena Chlo-a berperan dalam meningkatkan biomassa fitoplankton sebagai dasar rantai makanan laut (Cen et al., 2022). Scatter plot memperlihatkan bahwa pada nilai D_MadidihiangChlo yang rendah, variasi konsentrasi Chlo-a cukup tinggi, tetapi seiring meningkatnya nilai D, variasi tersebut menurun. Pola ini menunjukkan hubungan erat antara distribusi klorofil dengan dinamika lingkungan seperti suhu dan salinitas, yang secara signifikan memengaruhi produktivitas ekosistem laut (Wu et al., 2022; Li et al., 2023).

Untuk ikan tuna mata besar, penelitian menunjukkan bahwa peningkatan konsentrasi Chlo-a berkorelasi positif dengan jumlah tangkapan, seperti di perairan utara Aceh, di mana bulan November menunjukkan hasil tangkapan madidihiang yang lebih tinggi dibandingkan Desember (Irham et al., 2022). Pada analisis hubungan antara Chlo-a dan D_TunaMataBesarChlo, konsentrasi Chlo-a tertinggi terjadi saat D_TunaMataBesarChlo mendekati nol, terutama pada Kategori 4. Sebaliknya, peningkatan nilai D_TunaMataBesarChlo berkorelasi dengan penurunan Chlo-a, dominan di Kategori 1 dan 2. Ini menunjukkan hubungan negatif antara kedua variabel tersebut, yang menegaskan bahwa fluktuasi Chlo-a berperan sebagai indikator utama dalam menentukan lokasi penangkapan ikan tuna yang optimal (Abidin et al., 2020).



berbasis parameter lingkungan seperti suhu permukaan laut i dalam meningkatkan efisiensi penangkapan ikan cakalang di an menunjukkan bahwa ikan cakalang bermigrasi ke daerah

dengan SST optimal antara 28.3°C hingga 30.4°C, yang ideal untuk penangkapan yang efektif (Li et al., 2021; Abudarda et al., 2021). Analisis hubungan antara SST dan D_CakalangSST menunjukkan variasi antar kategori. Pada Kategori 1 (Sangat Baik), terjadi peningkatan D_CakalangSST seiring naiknya SST, sedangkan pada Kategori 4 (Kurang Baik), nilai D rendah saat SST tinggi tetapi meningkat ketika suhu lebih rendah. Pola ini mencerminkan preferensi habitat ikan cakalang terhadap suhu yang lebih rendah dan stabil, sejalan dengan penelitian sebelumnya tentang zona penangkapan optimal sepanjang tahun (Hidayat et al., 2019).

Untuk ikan madidihiang, penggunaan ECDF memungkinkan pemetaan lokasi feeding secara akurat, khususnya di wilayah dengan kondisi lingkungan yang dikategorikan "Baik" dan "Sangat Baik" (Sukresno et al., 2019). SST memainkan peran penting dalam distribusi madidihiang, di mana hasil tangkapan optimal terjadi pada rentang suhu 26°C hingga 29°C. Suhu di luar kisaran ini mengurangi efektivitas penangkapan karena ikan cenderung bermigrasi mencari habitat yang lebih sesuai (Sulistyowati et al., 2022; Nimit et al., 2020). Dari Januari hingga Desember, nilai D_MadidihiangSST menunjukkan fluktuasi musiman. Kondisi SST terbaik untuk penangkapan ditemukan pada bulan April hingga Juni dan Desember, dengan peningkatan area yang dikategorikan "Sangat Baik". Sebaliknya, bulan Juli dan Agustus menunjukkan penurunan kesesuaian SST untuk penangkapan, mencerminkan pengaruh musiman terhadap distribusi ikan.

Distribusi tuna mata besar juga dipengaruhi oleh variasi SST, dengan daerah penangkapan optimal ditemukan pada suhu sub-permukaan sekitar 16°C hingga 18°C (Achmad Fachruddin-Syah et al., 2020). Klasifikasi berdasarkan ECDF menunjukkan empat kategori utama. Kategori 1 (Sangat Baik) menunjukkan lingkungan optimal untuk aktivitas makan tuna mata besar, cakalang, dan madidihiang, menjadikannya hotspot perikanan potensial (Sukresno et al., 2019). Kategori 2 (Baik) menunjukkan korelasi kuat dengan CPUE, menandakan potensi feeding yang tinggi di daerah dengan kondisi lingkungan yang mendukung (Li et al., 2021). Kategori 3 (Cukup Baik) masih mendukung aktivitas feeding, meskipun dengan tingkat keberhasilan yang lebih rendah. Sementara itu, Kategori 4 (Kurang Baik) menunjukkan lingkungan yang kurang mendukung dengan tingkat penangkapan rendah (Sukresno et al., 2019). Data distribusi dari Januari hingga Desember menunjukkan bahwa Kategori 1 memiliki nilai D_TunaMataBesarSST yang tinggi pada suhu 29°C hingga 31°C, sementara Kategori 4 menunjukkan nilai yang sangat rendah pada suhu tinggi. Temuan ini menegaskan bahwa SST dan gradien suhu vertikal memainkan peran penting dalam menentukan lokasi dan jumlah tangkapan tuna mata besar (Cai et al., 2020).

4.4.1.3 Perbandingan Metrik

Berdasarkan analisis nilai Chlo-a, ikan cakalang dalam kategori 1 (Sangat Baik) memiliki rentang nilai antara 0.178–0.280 mg/m³, yang mencerminkan kelimpahan fitoplankton optimal untuk mendukung aktivitas perikanan. Rentang ini sesuai dengan hasil penelitian yang menunjukkan bahwa nilai Chlo-a antara 0.171–0.269 mg/m³ berkorelasi dengan habitat ideal tuna cakalang (Hsu et al., 2021). Untuk ikan madidihiang, nilai Chlo-a berada dalam kisaran 0.171–0.269 mg/m³, dibandingkan kategori Sangat Baik, namun masih memenuhi



kebutuhan ekosistem, sebagaimana didukung oleh studi yang menunjukkan rentang optimal Chlo-a hingga 0.35 mg/m³ untuk mendukung kelimpahan cakalang di perairan tropis (Zainuddin et al., 2023). Sementara itu, kategori 3 (Cukup Baik) menunjukkan variasi yang lebih besar dalam rentang nilai Chlo-a 0.163–0.639 mg/m³, yang mengindikasikan habitat dengan kondisi yang fluktuatif tetapi tetap memungkinkan untuk aktivitas perikanan. Terakhir, kategori 4 (Kurang Baik) mencerminkan nilai Chlo-a yang sangat ekstrem, yaitu 0.159–16.708 mg/m³, yang mencerminkan potensi penurunan kualitas habitat karena kondisi lingkungan yang tidak stabil dan sering kali kurang mendukung keberlanjutan ekosistem ikan cakalang (Putri & Zainuddin, 2019).

Berdasarkan nilai SST, ikan cakalang dalam kategori 1 (Sangat Baik) memiliki suhu optimal dengan kisaran 30.570–30.997 °C. Pada kategori 2 (Baik), suhu sedikit lebih rendah hingga 28.276–30.998 °C. Kategori 3 (Cukup Baik) menunjukkan kisaran suhu yang lebih bervariasi, yaitu 28.488–31.051 °C, sementara kategori 4 (Kurang Baik) dengan nilai ekstrem hingga 32.000 °C cenderung tidak ideal. Suhu optimal untuk ikan cakalang di perairan tropis mendukung rentang ini, sebagaimana dilaporkan bahwa suhu ideal cakalang berkisar antara 27.0–30.9 °C (Tangke et al., 2020).

Untuk ikan madidihang, kategori 1 memiliki suhu stabil antara 28.527–28.841 °C, sedangkan kategori 2 memiliki kisaran sedikit lebih tinggi, yaitu 28.528–29.079 °C. Kategori 3 menunjukkan variasi yang signifikan dengan rentang 26.927–29.289 °C, dan kategori 4 memiliki kisaran 29.386–32.654 °C yang terlalu tinggi untuk kondisi ideal. Penelitian lain menunjukkan bahwa madidihang menunjukkan preferensi suhu antara 28.3–30.4 °C (Abudarda et al., 2021).

Sementara itu, tuna mata besar dalam kategori 1 memiliki suhu optimal antara 29.372–29.639 °C, kategori 2 dengan rentang sedikit lebih rendah yaitu 28.589–29.915 °C, dan kategori 3 menunjukkan kisaran luas 27.000–30.660 °C. Kategori 4 memiliki suhu ekstrem 30.630–32.654 °C yang kurang mendukung habitat yang ideal. Studi serupa mendukung kisaran ini dengan menemukan bahwa suhu antara 28–30 °C optimal untuk tuna mata besar (Mediodia et al., 2020).

Berdasarkan kombinasi nilai Chlo-a dan SST, cakalang pada kategori 1 (Sangat Baik) memiliki nilai Chlo-a 0.178–0.280 mg/m³ dengan SST 30.570–30.997 °C, menciptakan lingkungan ideal dengan makanan yang cukup dan suhu optimal. Penelitian menunjukkan bahwa habitat cakalang yang optimal berada pada kisaran Chlo-a 0.15–0.28 mg/m³ dan SST 29.5–31.0 °C (Zainuddin et al., 2023). Pada kategori 2 (Baik), nilai Chlo-a 0.171–0.269 mg/m³ dengan SST 28.276–30.998 °C, menunjukkan kondisi yang masih mendukung tetapi sedikit kurang ideal dibandingkan kategori Sangat Baik. Pada kategori 3 (Cukup Baik), variasi nilai Chlo-a 0.1626–0.639 mg/m³ dengan SST 28.488–31.051 °C mencerminkan kondisi habitat yang kurang konsisten. Pada kategori 4 (Kurang Baik), nilai Chlo-a 0.159–16.708 mg/m³ dengan SST 31.073–32.000 °C

si ekstrem yang kurang mendukung. Untuk madidihang, kategori 1 memiliki Chlo-a 0.196–0.242 mg/m³ dengan SST 28.527–28.841 °C, ideal untuk habitat ikan. Habitat yang ideal ini didukung oleh kisaran Chlo-a 0.18–0.28 mg/m³ dan SST sekitar 28.3–30.4 °C (Abudarda et al., 2021).



al., 2021). Kategori 2 memiliki Chlo-a $0.156\text{--}0.176\text{ mg/m}^3$ dengan SST $28.528\text{--}29.079\text{ }^\circ\text{C}$, masih mendukung tetapi sedikit kurang optimal. Kategori 3 memiliki Chlo-a $0.1455\text{--}0.332\text{ mg/m}^3$ dengan SST $26.927\text{--}29.289\text{ }^\circ\text{C}$, menunjukkan variasi yang memengaruhi habitat. Pada kategori 4, Chlo-a mencapai $0.323\text{--}16.708\text{ mg/m}^3$ dengan SST $29.386\text{--}32.654\text{ }^\circ\text{C}$, mencerminkan kondisi ekstrem.

Untuk tuna mata besar, kategori 1 memiliki Chlo-a $0.130\text{--}0.144\text{ mg/m}^3$ dengan SST $29.372\text{--}29.639\text{ }^\circ\text{C}$, kondisi ini ideal untuk habitat ikan. Kategori 2 memiliki Chlo-a $0.125\text{--}0.202\text{ mg/m}^3$ dengan SST $28.589\text{--}29.915\text{ }^\circ\text{C}$, yang masih mendukung tetapi kurang optimal. Kategori 3 memiliki Chlo-a $0.142\text{--}0.321\text{ mg/m}^3$ dengan SST $27.000\text{--}30.660\text{ }^\circ\text{C}$, mencerminkan kondisi yang bervariasi. Pada kategori 4, Chlo-a $0.151\text{--}3.091\text{ mg/m}^3$ dengan SST $30.630\text{--}32.654\text{ }^\circ\text{C}$ menunjukkan kondisi ekstrem yang kurang mendukung (Setiawati et al., 2021).

4.4.2 Perbandingan metrik Fitting model RF (CPUE – factor oseanografis)

Model Random Forest untuk memprediksi CPUE dari tiga jenis ikan, yaitu cakalang, madidihang, dan tuna mata besar, menunjukkan perbedaan performa yang signifikan berdasarkan beberapa metrik seperti mean squared residuals (MSR), persentase variansi yang dijelaskan (% Var explained), IncNodePurity, dan Mean Squared Error (MSE) dari variabel Chlo-a dan SST. Pada cakalang, model menghasilkan MSR sebesar 3776.738 dengan persentase variansi yang dijelaskan sebesar 12.71%, di mana kontribusi Chlo-a terhadap kemurnian node (IncNodePurity) sebesar 14,704,170 lebih tinggi dibandingkan SST yang sebesar 9,104,236. Selain itu, MSE untuk Chlo-a (30,064.47) lebih besar dibandingkan SST (23,514.27), yang menunjukkan model lebih sulit memprediksi berdasarkan Chlo-a.

Pada madidihang, model menunjukkan performa lebih baik dengan MSR sebesar 737.295 dan persentase variansi yang dijelaskan mencapai 17.35%. Klorofil-a tetap menjadi variabel yang memberikan kontribusi lebih besar terhadap kemurnian node (IncNodePurity = 2,698,044) dibandingkan SST (IncNodePurity = 1,897,339). MSE Chlo-a sebesar 5,721.609 juga lebih besar daripada SST (3862.71), tetapi nilai keseluruhan MSE lebih rendah dibandingkan pada cakalang, yang mengindikasikan model ini lebih akurat dalam memprediksi CPUE.

Namun, pada tuna mata besar, performa model sangat terbatas dengan MSR sebesar 744.790 dan persentase variansi yang dijelaskan hanya 0.53%, menunjukkan kemampuan yang sangat rendah dalam menjelaskan variasi CPUE. IncNodePurity untuk Chlo-a sebesar 908,146.5 dan SST sebesar 537,055.3 jauh lebih rendah dibandingkan dua spesies lainnya, yang menandakan kedua variabel ini kurang relevan untuk prediksi CPUE pada spesies ini. MSE untuk Chlo-a (1,296.637) dan SST (1,422.451) juga lebih rendah, tetapi hal ini tidak diiringi dengan kemampuan prediksi yang memadai.

Secara keseluruhan, performa model terbaik dicapai pada madidihang, diikuti oleh cakalang, sedangkan tuna mata besar menunjukkan hasil yang paling rendah. Hal ini mengindikasikan bahwa hubungan antara CPUE dengan variabel oseanografis seperti Chlo-a dan SST bervariasi antar spesies, dengan SST secara konsisten lebih dominan dibandingkan Chlo-a.



4.4.3 Metrik model BRT pada CPUE – factor oseanografi

Model BRT digunakan untuk memprediksi CPUE pada cakalang, madidihiang, dan tuna mata besar, dengan hasil yang menunjukkan variasi signifikan dalam kontribusi variabel prediktor (Chlo-a dan SST) serta Mean Squared Error (MSE). Pada model untuk cakalang, Chlo-a memberikan kontribusi yang hampir seimbang dengan SST terhadap prediksi, dengan relevansi informasi sebesar 50.33% untuk Chlo-a dan 49.67% untuk SST. Namun, MSE untuk Chlo-a lebih besar (3,592.852) dibandingkan SST (941.041), mengindikasikan bahwa Chlo-a kurang presisi dalam memprediksi dibandingkan SST.

Pada madidihiang, SST menjadi variabel prediktor dominan dengan relevansi informasi sebesar 74.15%, jauh melebihi Chlo-a yang hanya sebesar 25.85%. Selain itu, MSE untuk SST jauh lebih rendah (47.4471) dibandingkan Chlo-a (530.0157), menegaskan bahwa SST lebih akurat dalam memprediksi CPUE untuk spesies ini.

Sebaliknya, pada tuna mata besar, kontribusi SST tetap lebih dominan dengan relevansi informasi sebesar 60.28% dibandingkan Chlo-a yang hanya 39.72%. Namun, MSE untuk Chlo-a (58.855) lebih kecil dibandingkan MSE untuk SST (496.212), yang mengindikasikan bahwa meskipun relevansi SST lebih tinggi, prediksi berbasis Chlo-a memiliki tingkat kesalahan yang lebih rendah.

Secara keseluruhan, hasil model BRT menunjukkan bahwa kontribusi dan akurasi variabel prediktor bergantung pada spesies ikan yang dianalisis, dengan SST cenderung memiliki relevansi lebih tinggi, terutama pada madidihiang dan tuna mata besar, sementara cakalang menunjukkan relevansi yang hampir seimbang antara kedua variabel.

4.4.4 Perbandingan metrik Model RF dan BRT

Perbedaan hasil pemodelan menggunakan Random Forest dan BRT dapat dijelaskan melalui sifat algoritma dan metode keduanya. RF menggabungkan prediksi dari banyak pohon keputusan menggunakan teknik bootstrapping, memberikan bobot tinggi pada variabel yang konsisten memiliki kontribusi signifikan. Hal ini dapat menjelaskan mengapa variabel klorofil (Chlo) lebih berpengaruh dalam RF, karena berkorelasi langsung dengan produktivitas primer yang mendukung ketersediaan makanan bagi spesies seperti Cakalang dan Tuna Mata Besar (Mugo & Saitoh, 2020).

Sebaliknya, BRT, yang membangun pohon secara iteratif untuk memperbaiki kesalahan prediksi sebelumnya, lebih sensitif terhadap hubungan non-linear dan interaksi antar variabel. Dalam BRT, SST menunjukkan pengaruh yang lebih besar, terutama pada spesies seperti Madidihiang dan Tuna Mata Besar, karena pola hubungan non-linear dan pengaruh langsung terhadap habitat serta perilaku spesies tersebut (Yang et al., 2022).

Selain itu, distribusi data dan sensitivitas ekologis spesies terhadap variabel lingkungan juga memengaruhi hasil. Umumnya SST cenderung memiliki pengaruh yang lebih signifikan pada habitat atau pola migrasi Madidihiang, sementara Chlo-a lebih berpengaruh pada ketersediaan makanan yang ditunjukkan oleh (Yang et al., 2022). Dengan demikian, sifat algoritma, interaksi antar



variabel, dan karakteristik ekologis spesies berperan penting dalam menghasilkan perbedaan pengaruh variabel antara kedua model ini.

4.4.5 Perbandingan Model RF, BRT, dan GAM (berat_ikan_pred ~ s(Chlo) + s(SST))

Perbandingan prediksi berat ikan berdasarkan konsentrasi Chlo-a pada cakalang, madidihang, dan tuna mata besar, menggunakan tiga pemodelan berbeda: BRT, RF, dan GAM. Secara umum, ketiga model menunjukkan tren yang berbeda dalam memprediksi berat ikan berdasarkan kadar klorofil-a. Model BRT cenderung menghasilkan prediksi yang stabil, sementara model RF menunjukkan variasi yang lebih besar, terutama pada kadar klorofil-a yang rendah. Model GAM, di sisi lain, menghasilkan pola yang lebih halus dan moderat dibandingkan RF.


Pada spesies Cakalang, prediksi berat ikan oleh model RF menunjukkan fluktuasi tajam pada kadar klorofil-a rendah ($0-1 \text{ mg/m}^3$), sedangkan model BRT dan GAM lebih stabil. Ketika kadar klorofil-a meningkat ($>2 \text{ mg/m}^3$), semua model menunjukkan stabilitas dengan prediksi berat ikan yang lebih rendah. Sementara itu, untuk spesies Madidihang, model RF juga memperlihatkan variasi signifikan pada kadar klorofil-a rendah, terutama dalam rentang $0-1 \text{ mg/m}^3$. Model BRT dan GAM menunjukkan pola yang lebih stabil, dengan kecenderungan kenaikan berat ikan seiring bertambahnya kadar klorofil-a. Adapun pada spesies Tuna Mata Besar, model RF menunjukkan pola fluktuatif yang lebih jelas pada kadar klorofil-a rendah, namun cenderung merata setelah mencapai 1 mg/m^3 . Model BRT tetap memberikan prediksi yang lebih linear dan stabil, sementara model GAM menunjukkan pola yang sedikit menurun pada kadar klorofil-a yang lebih tinggi.

Hasil ini menunjukkan bahwa model RF lebih sensitif terhadap perubahan kadar klorofil-a dibandingkan dua model lainnya, terutama pada nilai rendah. BRT memberikan prediksi yang lebih konservatif dan stabil, sedangkan GAM menunjukkan tren yang lebih fleksibel dibandingkan BRT tetapi lebih halus dibandingkan RF. Dari sudut pandang ekologi, fluktuasi yang terlihat pada model RF dapat mengindikasikan bahwa ikan lebih banyak ditemukan di daerah dengan konsentrasi klorofil-a rendah hingga sedang, sementara daerah dengan kadar klorofil-a tinggi nampaknya kurang optimal bagi spesies ini. Hal ini dapat dikaitkan dengan faktor lingkungan lain seperti suhu, arus laut, dan ketersediaan makanan yang memengaruhi distribusi ikan pelagis. Secara keseluruhan, hubungan antara klorofil-a dan berat ikan bersifat kompleks dan memerlukan analisis lebih lanjut untuk memahami faktor-faktor lain yang berkontribusi terhadap pola distribusi ikan di perairan. Pola hubungan non-linear antara konsentrasi Chlo-a dan berat ikan yang ditangkap, sebagaimana ditunjukkan oleh model GAM, sejalan dengan penelitian sebelumnya yang menunjukkan bahwa konsentrasi klorofil-a merupakan faktor penting dalam memprediksi distribusi dan hasil tangkapan ikan pelagis di berbagai wilayah perairan tropis dan subtropis (Mondal et al., 2022) dan (Eleni et al., 2019).



Secara keseluruhan, model GAM lebih sensitif dalam menangkap pola yang menunjukkan adanya puncak berat ikan pada konsentrasi Chlo-a dengan prinsip hubungan antara produktivitas primer dan Model RF menunjukkan ketidakstabilan pada konsentrasi

rendah, sementara model BRT memberikan prediksi stabil yang mungkin lebih berguna dalam aplikasi yang memerlukan prediksi sederhana tanpa memperhitungkan variasi lingkungan secara mendalam. Pola yang digambarkan di atas ditunjukkan pada Gambar 4.57 berikut.



Gambar 4.57 Hubungan model dengan hasil tangkapan (Chlo-a)

Adapun perbandingan prediksi berat ikan berdasarkan SST untuk cakalang, madidihang, dan tuna mata besar. Prediksi dilakukan menggunakan tiga model yang berbeda: BRT, RF, dan GAM. Hubungan tersebut memberikan gambaran mengenai respons berat ikan terhadap perubahan SST serta perbedaan karakteristik model dalam memprediksi hubungan tersebut.


Secara umum, model BRT menghasilkan prediksi yang lebih stabil dengan sedikit variasi, sedangkan model RF menunjukkan fluktuasi yang cukup besar, terutama pada rentang suhu tertentu. Sementara itu, model GAM menampilkan tren yang lebih fleksibel dibandingkan BRT tetapi tetap lebih halus dibandingkan RF. Pada spesies Cakalang, model RF menunjukkan fluktuasi berat ikan yang cukup tajam dalam rentang suhu 26–31°C, dengan beberapa lonjakan yang tidak terlihat pada model lain. Model BRT dan GAM, di sisi lain, menunjukkan pola yang lebih stabil, dengan sedikit kenaikan berat ikan di sekitar suhu 28–30°C sebelum kembali menurun. Sementara itu, pada spesies Madidihang, model RF juga memperlihatkan variasi yang tinggi, terutama dalam rentang suhu 27–30°C, dengan lonjakan tajam sekitar 30°C. Model BRT dan GAM tetap lebih stabil, menunjukkan sedikit kenaikan berat ikan pada suhu tertentu tetapi tanpa seperti pada RF. Adapun pada spesies Tuna Mata Besar, model RF menunjukkan variasi yang signifikan, dengan lonjakan tajam pada Sebaliknya, model BRT dan GAM memperlihatkan tren yang stabil dibandingkan RF.



Hasil ini menunjukkan bahwa model RF lebih sensitif terhadap perubahan SST, dengan pola prediksi berat ikan yang lebih fluktuatif dibandingkan dua model lainnya. BRT memberikan prediksi yang lebih konservatif, sedangkan GAM menawarkan keseimbangan antara fleksibilitas dan stabilitas. Dari sudut pandang ekologi, lonjakan berat ikan pada suhu tertentu dalam model RF dapat mengindikasikan bahwa ikan pelagis memiliki preferensi suhu yang optimal untuk pertumbuhan dan distribusi mereka. Namun, pola yang terlalu fluktuatif dalam model RF juga dapat mengindikasikan adanya overfitting terhadap data. Secara umum, ikan pelagis seperti cakalang, madidihang, dan tuna mata besar cenderung ditemukan dalam rentang suhu 26–30°C, meskipun faktor lingkungan lain seperti ketersediaan makanan, kedalaman perairan, dan arus laut juga berperan dalam menentukan distribusi dan berat ikan. Oleh karena itu, analisis lebih lanjut dengan mempertimbangkan faktor oseanografis lainnya diperlukan untuk memahami lebih dalam pola distribusi ikan berdasarkan SST.

Secara umum, model RF menunjukkan pola yang sangat fluktuatif pada ketiga jenis ikan, menandakan sensitivitas model ini terhadap variasi suhu permukaan laut. Model GAM menunjukkan pola yang lebih konsisten dan mengikuti hubungan ekologis antara suhu permukaan laut dan berat ikan, dengan pola peningkatan pada suhu menengah diikuti oleh penurunan di suhu yang lebih tinggi. Temuan ini konsisten dengan penelitian sebelumnya yang menunjukkan bahwa model GAM efektif dalam memprediksi distribusi habitat tuna dengan memanfaatkan parameter SST, di mana kenaikan suhu tertentu berhubungan dengan peningkatan berat dan kepadatan tangkapan ikan di berbagai perairan tropis (Mondal et al., 2022). Model BRT memberikan prediksi yang paling stabil dan linear, dengan sedikit perubahan prediksi meskipun terjadi variasi suhu. Dengan demikian, model GAM lebih baik dalam menangkap pola biologis yang realistis, sementara model RF tampaknya lebih sensitif terhadap data yang mungkin memiliki distribusi tidak merata, dan model BRT tetap memberikan hasil prediksi yang stabil tetapi kurang responsif terhadap perubahan suhu. Hubungan prediksi berat ikan berdasarkan SST ditunjukkan pada Gambar 4.58 berikut.





Gambar 4.58 Hubungan model dengan hasil tangkapan (SST)

4.4.6 Perbandingan nilai MSE Model RF, BRT, dan GAM

Untuk melihat kelayakan model, salah satunya menggunakan MSE (Mean Squared Error). Dalam hal ini dilakukan pengukuran MSE untuk menilai performa model GAM, BRT, dan Random Forest dibandingkan untuk memprediksi parameter klorofil dan suhu dengan metrik MSE untuk tiga jenis ikan, yaitu cakalang, madidihang, dan tuna mata besar.

Untuk prediksi klorofil, model GAM menghasilkan prediksi dengan MSE 1,104.01 untuk cakalang, 118.08 untuk madidihang, dan 7.41 untuk tuna mata besar. Model BRT menghasilkan MSE sebesar 3,592.85 untuk cakalang, 530.02 untuk madidihang, dan 58.85 untuk tuna mata besar. Sementara itu, model RF menghasilkan nilai MSE 30,046.77 untuk cakalang, 5,721.61 untuk madidihang, dan 1,281.59 untuk tuna mata besar.

Pada prediksi suhu, model GAM memiliki MSE 41.83 untuk cakalang, 355.68 untuk madidihang, dan 712.41 untuk tuna mata besar. Model BRT menghasilkan MSE sebesar 941.04 untuk cakalang, 47.45 untuk madidihang, dan 496.21 untuk tuna mata besar. Sementara model RF menunjukkan performa dengan MSE sebesar 23,504.12 untuk cakalang, 3,862.72 untuk madidihang, dan 1,404.12 untuk tuna mata besar.

Secara keseluruhan, model GAM cenderung memiliki performa yang lebih baik dalam hal MSE untuk prediksi klorofil dan suhu, terutama pada jenis ikan madidihang dan tuna mata besar, dibandingkan dengan model BRT dan RF.

Sementara itu, model RF menunjukkan MSE yang jauh lebih besar pada hampir semua parameter dibandingkan dengan model GAM dan BRT.



4.4.7 Fitting GAM dan ECDF pada hubungan CPUE dan faktor oseanografis

4.4.7.1 Model GAM pada aktivitas penangkapan cakalang

Hasil pemodelan menggunakan GAM menunjukkan bahwa intersep sebesar 125.20 dengan standar error 2.16 sangat signifikan secara statistik ($t = 57.95$, $p < 2e-16$) (Spiegel et al., 2019). Variabel $s(SST)$ menunjukkan signifikansi tinggi dengan $edf = 8.826$, $F = 6.639$, dan $p < 2e-16$, sedangkan $s(Chlo)$ tidak signifikan ($edf = 4.096$, $F = 1.444$, $p = 0.204$) (Liu et al., 2019). Meskipun demikian, model ini hanya mampu menjelaskan 0.37% dari variabilitas CPUE ($R\text{-squared adj} = 0.0037$) dengan deviance sebesar 0.443%, menunjukkan kecocokan model yang rendah (Gerling et al., 2019). Evaluasi lebih lanjut menggunakan Generalized Cross Validation (GCV) dan estimasi skala mengindikasikan adanya distribusi non-normal serta keberadaan outlier yang signifikan dalam data (Al-Talib & Hammodat, 2020).

Visualisasi data menunjukkan bahwa konsentrasi Chlo-a cenderung terkonsentrasi di dekat nol dengan beberapa outlier signifikan, sedangkan suhu permukaan laut (SST) berkisar di sekitar 30°C (He et al., 2021; Mashita & Lumban-Gaol, 2019). Boxplot dari Chlo-a menunjukkan variasi tinggi, yang kemungkinan dipengaruhi oleh fenomena iklim seperti El Niño atau La Niña (Ma et al., 2021). Penghapusan outlier dari model menunjukkan peningkatan $R\text{-squared}$ menjadi 0.0229 dan penurunan Akaike Information Criterion (AIC) dari 246,900.3 menjadi 128,618.3, yang menunjukkan peningkatan kecocokan model (Kilinc & Asfha, 2020).

Uji multikolinearitas mengungkapkan bahwa Chlo-a dan SST memiliki Generalized Variance Inflation Factor (GVIF) yang sangat tinggi ($8.7162e+20$), menunjukkan adanya korelasi kuat antar variabel yang dapat mempengaruhi stabilitas koefisien regresi dalam model (Kim, 2019). Hubungan antara Chlo-a dan CPUE bersifat negatif, menunjukkan bahwa peningkatan klorofil tidak selalu diikuti oleh peningkatan hasil tangkapan. Sebaliknya, SST menunjukkan hubungan positif terhadap CPUE, di mana peningkatan suhu cenderung meningkatkan hasil tangkapan (Mondal et al., 2022; Puspita et al., 2023).

Dari ketiga model yang diuji, Model 3 ($CPUE \sim s(Chlo) + s(SST)$) menunjukkan performa terbaik dengan $R\text{-squared adj}$ sebesar 0.0229 dan deviance explained sebesar 2.41%, meskipun nilai ini masih relatif rendah (Razib & Mustapha, 2019). Rendahnya performa model ini menunjukkan perlunya perbaikan dalam representasi data dan pengurangan multikolinearitas. Salah satu pendekatan yang direkomendasikan adalah penggunaan metode non-parametrik seperti ECDF yang lebih fleksibel terhadap distribusi data yang tidak normal (Aslam, 2019).

Analisis lebih lanjut menggunakan grafik ECDF dan Uji Kolmogorov-Smirnov (KS) menunjukkan adanya hubungan signifikan antara Chlo-a (0.280 mg/m^3) dan SST (30.57°C) dengan CPUE ikan cakalang di Laut Banda ($p < 0.05$) (Hong et al., 2021; Dimitrova et al., 2020). Selain itu, metode elbow dalam analisis

n bahwa kluster optimal berada pada kluster 4, yang dapat meningkatkan efisiensi dalam penangkapan ikan (Dowd, 2020). k hanya meningkatkan akurasi model, tetapi juga membantu strategi pengelolaan perikanan yang lebih efektif dan



berkelanjutan.

4.4.7.2 Model GAM pada aktivitas penangkapan madidihang

Hasil pemodelan dengan GAM menunjukkan bahwa intersep model sebesar 125.20 signifikan secara statistik ($t = 45.43$, $p < 2e-16$), menunjukkan bahwa CPUE tetap signifikan meskipun tanpa pengaruh variabel independen (Razib & Mustapha, 2019). Variabel SST berkontribusi signifikan terhadap variasi CPUE ($EDF = 8.665$, $F = 6.411$, $p < 2e-16$), sementara Chlo-a tidak menunjukkan signifikansi ($EDF = 4.096$, $F = 1.444$, $p = 0.204$) (Puspita et al., 2023). Distribusi Chlo-a yang didominasi nilai rendah dan distribusi SST yang menunjukkan skewness negatif mengindikasikan bahwa sebagian besar data berada pada suhu yang lebih tinggi dengan beberapa outlier di bawah 26°C (Muskananfola et al., 2021; Ma et al., 2021; Pelly et al., 2020). Penghapusan outlier meningkatkan kecocokan model, dengan peningkatan efisiensi dalam menjelaskan variabilitas data (Nugroho et al., 2020).

Evaluasi multikolinearitas melalui Variance Inflation Factor (VIF) mengindikasikan korelasi kuat antar variabel yang dapat mengganggu stabilitas model (Kim, 2019). Hubungan CPUE dengan Chlo-a menunjukkan fluktuasi signifikan, sedangkan SST optimal untuk peningkatan CPUE berada pada rentang $28-29^{\circ}\text{C}$, di mana hasil tangkapan lebih baik (Puspita et al., 2023; Mondal et al., 2022). Dari berbagai model yang diuji, Model 3 ($\text{CPUE} \sim s(\text{Chlo}) + s(\text{SST})$) menunjukkan performa terbaik dengan nilai t tertinggi (89.67), F -statistik tertinggi untuk SST (37.56) dan Chlo-a (7.79), serta R -squared adj sebesar 0.036. Model ini juga memiliki deviasi dijelaskan sebesar 3.74%, GCV terendah (147.59), dan AIC terendah (80,165.51), menunjukkan efisiensi prediksi yang lebih baik (Sasmitho et al., 2022; Han et al., 2022).

Analisis lebih lanjut menunjukkan bahwa Chlo-a tidak berpengaruh signifikan terhadap CPUE, sebagaimana terlihat pada kurva mendatar pada model GAM (Ravindra et al., 2019). Sebaliknya, SST menunjukkan pengaruh signifikan dengan pola non-linear, di mana CPUE meningkat pada perubahan SST tertentu (Liu et al., 2019). Ketika kedua variabel dikombinasikan, SST tetap dominan, sedangkan Chlo-a menunjukkan ketidakpastian tinggi. Secara keseluruhan, kinerja model masih rendah dengan Std. Error > 0.05 dan deviansi dijelaskan $< 50\%$, kemungkinan akibat multikolinearitas atau kurangnya variasi data (Dowd, 2020; Aslam, 2019).

Untuk mengatasi keterbatasan GAM, digunakan metode ECDF. Uji Kolmogorov-Smirnov menunjukkan hubungan signifikan antara Chlo-a (0.196 mg/m^3) dan SST (28.841°C) dengan CPUE ($p < 0.05$) (Hong et al., 2021). Analisis kluster menggunakan metode elbow menunjukkan nilai optimal Chlo-a pada $0.0748-0.334 \text{ mg/m}^3$ dan SST pada $28.68-30.30^{\circ}\text{C}$, yang mencerminkan kondisi lingkungan yang mendukung penangkapan ikan Madidihang di WPP 714 (Aslam, 2019). Pendekatan ini memberikan wawasan penting bagi pengelolaan perikanan

in berkelanjutan.



4.4.7.3 Model GAM pada aktivitas penangkapan tuna mata besar

Penelitian ini mengevaluasi pengaruh parameter oseanografi, yaitu Chlo-a dan SST, terhadap ekosistem laut dan hasil tangkapan ikan. Chlo-a mencerminkan produktivitas primer dan kesuburan perairan, yang berperan dalam rantai makanan laut (Christou et al., 2022), sementara SST memengaruhi distribusi, metabolisme, dan reproduksi ikan (Dvoretzky et al., 2023).

Identifikasi dan penanganan outlier dalam data Chlo-a dan SST dilakukan menggunakan pustaka 'e1071'. Distribusi frekuensi menunjukkan adanya outlier yang signifikan, dan metode ambang batas terbaik ($n = 1$) berhasil mengurangi kesalahan standar menjadi 0.062 dan meningkatkan deviasi yang dijelaskan hingga 7.23% (Yang et al., 2019). Model tanpa outlier menunjukkan performa lebih baik dengan nilai AIC lebih rendah (15,248.46) dibandingkan model dengan outlier (38,984.36), serta adjusted R-squared yang lebih tinggi (0.068 vs. 0.018), menandakan efisiensi model dalam menjelaskan variabilitas data (Kilinc & Asfha, 2020; Herawati et al., 2022).

Evaluasi pengaruh Chlo-a dan SST terhadap CPUE dilakukan menggunakan GAM. Variance Inflation Factor (VIF) mengindikasikan adanya multikolinearitas tinggi antar variabel, dengan nilai GVIF tak terbatas (Roozbeh et al., 2021). Visualisasi data menunjukkan bahwa peningkatan Chlo-a cenderung menurunkan CPUE, sementara SST menunjukkan fluktuasi dengan konsentrasi data tertinggi pada sekitar 29.62°C (Ningsih et al., 2021). Model 3 ($CPUE \sim s(Chlo) + s(SST)$) menunjukkan performa terbaik dengan R-squared 0.068, deviasi dijelaskan 7.23%, GCV 11.12, dan AIC 15,248.46, dengan signifikansi tinggi untuk kedua variabel (Puspita et al., 2023).

Meskipun begitu, model ini menunjukkan kinerja yang masih rendah (Std. Error > 0.05, deviasi dijelaskan < 50%), yang disebabkan oleh keterbatasan data dan multikolinearitas antar variabel (Yadav et al., 2022). Formula akhir GAM adalah $CPUE = 2.86 + s(Chlo, edf = 5.81) + s(SST, edf = 8.83)$, dengan nilai signifikan Chlo-a sebesar 0.542 mg/m³ dan SST sebesar 30.03°C. Untuk mengurangi bias model, digunakan metode ECDF (Zhong et al., 2022).

ECDF digunakan untuk mengevaluasi hubungan distribusi Chlo-a dan SST terhadap CPUE ikan tuna mata besar. Plot ECDF menunjukkan nilai maksimum Chlo-a sebesar 0.133 mg/m³ dan SST sebesar 29.64°C. Uji Kolmogorov-Smirnov mengindikasikan bahwa Chlo-a tidak signifikan ($p = 0.29$), sementara SST sangat signifikan ($p = 9.27e-21$), menunjukkan pengaruh kuat SST terhadap CPUE (Nanda et al., 2021).

Selanjutnya, analisis k-means clustering dan ANOVA menunjukkan adanya perbedaan signifikan antar klaster ($Pr(>F) < 2e-16$), dengan uji Tukey's HSD yang mengonfirmasi perbedaan antar kelompok ($p_{adj} = 0$). Klaster 2 diidentifikasi sebagai klaster terbaik dengan rata-rata CPUE tertinggi (12.11) dan median Chlo-a sebesar 0.201 mg/m³. Metode Elbow menunjukkan klaster optimal pada klaster ke-3 untuk Chlo-a dan klaster ke-4 untuk SST (Shi et al., 2020), nilai optimal Chlo-a antara 0.087–0.30 mg/m³ dan SST antara 29.62–30.03°C untuk aktivitas penangkapan tuna mata besar.

Hasil analisis sebelumnya juga menunjukkan bahwa kondisi lingkungan laut yang optimal terhadap hasil tangkapan tuna mata besar, dengan rentang optimal



Chlo-a antara 0.04–0.17 mg/m³ dan SST antara 24–28.7°C, yang bervariasi tergantung lokasi dan waktu penangkapan (Syah et al., 2019). Temuan ini menegaskan pentingnya pemahaman faktor lingkungan dalam pengelolaan perikanan berkelanjutan.

4.4.8 Perbandingan metrik model GAM, ECDF, elbow method, dan k-means

Analisis metrik model pada tiga jenis ikan, yaitu cakalang, madidihiang, dan tuna mata besar, menunjukkan pengaruh yang signifikan dari outlier terhadap kinerja model. Pada cakalang, penghilangan outlier meningkatkan performa model dengan pengurangan AIC sebesar 118,281.9 dan peningkatan deviance explained sebesar 1.97%. Mean Squared Error (MSE) untuk Chlo-a juga menurun drastis dari 15,634.70 menjadi 1,080.48, sementara MSE SST menurun dari 9,426.06 menjadi 39.81. Nilai signifikan untuk Chlo-a di perairan Laut Banda adalah 0.280 mg/m³, dengan rentang optimal 0.075 mg/m³ hingga 0.33 mg/m³, sementara nilai signifikan SST adalah 30.57°C, dengan rentang optimal 29.47°C hingga 30.47°C. Data ini menunjukkan relevansi tinggi Chlo-a dan SST dalam memprediksi penangkapan cakalang, terutama saat nilai-nilai lingkungan berada dalam rentang optimal.

Pada madidihiang, penghilangan outlier juga meningkatkan model secara signifikan. AIC menurun sebesar 85,757, dan deviance explained meningkat sebesar 3.17%. MSE Chlo-a menurun dari 2,191.948 menjadi 111.356, sementara MSE SST tetap rendah, yaitu dari 366.453 menjadi 375.040. Nilai signifikan Chlo-a di WPP 714 adalah 0.196 mg/m³, dengan rentang optimal 0.0748 mg/m³ hingga 0.334 mg/m³, dan nilai signifikan SST adalah 28.84°C, dengan rentang optimal 28.68°C hingga 30.30°C. SST tampak lebih relevan dalam memprediksi CPUE madidihiang dibandingkan Chlo-a, dengan nilai optimal SST yang mendekati rata-rata signifikan.

Untuk tuna mata besar, penghilangan outlier juga menghasilkan peningkatan performa model, dengan AIC menurun sebesar 23,735.9 dan deviance explained meningkat dari 2.14% menjadi 7.23%. MSE Chlo-a menurun dari 4,728.60 menjadi 58.855, sementara MSE SST menurun dari 496.212 menjadi 11.12. Nilai signifikan Chlo-a untuk tuna mata besar adalah 0.201 mg/m³, dengan rentang optimal 0.087 mg/m³ hingga 0.30 mg/m³, sedangkan nilai signifikan SST adalah 29.64°C, dengan rentang optimal 29.35°C hingga 30.45°C. Hasil ini mengindikasikan relevansi yang kuat dari faktor oseanografis terhadap prediksi CPUE tuna mata besar, dengan pengaruh yang hampir seimbang antara Chlo-a dan SST dalam rentang optimal.

Secara keseluruhan, penghilangan outlier terbukti meningkatkan performa model pada ketiga jenis ikan. Analisis ini menegaskan bahwa faktor oseanografis seperti Chlo-a dan SST memiliki pengaruh yang signifikan terhadap prediksi penangkapan ikan, dengan nilai optimal yang berbeda-beda sesuai dengan spesies dan wilayah perairan. Pendekatan seperti ECDF untuk nilai signifikan dan elbow method untuk nilai optimal menunjukkan efektivitas dalam faktor oseanografis dengan CPUE.



4.4.9 Model MaxEnt

4.4.9.1 Ikan cakalang

Penelitian ini memodelkan distribusi spasial ikan cakalang di Laut Banda menggunakan pendekatan *Maximum Entropy* (MaxEnt) dengan mempertimbangkan pengaruh parameter oseanografi seperti SST dan konsentrasi Chlo-a. Chlo-a mencerminkan produktivitas primer melalui kelimpahan fitoplankton, sedangkan SST menentukan habitat termal yang sesuai untuk cakalang (Hidayat et al., 2019; Putri & Zainuddin, 2019). Model MaxEnt dipilih karena kemampuannya dalam menangani data terbatas dan menghasilkan prediksi yang akurat pada berbagai skala spasial (Wan et al., 2019; Alsamadisi et al., 2020).

Evaluasi model menggunakan kurva ROC dan metrik AUC menunjukkan akurasi prediksi yang tinggi, dengan AUC tertinggi 0.82 pada Mei, mengindikasikan kemampuan model membedakan area keberadaan dan ketidakhadiran ikan cakalang secara efektif. Sebaliknya, nilai AUC terendah mendekati 0.5 menunjukkan prediksi acak, terutama pada bulan dengan kondisi lingkungan yang fluktuatif. Korelasi prediksi model dengan data observasi dan nilai $\max_TPR+TNR_at$ tertinggi pada Oktober (0.63) menunjukkan keseimbangan optimal dalam deteksi spesies (Syah et al., 2023).

Distribusi spasial ikan cakalang menunjukkan variasi musiman yang signifikan. Probabilitas keberadaan tertinggi terjadi pada Januari dan Desember (0.8), terutama di bagian utara dan tengah Laut Banda, sedangkan pada Februari hingga April, probabilitas menurun hingga 0.6. Periode Mei hingga Juli menunjukkan fragmentasi distribusi dengan probabilitas rendah (0.2), mengindikasikan penurunan keberadaan ikan. Dari Agustus hingga Oktober, probabilitas meningkat kembali (0.6–0.8), menunjukkan dinamika musiman yang konsisten dengan perubahan parameter oseanografi (Mugo & Saitoh, 2020).

Variabilitas temporal dalam Chlo-a dan SST juga memengaruhi distribusi ikan. Chlo-a menunjukkan puncak tertinggi pada September (0.084–6.93 mg/m³), sedangkan SST berkisar antara 26.19°C hingga 32.54°C sepanjang tahun. SST yang lebih rendah dan konsentrasi Chlo-a yang lebih tinggi, terutama pada Juli dan Agustus, menciptakan kondisi optimal untuk keberadaan cakalang (Hidayat et al., 2019; Syah et al., 2023). Model MaxEnt menunjukkan bahwa Chlo-a meningkatkan prediksi keberadaan ikan pada konsentrasi 5–10 mg/m³, dengan lonjakan signifikan pada Februari, April, dan Desember. Sebaliknya, SST tinggi (30–35°C) menurunkan prediksi keberadaan ikan, terutama pada bulan Maret, Juni, Agustus, dan Desember, sementara suhu lebih rendah (20–25°C) pada Juli meningkatkan prediksi (Wu et al., 2023).

Evaluasi kontribusi variabel menggunakan Variable Contribution dan Permutation Importance menunjukkan bahwa rata-rata kontribusi SST (67.31%) lebih besar dibandingkan Chlo-a (32.70%). Namun, Chlo-a memberikan kontribusi tertinggi pada Desember (81.01%), sedangkan SST mencapai 96.09% pada Juni.

bahwa kedua variabel tersebut memiliki peran penting dalam distribusi spasial ikan cakalang sepanjang tahun (Syah et al., 2023;).



Pola distribusi musiman ini menunjukkan adaptasi ikan cakalang terhadap perubahan lingkungan di Laut Banda. Wilayah dengan probabilitas tinggi keberadaan ikan cakalang berada di antara 122° hingga 130° BT, dipengaruhi oleh suhu air dan arus laut. Pola ini menunjukkan konsentrasi ikan di bagian utara pada awal dan akhir tahun, serta pergeseran ke timur dan selatan pada pertengahan tahun (Putri & Zainuddin, 2019).

Temuan ini memiliki implikasi penting dalam pengelolaan perikanan berkelanjutan. Identifikasi waktu dan lokasi penangkapan yang optimal dapat meningkatkan efisiensi penangkapan ikan dan mengurangi tekanan pada stok perikanan. Selain itu, hasil ini mendukung pendekatan pengelolaan berbasis ekosistem dengan memperhitungkan perubahan kondisi lingkungan untuk menjaga keberlanjutan sumber daya perikanan (Vayghan & Lee, 2022). Dengan mengidentifikasi area dengan probabilitas ikan rendah, pengelolaan dapat difokuskan pada upaya konservasi di wilayah yang memerlukan perlindungan lebih lanjut.

Secara keseluruhan, penelitian ini memberikan dasar ilmiah yang kuat untuk pengelolaan perikanan adaptif dan berkelanjutan di Laut Banda. Model MaxEnt yang digunakan berhasil memetakan distribusi spasial ikan cakalang dengan mempertimbangkan variabel lingkungan kunci, memperkuat pemahaman tentang dinamika ekosistem laut, dan mendukung praktik perikanan yang lebih ramah lingkungan (Wu et al., 2023).

4.4.9.2 Ikan madidihang

Pemodelan distribusi spasial madidihang di Laut Banda menggunakan metode MaxEnt menjadi kunci dalam memahami pengaruh faktor lingkungan terhadap habitat spesies ini. MaxEnt efektif dalam memprediksi area distribusi potensial berdasarkan data keberadaan dan variabel oseanografi seperti suhu permukaan laut (SST) dan konsentrasi Chlorophyll-a (Chlo-a) (Anand et al., 2021; Lin et al., 2023). Hasil pemodelan menunjukkan variasi musiman yang signifikan dalam distribusi madidihang, yang dapat mendukung pengelolaan perikanan berkelanjutan di wilayah tersebut (Sambah et al., 2023).

Evaluasi kinerja model menggunakan AUC (Area Under Curve) menunjukkan nilai tertinggi sebesar 0.71 pada Mei, yang mengindikasikan akurasi prediksi yang baik, sementara nilai AUC terendah menunjukkan adanya variabilitas lingkungan yang memengaruhi prediksi (Syah et al., 2020). Studi di perairan Aceh dan Samudra Hindia menunjukkan hasil serupa dengan AUC mencapai 0.96 dan >0.90, mengonfirmasi keandalan MaxEnt dalam memodelkan distribusi tuna (Siregar et al., 2019; Syah et al., 2020).

Distribusi spasial madidihang sepanjang tahun menunjukkan pola fluktuatif. Pada Januari, area dengan probabilitas keberadaan tinggi (0.7) ditemukan di bagian utara Laut Banda. Probabilitas ini meningkat pada Februari hingga 0.8 di barat laut, lalu menyebar merata dengan puncak 0.6–0.7 pada Maret. Mei–Juli menunjukkan penurunan distribusi dengan probabilitas yang kemudian meningkat kembali pada Agustus–Oktober (0.6–puncak pada Desember (0.8), terutama di wilayah barat laut (3).



Analisis metrik $n_presences$, $n_absences$, korelasi, dan $max_TPR+TNR_at$ memperkuat hasil model. Nilai $max_TPR+TNR_at$ tertinggi (0.64) pada Mei dan Agustus menunjukkan keseimbangan optimal dalam mendeteksi keberadaan dan ketidakhadiran spesies. Variabel lingkungan seperti SST dan Chlo-a terbukti memiliki pengaruh signifikan terhadap distribusi madidihang, mendukung upaya konservasi dan pengelolaan perikanan berkelanjutan (Rohner et al., 2023; Hidayat et al., 2019).

Variabilitas temporal dalam konsentrasi Chlo-a dan SST menunjukkan perubahan signifikan dari Januari hingga Desember, yang memengaruhi distribusi madidihang. Konsentrasi Chlo-a tertinggi tercatat pada Januari (0.11–8.29 mg/m³) dan September (0.086–6.93 mg/m³), sedangkan SST berfluktuasi antara suhu terendah 26.03°C pada Juli hingga tertinggi 32.95°C pada Oktober. Pola ini mencerminkan dinamika lingkungan laut yang berdampak langsung pada habitat madidihang.

Respons model MaxEnt terhadap variabel lingkungan menunjukkan bahwa prediksi keberadaan madidihang meningkat pada Chlo-a sekitar 5–10 mg/m³, terutama pada Februari, Mei, dan Desember. Sebaliknya, konsentrasi Chlo-a yang rendah (<0 mg/m³) mengurangi probabilitas keberadaan ikan. Untuk SST, prediksi meningkat signifikan pada suhu 30–35°C, terutama pada Januari, Juni, dan Oktober, sedangkan suhu yang lebih rendah (20–25°C) pada Juli dan Agustus menurunkan probabilitas keberadaan ikan. Hal ini menunjukkan bahwa SST dan Chlo-a memiliki pengaruh kompleks terhadap distribusi madidihang.

Penggunaan nilai modus untuk Chlo-a dan SST memberikan pemahaman lebih dalam tentang potensi keberadaan madidihang sepanjang tahun. Bulan-bulan seperti Juli (Chlo-a 0.18–0.34 mg/m³, SST 28.22°C) dan Agustus (Chlo-a 0.19–0.33 mg/m³, SST 27.25°C) menunjukkan potensi keberadaan ikan yang lebih tinggi, sejalan dengan kondisi lingkungan yang optimal. Sebaliknya, bulan-bulan dengan SST tinggi, seperti Oktober (30.19°C) dan Desember (31.25°C), menunjukkan distribusi madidihang yang lebih terbatas.

Evaluasi kontribusi variabel menggunakan *Variable Contribution* dan *Permutation Importance* menunjukkan bahwa Chlo-a memberikan kontribusi tertinggi sebesar 83.03% pada April, sedangkan SST menunjukkan kontribusi terbesar sebesar 87.11% pada Juni. *Permutation Importance* menunjukkan bahwa Chlo-a mencapai nilai tertinggi sebesar 68.79% pada Februari, sementara SST menunjukkan pengaruh terbesar pada Januari dengan 77.35%. Rata-rata kontribusi Chlo-a adalah 67.91%, sedangkan SST adalah 32.09%, menunjukkan bahwa kedua variabel tersebut memainkan peran penting dalam memprediksi distribusi madidihang.

Nilai AUC model menunjukkan fluktuasi kinerja sepanjang tahun, dengan nilai tertinggi 0.72 pada Juli dan terendah 0.60 pada April, September, dan Desember. Perbandingan dengan studi di Aceh dan Samudra Hindia menunjukkan bahwa model MaxEnt tetap andal meskipun ada variasi kondisi lingkungan (Syah et al., 2020).

Penelitian ini menemukan bahwa SST dan salinitas adalah variabel yang paling berpengaruh terhadap distribusi madidihang, khususnya selama musim hujan. Probabilitas keberadaan ikan lebih tinggi saat SST berada di



sekitar 29.5°C dan salinitas stabil di 33.7 psu. Temuan ini memiliki implikasi penting bagi pengelolaan perikanan di Laut Banda, dengan informasi tentang variasi spasial dan temporal distribusi madidihang yang dapat digunakan untuk menentukan waktu dan lokasi penangkapan optimal.

Secara keseluruhan, penelitian ini memberikan wawasan tentang pengaruh faktor lingkungan terhadap distribusi madidihang dan menyediakan dasar ilmiah untuk pengelolaan perikanan yang lebih adaptif dan berkelanjutan di perairan Indonesia. Dengan menggunakan model MaxEnt dan data lingkungan seperti Chlo-a dan SST, penelitian ini membantu dalam merencanakan strategi penangkapan yang efektif dan mendukung keberlanjutan sumber daya perikanan di wilayah ini.

4.4.9.3 Ikan tuna mata besar

Penelitian ini bertujuan memodelkan distribusi spasial tuna mata besar di Laut Banda menggunakan model MaxEnt dengan variabel lingkungan utama, yaitu konsentrasi Chlorophyll-a (Chlo-a) dan Suhu Permukaan Laut (SST). Tuna mata besar memiliki nilai ekonomi tinggi dan peran ekologis penting sebagai predator tingkat trofik menengah. Namun, tekanan eksploitasi yang meningkat menimbulkan kekhawatiran terhadap keberlanjutan populasi spesies ini di perairan Indonesia (Lin et al., 2023; Yang et al., 2020).

Model MaxEnt telah terbukti efektif dalam memprediksi distribusi tuna di berbagai wilayah. Studi sebelumnya oleh Syah et al. (2020) menunjukkan bahwa Chlo-a, SST, dan salinitas memengaruhi distribusi tuna mata besar di Samudra Hindia bagian timur. Namun, pemahaman lebih lanjut tentang interaksi variabel lingkungan dan distribusi tuna mata besar di perairan Indonesia, khususnya selama musim angin tenggara, masih diperlukan (Syah et al., 2019).

Evaluasi kinerja model menggunakan kurva ROC dan AUC menunjukkan hasil yang kuat. Nilai AUC tertinggi tercatat pada Juli (0.83), menunjukkan kinerja model yang sangat baik dalam membedakan keberadaan dan ketidakhadiran tuna mata besar. Nilai AUC mendekati 1 mencerminkan akurasi prediksi yang tinggi, sementara nilai mendekati 0.5 menunjukkan prediksi acak. Studi lain di Samudra Hindia menunjukkan nilai AUC serupa, yang menegaskan efektivitas MaxEnt dalam memodelkan distribusi tuna berdasarkan faktor lingkungan (Syah et al., 2020). Selain itu, korelasi tertinggi antara prediksi model dan data observasi tercatat sebesar 0.42 pada Juli, menunjukkan kesesuaian yang baik. Metrik *max_TPR+TNR_at*, yang menggabungkan *True Positive Rate* (TPR) dan *True Negative Rate* (TNR) untuk menentukan ambang prediksi optimal, menunjukkan nilai tertinggi sebesar 0.74 pada Maret, menandakan keseimbangan optimal dalam deteksi keberadaan dan ketidakhadiran spesies.

Variabel Chlo-a dan SST menunjukkan kontribusi yang signifikan dalam model. *Variable Contribution* menunjukkan bahwa Chlo-a memberikan kontribusi terbesar pada April (83.03%), sedangkan SST mendominasi pada Juni (87.11%). *Sensitivity Analysis* menunjukkan bahwa Chlo-a memiliki pengaruh terbesar (79%), sementara SST menunjukkan pengaruh tertinggi pada Maret (79%). Hal ini mengindikasikan bahwa kedua variabel tersebut



memainkan peran penting dalam memprediksi distribusi tuna mata besar, dengan variasi musiman yang signifikan.

Prediksi distribusi spasial tuna mata besar dari tahun 2014 hingga 2022 menunjukkan fluktuasi yang signifikan sepanjang tahun. Pada Januari dan Februari, area dengan probabilitas tinggi (hingga 0.8) terkonsentrasi di bagian tengah Laut Banda. Maret menunjukkan pola serupa dengan probabilitas tinggi, tetapi pada April, distribusi menjadi lebih merata dengan probabilitas tertinggi hanya mencapai 0.6. Dari Mei hingga Juni, area dengan probabilitas tinggi menjadi lebih terfragmentasi, menandakan penurunan keberadaan tuna di wilayah tersebut. Pada Agustus dan September, distribusi meningkat kembali dengan probabilitas mencapai 0.9 di beberapa wilayah. Pada Desember, terjadi peningkatan area dengan probabilitas tinggi hingga 0.8, terutama di bagian barat laut dan tengah Laut Banda.

Variabilitas lingkungan yang signifikan terlihat dari fluktuasi konsentrasi Chlo-a dan SST dari Januari hingga Desember. Puncak konsentrasi Chlo-a terjadi pada April (8.39 mg/m^3) dan September (7.81 mg/m^3), sementara SST berfluktuasi antara 26.20°C pada Agustus hingga 33.67°C pada Desember. Kurva respon dari model MaxEnt menunjukkan bahwa probabilitas keberadaan tuna mata besar meningkat pada konsentrasi Chlo-a sekitar 0 hingga 5 mg/m^3 , dengan lonjakan tajam pada Februari, April, dan November. Sebaliknya, pada konsentrasi Chlo-a yang lebih rendah (sekitar -10 hingga -5 mg/m^3), model menunjukkan penurunan prediksi keberadaan secara konsisten, terutama pada Maret, Juni, dan Desember. Respon model terhadap SST menunjukkan bahwa prediksi keberadaan tuna meningkat pada rentang suhu $25-30^\circ\text{C}$, dengan puncak prediksi pada Februari, Mei, dan Agustus. Sebaliknya, suhu yang lebih tinggi sekitar $35-40^\circ\text{C}$ pada April dan November menyebabkan penurunan probabilitas keberadaan tuna mata besar.

Analisis variabilitas temporal menunjukkan bahwa potensi keberadaan tuna mata besar cenderung lebih tinggi pada bulan-bulan dengan konsentrasi Chlo-a yang lebih tinggi dan SST yang lebih rendah, seperti pada Juli (Chlo-a 0.19 mg/m^3 , SST 27.6°C) dan Agustus (Chlo-a 0.23 mg/m^3 , SST 27.24°C). Sebaliknya, pada bulan-bulan dengan SST yang lebih tinggi, seperti November dan Desember ($>31^\circ\text{C}$), potensi keberadaan tuna menurun meskipun konsentrasi Chlo-a masih signifikan.

Hasil penelitian ini konsisten dengan studi sebelumnya oleh Syah et al. (2019), yang melaporkan bahwa Chlo-a adalah variabel lingkungan paling berpengaruh dalam memprediksi distribusi tuna mata besar di Samudra Hindia bagian timur, dengan nilai AUC lebih dari 0.80. Penelitian lain oleh Yang et al. (2020) di Samudra Atlantik juga menunjukkan bahwa distribusi tuna mata besar sangat dipengaruhi oleh SST dan konsentrasi Chlo-a, terutama pada kedalaman 100-400 m. Studi-studi ini menegaskan pentingnya pemantauan variabel oseanografi dalam pengelolaan perikanan tuna yang berkelanjutan.



Penelitian ini memiliki keterbatasan, yaitu hanya menggunakan Chlo-a dan SST) serta keterbatasan data keberadaan yang dapat meningkatkan akurasi prediksi, penelitian selanjutnya disarankan untuk menambahkan variabel tambahan seperti salinitas, arus laut, dan oksigen.

terlarut. Penggunaan data penginderaan jauh dan model prediktif seperti MaxEnt terbukti efektif dalam mendukung pengelolaan perikanan berkelanjutan melalui pemetaan distribusi spasial berbasis kondisi lingkungan.

Secara keseluruhan, penelitian ini tidak hanya memberikan pemahaman tentang faktor-faktor lingkungan yang memengaruhi distribusi tuna mata besar tetapi juga menawarkan pendekatan ilmiah untuk mendukung pengelolaan perikanan yang adaptif dan berkelanjutan di perairan Indonesia. Hanya saja, kajian terkait tuna pada penelitian ini relatif belum komprehensif, mengingat tuna mata besar dalam kajian ini terbatas pada Sea Surface Chlo-a (SSC) dan Sea Surface Temperature (SST) saja, padahal realitasnya tuna mata besar umumnya lebih banyak menghabiskan waktunya pada zona mesopelagis.

Tuna mata besar dikenal sebagai spesies ikan pelagis yang memiliki kemampuan untuk melakukan migrasi vertikal secara signifikan di kolom air. Berdasarkan berbagai penelitian, tuna mata besar paling banyak menghabiskan waktunya pada rentang kedalaman dominan 200-500 m. Tuna mata besar sering menyelam ke kedalaman ini untuk menghindari sinar matahari langsung dan pemangsa, sekaligus memanfaatkan suhu yang lebih stabil dan tingkat oksigen yang memadai di zona mesopelagis (200–500 m). penelitian di Samudra Hindia menunjukkan bahwa kedalaman sekitar 300–500 meter menjadi preferensi di siang hari untuk meminimalkan paparan suhu permukaan yang lebih tinggi (Mondal et al., 2022). Adapun pada malam hari, tuna mata besar biasanya naik ke zona epipelagis (0–200 m) untuk berburu mangsa yang bergerak ke permukaan saat fenomena migrasi vertikal diel. Studi di Samudra Pasifik Barat menunjukkan bahwa suhu permukaan sekitar 26–28°C dan konsentrasi klorofil-a menengah (0,3–0,6 mg/m³) menjadi faktor utama yang memengaruhi pola makan mereka di perairan dangkal (Elepathage & Tang, 2019). Tuna mata besar bahkan dapat menyelam hingga kedalaman lebih dari 1000 meter, meskipun waktu yang dihabiskan pada kedalaman ini relatif singkat dan terkait dengan aktivitas khusus seperti mencari mangsa atau menghindari predator.

4.4.9.4 Perbandingan metrik model MaxEnt

Model MaxEnt menunjukkan kinerja yang berbeda untuk ketiga spesies ikan, dengan nilai AUC yang mencerminkan akurasi prediksi distribusi spasialnya. Tuna mata besar memiliki AUC tertinggi sebesar 0.83 pada bulan Juli, menunjukkan kinerja model yang sangat baik, diikuti oleh cakalang dengan AUC 0.82 pada bulan Mei, dan madidihang dengan AUC 0.71 pada bulan yang sama. Pola distribusi spasial masing-masing spesies bervariasi sepanjang tahun. Cakalang menunjukkan fluktuasi yang dinamis, dengan probabilitas keberadaan tinggi (0.8) terlihat pada bulan Januari di bagian utara dan tengah serta kembali meningkat pada bulan Desember di wilayah utara dan timur. Namun, dari Mei hingga Juli, distribusi cakalang menjadi lebih terfragmentasi dengan dominasi probabilitas rendah (0.2). Madidihang, di sisi lain, memiliki distribusi yang lebih seragam di cakalang, dengan probabilitas tertinggi (0.8) muncul pada barat laut dan Desember di wilayah barat laut dan tengah. Tuna mata besar (0.2–0.4) mendominasi pada bulan Mei hingga Juli, dengan distribusi yang lebih terfragmentasi. Tuna mata besar menunjukkan



puncak probabilitas tertinggi hingga 0.9 pada bulan Agustus–September di wilayah tengah dan barat laut, menjadikannya spesies dengan distribusi paling terkonsentrasi pada momen-momen tertentu. Distribusi tuna mata besar menurun pada Mei–Juni, serupa dengan dua spesies lainnya, tetapi menunjukkan pemulihan cepat dengan lonjakan signifikan pada bulan Agustus. Secara keseluruhan, pola distribusi ketiga spesies ini menurun pada pertengahan tahun (Mei–Juli) dan meningkat kembali menjelang akhir tahun, dengan tuna mata besar menunjukkan kinerja model dan puncak distribusi tertinggi dibandingkan cakalang dan madidihiang.

Pada model MaxEnt di atas menunjukkan perbedaan pola distribusi dan preferensi lingkungan pada ketiga spesies ikan, yaitu cakalang, madidihiang, dan tuna mata besar, sepanjang tahun. Pada ikan cakalang, variabilitas lingkungan ditandai oleh konsentrasi Chlo-a tertinggi sebesar 6.93 mg/m^3 pada bulan September dan SST yang berfluktuasi antara 26.19°C hingga 32.54°C . Keberadaan cakalang cenderung lebih tinggi pada bulan Juli dan Agustus, ketika modus Chlo-a mencapai $0.15\text{--}0.39 \text{ mg/m}^3$ dan SST berada pada rentang yang lebih rendah, sekitar $27.19\text{--}28.68^\circ\text{C}$, mencerminkan preferensi terhadap suhu dingin dan konsentrasi Chlo-a sedang hingga tinggi. Untuk ikan madidihiang, puncak Chlo-a terjadi pada bulan Januari dan September, masing-masing mencapai 8.29 mg/m^3 dan 6.93 mg/m^3 , dengan SST bervariasi antara 26.03°C hingga 32.95°C . Madidihiang memiliki potensi keberadaan yang tinggi pada bulan Juli dan Agustus, dengan modus Chlo-a sebesar $0.18\text{--}0.34 \text{ mg/m}^3$ dan SST lebih rendah di sekitar $27.25\text{--}28.22^\circ\text{C}$, menunjukkan preferensi serupa terhadap lingkungan dengan suhu yang lebih dingin dan Chlo-a sedang. Sementara itu, tuna mata besar menunjukkan pola distribusi yang lebih dinamis dengan puncak Chlo-a mencapai 8.39 mg/m^3 pada April dan 7.81 mg/m^3 pada September, serta SST yang berfluktuasi antara 26.20°C hingga 33.67°C sepanjang tahun. Keberadaan tuna mata besar paling tinggi tercatat pada bulan Juli dan Agustus, ketika modus Chlo-a berada di rentang $0.19\text{--}0.23 \text{ mg/m}^3$ dan SST relatif rendah, sekitar $27.24\text{--}27.60^\circ\text{C}$, menandakan preferensi terhadap kondisi lingkungan serupa. Ketiga spesies ikan ini menunjukkan pola distribusi yang dipengaruhi oleh variasi temporal dalam Chlo-a dan SST, dengan Juli dan Agustus menjadi bulan-bulan penting karena kombinasi suhu dingin dan konsentrasi Chlo-a sedang menciptakan kondisi yang ideal untuk keberadaan mereka di Laut Banda.

Selain itu, model MaxEnt memberikan wawasan tentang pengaruh variabel lingkungan Chlo-a dan SST terhadap distribusi tiga spesies ikan, yaitu cakalang, madidihiang, dan tuna mata besar, melalui metrik Variable Contribution dan Permutation Importance. Metrik Variable Contribution mengukur seberapa besar variabel meningkatkan "gain" model selama pelatihan, sementara Permutation Importance mengevaluasi dampak variabel terhadap akurasi prediksi dengan menghitung degradasi kinerja saat nilai variabel diacak. Pada ikan cakalang, SST memberikan pengaruh yang lebih dominan dibandingkan Chlo-a,

kontribusi SST sebesar 67.31% dibandingkan Chlo-a yang hanya 32.95%. Hal ini terlihat pada Permutation Importance, di mana SST memiliki kontribusi sebesar 67.05% dibandingkan Chlo-a sebesar 32.95%. Puncak terjadi pada bulan Desember dengan nilai tertinggi sebesar



81.01%, sedangkan SST memberikan kontribusi tertinggi pada bulan Juni sebesar 96.09%. Ini menunjukkan bahwa SST menjadi faktor utama dalam menentukan distribusi cakalang, terutama pada pertengahan tahun, sementara Chlo-a lebih dominan pada akhir tahun. Berbeda dengan cakalang, pada ikan madidihiang, Chlo-a memiliki kontribusi yang lebih signifikan pada waktu-waktu tertentu. Chlo-a memberikan kontribusi tertinggi sebesar 83.03% pada bulan April, sementara SST memberikan kontribusi terbesar sebesar 87.11% pada bulan Juni. Untuk Permutation Importance, Chlo-a mencapai nilai puncaknya sebesar 68.79% pada bulan Februari, sedangkan SST memiliki nilai tertinggi sebesar 77.35% pada bulan Januari.

Hasil ini menunjukkan bahwa kedua variabel saling memengaruhi distribusi madidihiang dengan peran yang bergeser sepanjang tahun, di mana Chlo-a lebih dominan pada awal tahun, sementara SST lebih penting pada pertengahan tahun. Pada ikan tuna mata besar, Chlo-a menjadi variabel paling dominan dibandingkan SST, dengan rata-rata Variable Contribution sebesar 67.91% untuk Chlo-a dan hanya 32.09% untuk SST. Hal serupa terlihat pada Permutation Importance, di mana Chlo-a memiliki rata-rata pengaruh sebesar 61.86% dibandingkan SST sebesar 38.14%. Kontribusi Chlo-a mencapai puncaknya pada bulan Februari dengan nilai tertinggi sebesar 96.18%, sedangkan SST memberikan kontribusi tertinggi sebesar 84.70% pada bulan September. Untuk Permutation Importance, Chlo-a mencapai nilai tertinggi pada bulan Mei sebesar 90.84%, sedangkan SST tertinggi pada bulan Januari sebesar 69.35%. Ini menunjukkan bahwa Chlo-a memainkan peran dominan dalam memengaruhi distribusi tuna mata besar sepanjang tahun, terutama pada awal hingga pertengahan tahun, sementara SST menjadi lebih penting pada akhir tahun.

Secara keseluruhan, model MaxEnt mengungkapkan bahwa SST lebih dominan memengaruhi distribusi cakalang, sementara madidihiang menunjukkan keseimbangan pengaruh antara Chlo-a dan SST yang bergeser sepanjang tahun. Sebaliknya, tuna mata besar menunjukkan ketergantungan yang lebih tinggi pada Chlo-a, menjadikannya faktor utama dalam menentukan distribusinya. Pola ini mencerminkan adaptasi spesifik setiap spesies terhadap variabilitas lingkungan di Laut Banda sepanjang tahun.

4.5 Kesimpulan

Berdasarkan uraian pada pembahasan di atas, disimpulkan sebagai berikut:

1. Nilai D dalam ECDF efektif untuk mengidentifikasi area penangkapan ikan pelagis. Pada ikan cakalang dan madidihiang, peningkatan konsentrasi Chlo-a berkorelasi positif dengan aktivitas penangkapan, sementara tuna mata besar menunjukkan korelasi negatif, menunjukkan perbedaan dinamika lingkungan.
2. ECDF pada suhu permukaan laut (SST) menunjukkan bahwa SST distribusi dan efektivitas penangkapan ikan pelagis di WPP 714. madidihiang, dan tuna mata besar lebih banyak ditemukan pada dengan kategori "Sangat Baik" mengidentifikasi area dengan



potensi tangkapan tertinggi.

3. Distribusi spasial ikan cakalang, madidihang, dan tuna mata besar dipengaruhi oleh kombinasi konsentrasi Chlo-a dan SST. Suhu dan konsentrasi Chlo-a ekstrem cenderung mengurangi efektivitas habitat dan potensi penangkapan.
4. Perbedaan hasil antara Random Forest (RF) dan BRT disebabkan oleh sensitivitas spesies terhadap variabel lingkungan. RF lebih menonjolkan pengaruh Chlo-a, sementara BRT lebih sensitif terhadap SST, khususnya pada madidihang dan tuna mata besar.
5. Model GAM menunjukkan performa terbaik dalam memprediksi klorofil dan suhu untuk ikan pelagis, lebih efektif dibandingkan dengan BRT dan RF, yang menunjukkan kinerja prediksi yang kurang optimal.
6. Model GAM menunjukkan bahwa SST memiliki pengaruh signifikan terhadap aktivitas penangkapan ikan, sementara Chlo-a menunjukkan pengaruh yang lebih lemah. Model yang menggabungkan SST dan Chlo-a memberikan hasil terbaik, meskipun masih menghadapi tantangan multikolinearitas.
7. Penelitian ini memetakan distribusi spasial ikan cakalang di Laut Banda dengan menggunakan model MaxEnt, yang menunjukkan bahwa SST lebih berpengaruh daripada Chlo-a. Keberadaan ikan cakalang tertinggi ditemukan pada suhu rendah dan konsentrasi Chlo-a tinggi.
8. Model MaxEnt menunjukkan bahwa distribusi cakalang, madidihang, dan tuna mata besar dipengaruhi oleh SST dan Chlo-a, dengan pola distribusi musiman yang mencerminkan adaptasi spesifik setiap spesies terhadap perubahan lingkungan, yang mendukung pengelolaan perikanan yang lebih efektif..



BAB V

PEMETAAN LOKASI OPTIMUM PENANGKAPAN IKAN DI WPP 714

5.1 Pendahuluan

Perubahan lingkungan laut berpengaruh besar terhadap distribusi dan kelimpahan sumber daya perikanan, termasuk ikan pelagis besar seperti cakalang, madidihiang, dan tuna mata besar. Dua faktor lingkungan utama yang berperan dalam menentukan habitat optimal bagi spesies ini adalah klorofil-a (Chlo-a) dan suhu permukaan laut (SST). Klorofil-a merupakan indikator utama kelimpahan fitoplankton yang menjadi dasar rantai makanan di ekosistem laut, sementara SST berpengaruh terhadap metabolisme, pola migrasi, dan ketersediaan pakan bagi ikan. Pemahaman yang lebih mendalam mengenai hubungan antara variabel lingkungan ini dengan distribusi ikan sangat penting untuk mendukung pengelolaan perikanan yang berkelanjutan.

Beberapa penelitian telah menunjukkan bahwa masing-masing spesies tuna memiliki preferensi lingkungan yang khas, terutama dalam rentang nilai Chlo-a dan SST. Hasil penelitian ini (sebagaimana telah diungkap pada bab sebelumnya), menunjukkan bahwa cakalang cenderung ditemukan pada rentang Chlo-a 0.075–0.33 mg/m³ dan SST 29.47–30.47°C, madidihiang pada Chlo-a 0.0748–0.334 mg/m³ dan SST 28.68–30.30°C, sedangkan tuna mata besar lebih menyukai Chlo-a 0.087–0.30 mg/m³ dengan SST 29.35–30.45°C. Variabilitas lingkungan ini dapat berubah secara spasial dan temporal, sehingga diperlukan metode yang lebih komprehensif untuk mengidentifikasi pola distribusi yang lebih akurat.

Berbagai metode analisis data telah digunakan untuk memetakan hubungan antara faktor lingkungan dan distribusi ikan pada bab sebelumnya. Metode ECDF memungkinkan analisis distribusi kumulatif nilai Chlo-a dan SST untuk mengkategorikan habitat. Elbow Method dan K-Means Clustering digunakan untuk mengidentifikasi pola segmentasi habitat berdasarkan data numerik. Sementara itu, Maximum Entropy Model (MaxEnt) menawarkan pendekatan berbasis probabilistik untuk memprediksi keberadaan spesies berdasarkan faktor lingkungan utama. Kombinasi metode ini memberikan wawasan yang lebih luas terhadap pola distribusi ikan pelagis besar dan bagaimana perubahan lingkungan mempengaruhi ketersediaan habitatnya.

Untuk menginterpretasikan hasil analisis secara lebih sistematis, penelitian ini mengembangkan klasifikasi habitat berdasarkan empat kategori kondisi perairan, yaitu Sangat Baik, Baik, Cukup Baik, dan Kurang Baik. Rentang kategori ditentukan dengan menggabungkan hasil analisis statistik (Mean dan Standar Deviasi) serta distribusi ECDF, yang kemudian divalidasi untuk memastikan kesesuaian dengan data lapangan. Kategori ini memberikan



lebih jelas mengenai bagaimana kondisi lingkungan distribusi ikan dan memungkinkan pengelolaan sumber daya yang efektif.

ini bertujuan untuk menganalisis keterkaitan antara Chlo-a dan

SST dengan potensi distribusi ikan cakalang, madidihang, dan tuna mata besar menggunakan pendekatan berbasis Multi-Factor Classification (MFC), khususnya Dual-Factor Classification (DFC). Dengan pendekatan ini, penelitian diharapkan dapat menghasilkan peta distribusi habitat untuk setiap spesies serta peta overlay yang menunjukkan area dengan kondisi habitat optimal secara keseluruhan. Hasil penelitian ini akan memberikan kontribusi penting dalam pengelolaan perikanan berbasis ekosistem dan pemanfaatan sumber daya tuna secara lebih berkelanjutan.

5.2 Metodologi

5.2.1 Batasan Penelitian

Penelitian ini memiliki beberapa batasan kajian. Analisis hanya berfokus pada dua variabel lingkungan utama, yaitu klorofil-a (Chlo-a) dan suhu permukaan laut (SST), tanpa mempertimbangkan faktor lain seperti salinitas, arus laut, dan ketersediaan pakan. Metode yang digunakan terbatas pada ECDF, Elbow Method, K-Means Clustering, dan MaxEnt, tanpa melibatkan pendekatan pemodelan lain seperti hidrodinamika atau machine learning lanjutan. Klasifikasi habitat didasarkan pada Mean dan Standar Deviasi (SD) dengan validasi ECDF, namun tidak mencakup faktor biologis seperti kepadatan populasi ikan. Penelitian ini juga memiliki keterbatasan dalam cakupan spasial dan temporal, sehingga hasilnya mungkin tidak sepenuhnya mencerminkan dinamika lingkungan dalam jangka panjang. Selain itu, validasi hasil dilakukan secara statistik tanpa verifikasi langsung melalui survei lapangan. Model MFC dan Dual-Factor Classification (DFC) yang digunakan hanya mempertimbangkan dua variabel utama, sehingga hasil pemetaan lebih berfokus pada potensi distribusi ikan, bukan kelimpahan stok ikan secara langsung. Meskipun demikian, penelitian ini tetap memberikan wawasan awal yang berguna bagi pengelolaan perikanan berbasis lingkungan.

Tujuan uraian pada bab ini adalah untuk: 1) Menganalisis efektivitas metode Multifactor Classification dalam menilai kondisi ekosistem dan potensi perikanan pelagis berdasarkan faktor utama seperti Chlorophyll-a (Chlo-a) dan Sea Surface Temperature (SST), serta mengevaluasi keterbatasannya dalam mempertimbangkan faktor lingkungan lainnya. 2) Mengevaluasi kemampuan model dalam merepresentasikan kondisi aktual hasil tangkapan ikan dan menjelaskan dinamika upwelling di Laut Banda selama musim angin tenggara, dengan mempertimbangkan pengaruh variabilitas iklim global dan menerapkan pendekatan temporal yang lebih rinci untuk meningkatkan akurasi prediksi. 3) Merumuskan strategi penangkapan ikan pelagis yang adaptif terhadap fluktuasi musiman dan spasial di WPP 714 dengan memanfaatkan analisis distribusi spasial, pengaruh Chlo-a dan suhu. 4) Menilai akurasi model dalam memprediksi distribusi ikan berdasarkan karakteristik oseanografi, serta memahami hubungan antara ukuran ikan dan kondisi habitat untuk mendukung pengelolaan perikanan yang lebih efisien dan berkelanjutan.



5.2.2 Data

Penelitian ini menganalisis hubungan antara klorofil-a (Chlo-a) dan suhu permukaan laut (SST) dengan distribusi ikan cakalang, madidihang, dan tuna mata besar menggunakan kombinasi metode statistik dan klasifikasi berbasis data. Metode yang digunakan mencakup ECDF, Elbow Method, K-Means Clustering, dan MaxEnt untuk mengidentifikasi pola habitat optimal. Habitat diklasifikasikan dalam empat kategori: Sangat Baik, Baik, Cukup Baik, dan Kurang Baik, dengan rentang yang ditentukan berdasarkan Mean dan Standar Deviasi (SD) serta validasi menggunakan ECDF.

Data yang digunakan dalam penelitian ini berasal dari citra satelit oseanografi (MODIS, VIIRS), laporan hasil tangkapan perikanan, serta database oseanografi global seperti NOAA dan Copernicus Marine Service. Hasil penelitian menghasilkan peta distribusi habitat untuk setiap spesies ikan serta peta overlay yang menunjukkan area dengan kondisi habitat optimal. Pendekatan ini diharapkan dapat memberikan wawasan yang lebih mendalam dalam pengelolaan perikanan yang berkelanjutan.

5.2.3 Metode Penelitian

Penelitian ini menggunakan kombinasi metode statistik dan klasifikasi berbasis data untuk memahami hubungan antara klorofil-a (Chlo-a) dan suhu permukaan laut (SST) dengan potensi distribusi ikan cakalang, madidihang, dan tuna mata besar. Metode yang digunakan meliputi ECDF untuk analisis distribusi kumulatif, Elbow Method dan K-Means Clustering untuk segmentasi habitat, serta Maximum Entropy Model (MaxEnt) untuk memprediksi distribusi spesies berdasarkan faktor lingkungan. Hasil dari metode ini menunjukkan bahwa setiap spesies memiliki rentang optimal Chlo-a dan SST yang khas, dengan variasi pola distribusi tergantung pada metode yang digunakan.

Untuk mengklasifikasikan habitat, digunakan pendekatan berbasis statistik dengan empat kategori kondisi perairan: Sangat Baik, Baik, Cukup Baik, dan Kurang Baik. Rentang kategori ditentukan dengan kombinasi hasil statistik dan distribusi ECDF, dihitung menggunakan Mean dan Standar Deviasi (SD) dari hasil analisis K-Means dan Elbow Method. Kategori Sangat Baik memiliki rentang sempit ($\text{Mean} \pm 0.5 \text{ SD}$), diikuti oleh Baik ($\text{Mean} \pm 1.5 \text{ SD}$), Cukup Baik ($\text{Mean} \pm 2.5 \text{ SD}$), dan Kurang Baik, yang mencakup nilai ekstrem di luar batas kategori lainnya. Rentang kategori disesuaikan dengan data ECDF untuk memastikan representasi habitat yang realistis.

Dalam penerapannya, penelitian ini menggunakan MFC, khususnya DFC, yang mengintegrasikan faktor Chlo-a dan SST untuk klasifikasi habitat yang lebih akurat. Berdasarkan klasifikasi ini, dihasilkan peta distribusi habitat untuk masing-masing spesies ikan serta peta overlay yang menunjukkan area dengan kondisi habitat optimal secara keseluruhan. Metode ini memungkinkan pemahaman lebih mendalam tentang distribusi ikan dan mendukung pengelolaan perikanan yang



5.3 Hasil Penelitian

5.3.1 Perbandingan metrik keseluruhan model

Metode ECDF, elbow method, k-means, dan MaxEnt menunjukkan perbedaan serta kesamaan dalam memahami hubungan antara variabel lingkungan (Chlo-a dan SST) dengan potensi distribusi ikan cakalang, madidihiang, dan tuna mata besar. Semua metode mengidentifikasi bahwa Chlo-a dan SST berada dalam rentang tertentu yang mendukung habitat optimal ketiga spesies ikan, seperti rentang Chlo-a 0.075–0.33 mg/m³ untuk cakalang, 0.0748–0.334 mg/m³ untuk madidihiang, dan 0.087–0.30 mg/m³ untuk tuna mata besar. SST optimal juga serupa, yaitu sekitar 29.47–30.47°C untuk cakalang, 28.68–30.30°C untuk madidihiang, dan 29.35–30.45°C untuk tuna mata besar. Ketiga spesies ikan menunjukkan preferensi terhadap suhu yang lebih rendah (SST) dan konsentrasi Chlo-a sedang hingga tinggi, dengan bulan Juli dan Agustus menjadi periode penting karena menciptakan kondisi lingkungan yang ideal. Semua metode juga mengonfirmasi relevansi Chlo-a dan SST dalam memprediksi distribusi ikan, di mana Chlo-a merepresentasikan kelimpahan fitoplankton dan SST mencerminkan kondisi termal yang mendukung metabolisme ikan. Berikut ini adalah ringkasan kondisi variabel oseanografi berdasarkan nilai signifikansi dan optimum dari ECDF, k-means dan elbow method, sebagaimana ditunjukkan pada Tabel 5.1 berikut.

Tabel 5.1 Nilai signifikansi dan optimum ECDF, k-means dan elbow method

Jenis Ikan	Model Analisis	Chlo-a (mg/m ³)	SST (°C)	Keterangan
Cakalang	ECDF, Elbow Method, K-Means	Signifikan: 0.280 Optimal: 0.075-0.33	Signifikan: 30.57 Optimal: 29.47-30.47	Chlo-a dan SST memiliki relevansi tinggi dalam memprediksi penangkapan.
Madidihiang	ECDF, Elbow Method, K-Means	Signifikan: 0.196 Optimal: 0.0748-0.334	Signifikan: 28.84 Optimal: 28.68-30.30	SST lebih relevan dalam memprediksi CPUE dibandingkan Chlo-a.
Tuna Mata Besar	ECDF, Elbow Method, K-Means	Signifikan: 0.201 Optimal: 0.087-0.30	Signifikan: 29.64 Optimal: 29.35-30.45	Pengaruh Chlo-a dan SST seimbang dalam memprediksi CPUE.

Metode-metode ini juga memiliki perbedaan yang signifikan. ECDF adalah metode yang paling banyak digunakan dalam penelitian ini untuk mengklasifikasi habitat ke dalam kategori kualitas (Sangat Baik, Baik, Cukup Baik, Kurang Baik, dan Sangat Kurang Baik). Misalnya, cakalang dalam kategori Sangat Baik berada pada 0.178–0.280 mg/m³ dengan SST 30.57–30.997°C, dan tuna mata besar dalam kategori Kurang Baik menunjukkan nilai ekstrem hingga 16.708 mg/m³.



dan SST 32.00°C yang kurang mendukung habitat. Elbow method dan k-means lebih efektif dalam segmentasi data untuk memahami variasi spasial, tetapi kurang memperhatikan dinamika temporal secara mendalam. Tabel kategori nilai Chlo-a dan SST berdasarkan metode nilai D ECDF, ditunjukkan pada Tabel 5.2 berikut.

Tabel 5.2 Kategori nilai Chlo-a dan SST berdasarkan D ECDF

Ikan	Kategori Habitat	Metode Analisis	Chlo-a (mg/m ³)	SST (°C)	Keterangan
Cakalang	Sangat Baik	ECDF	0.178–0.280	30.570–30.997	Lingkungan ideal dengan makanan yang cukup dan suhu optimal.
Cakalang	Baik	ECDF	0.171–0.269	28.276–30.998	Masih mendukung tetapi kurang optimal.
Cakalang	Cukup Baik	ECDF	0.163–0.639	28.488–31.051	Habitat kurang konsisten tetapi memungkinkan aktivitas perikanan.
Cakalang	Kurang Baik	ECDF	0.159–16.708	31.073–32.000	Kondisi ekstrem sering kali tidak mendukung habitat.
Madidihang	Sangat Baik	ECDF	0.195–0.242	28.527–28.841	Ideal untuk habitat ikan.
Madidihang	Baik	ECDF	0.156–0.176	28.528–29.079	Masih mendukung tetapi kurang optimal.
Madidihang	Cukup Baik	ECDF	0.145–0.332	26.927–29.289	Habitat menunjukkan variasi besar.
Madidihang	Kurang Baik	ECDF	0.323–16.708	29.386–32.654	Kondisi ekstrem yang kurang mendukung habitat ideal.
Tuna Mata Besar	Sangat Baik	ECDF	0.130–0.144	29.372–29.639	Habitat ideal dengan kondisi optimal.
		ECDF	0.125–0.202	28.589–29.915	Masih mendukung tetapi kurang optimal.



Tuna Mata Besar	Cukup Baik	ECDF	0.142–0.321	27.000–30.660	Habitat menunjukkan fluktuasi besar.
Tuna Mata Besar	Kurang Baik	ECDF	0.151–3.091	30.630–32.654	Kondisi ekstrem yang tidak ideal untuk habitat.

Adapun nilai MaxEnt memberikan gambaran distribusi spasial yang lebih kompleks dengan mempertimbangkan dinamika temporal sepanjang tahun. MaxEnt menyoroti puncak konsentrasi Chlo-a untuk cakalang pada bulan September (6.93 mg/m^3), sementara untuk madidiang dan tuna mata besar, puncaknya terjadi pada bulan Januari dan September, masing-masing mencapai 8.29 mg/m^3 dan 8.39 mg/m^3 . Selain itu, MaxEnt juga menunjukkan dominasi pengaruh variabel yang berbeda, SST lebih signifikan untuk cakalang dan madidiang, sedangkan Chlo-a lebih berpengaruh pada tuna mata besar (rata-rata kontribusi 67.91%). Berikut adalah tabel nilai Chlo-a dan SST berdasarkan metode MaxEnt, sebagaimana ditunjukkan pada Tabel 5.3 berikut.

Tabel 5.3 Nilai Chlo-a dan SST metode MaxEnt

Ikan	Bulan Puncak	Metode Analisis	Chlo-a (mg/m^3)	SST ($^{\circ}\text{C}$)	Keterangan
Cakalang	September	MaxEnt	Puncak: 6.93	26.19–32.54	Preferensi pada Juli–Agustus dengan Chlo-a $0.15\text{--}0.39 \text{ mg/m}^3$ dan SST $27.19\text{--}28.68 \text{ }^{\circ}\text{C}$.
Madidiang	Januari, September	MaxEnt	Puncak: 8.29 (Jan), 6.93 (Sep)	26.03–32.95	Preferensi pada Juli–Agustus dengan Chlo-a $0.18\text{--}0.34 \text{ mg/m}^3$ dan SST $27.25\text{--}28.22 \text{ }^{\circ}\text{C}$.
Tuna Mata Besar	April, September	MaxEnt	Puncak: 8.39 (Apr), 7.81 (Sep)	26.20–33.67	Preferensi pada Juli–Agustus dengan Chlo-a $0.19\text{--}0.23 \text{ mg/m}^3$ dan SST $27.24\text{--}27.60 \text{ }^{\circ}\text{C}$.



Pada tabel di atas, cakalang menunjukkan rentang Chlo-a optimal 0.15–0.28 mg/m³ dan SST 29.5–31°C yang serupa pada semua metode, tetapi MaxEnt mengidentifikasi bulan September sebagai puncak habitat optimal, sedangkan ECDF dan k-means mengindikasikan distribusi optimal yang lebih merata pada Juli–Agustus. Madidiang memiliki rentang SST optimal 28.3–30.4°C dengan Chlo-a sedang (0.18–0.28 mg/m³), dan MaxEnt menunjukkan bulan Januari dan Juli sebagai periode penting, sementara elbow method lebih menyoroti segmentasi spasial. Tuna mata besar menunjukkan preferensi pada Chlo-a 0.19–0.23 mg/m³ dan SST 29–30°C dengan dinamika temporal yang lebih menonjol menurut MaxEnt, sedangkan ECDF menunjukkan habitat kategori Kurang Baik dengan Chlo-a ekstrem. Untuk mengetahui kecenderungan masing-masing model, maka dilakukan penggabungan semua nilai model, dengan membuat 4 kategori kondisi perairan laut berdasarkan Chlo-a dan SST: Sangat Baik, Baik, Cukup Baik, dan Kurang Baik.

Penentuan nilai baru untuk setiap kategori (Sangat Baik, Baik, Cukup Baik, dan Kurang Baik) dilakukan dengan pendekatan yang menggabungkan hasil statistik dan distribusi kategori ECDF. Proses ini dimulai dengan penghitungan nilai statistik berupa Mean dan Standar Deviasi (SD) berdasarkan rentang optimal yang diperoleh dari analisis K-Means dan Elbow Method. Rentang kategori dihitung secara bertahap, di mana kategori Sangat Baik ditentukan sebagai Mean $\pm$ 0.5 * SD, mencerminkan habitat optimal dengan rentang yang sempit. Selanjutnya, kategori Baik dihitung sebagai Mean $\pm$ 1.5 * SD, yang memiliki rentang lebih lebar dibandingkan Sangat Baik. Kategori Cukup Baik dihitung dengan Mean $\pm$ 2.5 * SD, mencerminkan habitat yang toleran, namun tidak optimal, dengan rentang lebih besar dari Baik. Sementara itu, kategori Kurang Baik mencakup nilai-nilai ekstrem yang berada di luar batas kategori lainnya.

Hasil rentang statistik kemudian dibandingkan dengan rentang kategori ECDF untuk setiap kategori. Proses ini memastikan bahwa nilai-nilai statistik selaras dengan data lapangan yang nyata. Rentang baru untuk setiap kategori ditentukan berdasarkan irisan (overlap) antara hasil statistik dan rentang kategori ECDF. Rentang overlap ini membantu memilih batas minimum dan maksimum yang sesuai, sehingga kategori tetap akurat dan tidak menyimpang dari distribusi data lapangan. Penyesuaian ini sangat penting untuk memastikan bahwa setiap kategori menggambarkan kondisi ekologis yang realistis.

Langkah terakhir adalah menata ulang rentang nilai agar semakin melebar dari kategori Sangat Baik hingga Kurang Baik, tanpa terjadi tumpang tindih atau ketidakkonsistenan, seperti batas atas kategori Cukup Baik lebih rendah daripada Baik. Dengan pendekatan ini, kategori Sangat Baik mempertahankan rentang sempit untuk habitat optimal, sementara kategori Kurang Baik mencakup habitat ekstrem dengan rentang yang lebih luas. Proses ini menghasilkan rentang kategori yang logis, konsisten, dan mampu merepresentasikan kondisi habitat dengan lebih baik, baik dari segi statistik maupun ekologis, sebagaimana ditunjukkan pada ahapan sintesis nilai baru Chlo-a dan SST Terlampir IV).



Tabel 5.4 Kombinasi nilai model ECDF, k-means, elbow method dan pendekatan statistik

Ikan	Kriteria	Chlo-a (mg/m ³)	SST (°C)	Pertimbangan Ekologis
Cakalang	Sangat Baik	0.17–0.28	29.85–30.99	Kadar Chlo-a pada kisaran ini mendukung tingkat produktivitas primer tinggi tanpa risiko bloom alga, dan SST optimal untuk habitat pelagis (Waite & Mueter, 2013).
	Baik	0.11–0.30	29.60–30.99	Kondisi ini ideal untuk distribusi ikan seperti tuna dan cakalang karena ketersediaan plankton yang memadai (Zainuddin et al., 2017).
	Cukup Baik	0.04–0.64	28.48–31.05	Rentang Chlo-a ini menunjukkan penurunan ketersediaan makanan atau habitat marginal, memengaruhi biomassa ikan pelagis (Safruddin et al., 2014).
	Kurang Baik	< 0.04–>0.64	<28.48–>32.00	Tingkat Chlo-a yang sangat rendah atau fluktuasi ekstrem menunjukkan kondisi perairan kurang produktif atau terkena tekanan lingkungan (Muskananfolo et al., 2021).
Madidihang	Sangat Baik	0.17–0.24	28.52–29.69	Chlo-a optimal mendukung produktivitas tinggi yang ideal untuk ikan pelagis besar, dengan SST yang stabil (Handika et al., 2024).
	Baik	0.11–0.30	28.52–30.10	Suhu dan Chlo-a mendukung zona pemijahan dan pertumbuhan ikan tuna, sesuai dengan habitat tropis (Druon et al., 2016).
	Cukup Baik	0.04–0.33	26.92–30.50	Habitat marginal dengan ketersediaan makanan yang lebih rendah dibandingkan kriteria "Baik" (Zainuddin et al., 2017).
	Kurang Baik	<0.04–>0.33	<26.92–>32.65	Kondisi ekstrim seperti suhu tinggi atau klorofil rendah menunjukkan tekanan



Tuna Mata Besar				lingkungan yang signifikan (Muskananfola et al., 2021).
	Sangat Baik	0.14–0.22	29.37–30.04	Kondisi optimal untuk kelangsungan hidup dan reproduksi tuna mata besar (Handika et al., 2024).
	Baik	0.11–0.27	28.58–30.31	Habitat mendukung pertumbuhan dan ketersediaan mangsa yang melimpah (Zainuddin et al., 2017).
	Cukup Baik	0.06–0.33	27.00–30.66	Rentang marginal yang mungkin tidak mencukupi untuk kebutuhan energi tuna mata besar (Fadhilah et al., 2022).
	Kurang Baik	<0.06–>0.33	<27.00–>32.65	Suhu ekstrem dan klorofil yang rendah menciptakan tekanan lingkungan tinggi (Muskananfola et al., 2021).

Kriteria di atas diformulasikan sebagaimana ditunjukkan pada Tabel 5.5 berikut.

Tabel 5.5 Formula kriteria rentang nilai Chlo-a dan SST

Ikan	Chlo-a (mg/m ³)	Formula	SST (°C)	Formula
Cakalang	0.17–0.28	$0.17 \leq x \leq 0.28$	29.85–30.99	$29.85 \leq x \leq 30.99$
	0.11–0.30	$0.11 \leq x < 0.17 \vee 0.28 < x \leq 0.30$	29.60–30.99	$29.60 \leq x \leq 30.99$
	0.04–0.64	$0.04 \leq x \leq 0.11 \vee 0.30 < x \leq 0.64$	28.48–31.05	$28.48 \leq x \leq 31.05 \vee 31.05 < x \leq 32.00$
	< 0.04–> 0.64	$x < 0.04 \vee x > 0.64$	<28.48–>32.00	$x < 28.48 \vee x > 32.00$
Madidihang	0.17–0.24	$0.17 \leq x \leq 0.24$	28.52–29.69	$28.52 \leq x \leq 29.69$
	0.11–0.30	$0.11 \leq x < 0.17 \vee 0.24 < x \leq 0.30$	28.52–30.10	$29.69 < x \leq 30.10$
	0.04–0.33	$0.04 \leq x < 0.11 \vee 0.30 < x \leq 0.33$	26.92–30.50	$26.92 \leq x \leq 28.52 \vee 30.50 \leq x < 32.65$
	<0.04–>0.33	$x < 0.04 \vee x > 0.33$	<26.92–>32.65	$x < 26.92 \vee x \geq 32.65$
Tuna Mata Besar	0.14–0.22	$0.14 \leq x \leq 0.22$	29.37–30.04	$29.37 \leq x \leq 30.04$
	0.11–0.27	$0.11 \leq x < 0.14 \vee 0.22 < x \leq 0.27$	28.58–30.31	$28.58 \leq x < 29.37 \vee 30.04 < x \leq 30.31$
	0.06–0.33	$0.06 \leq x \leq 0.11 \vee 0.27 < x \leq 0.33$	27.00–30.66	$27.00 \leq x \leq 28.58 \vee 30.31 \leq x < 30.66$
	<0.06–>0.33	$x < 0.06 \vee x > 0.33$	<27.00–>32.65	$x < 27.00 \vee x \geq 32.65$



gaplikasikan kriteria ekologis dalam pemetaan, digunakan Classification, yakni Dual-Factor Classification (DFC), sebuah mengintegrasikan dua faktor utama—yaitu Chlo-a dan SST—

untuk menentukan kategori secara terintegrasi. DFC bertujuan menciptakan klasifikasi yang lebih holistik dengan mempertimbangkan interaksi antarvariabel yang saling memengaruhi. Pendekatan ini memetakan setiap kombinasi nilai dari kedua faktor ke dalam kategori tertentu: Kurang Baik, Cukup Baik, Baik, dan Sangat Baik. Metode ini menekankan dampak relatif setiap faktor, di mana faktor dominan lebih menentukan kategori, sehingga memungkinkan analisis yang fleksibel dan interpretasi yang lebih akurat untuk pengambilan keputusan berbasis data. Dalam penelitian ini, penerapan DFC menggunakan teknik feature engineering untuk mengolah data Chlo-a dan SST menjadi fitur baru yang lebih informatif. Nilai kontinu Chlo-a dan SST dikonversi menjadi kategori diskrit menggunakan fungsi `klorofil_to_kategori` dan `SST_to_kategori`, berdasarkan rentang nilai tertentu. Data dari kedua faktor ini digabungkan dengan ID unik melalui fungsi `merge`, dan variabel baru `Kategori_Baru` dibuat menggunakan fungsi `mapply`. Fungsi ini menggabungkan kategori Chlo-a dan SST berdasarkan logika rule-based classification untuk menentukan status ekologis gabungan. Model klasifikasi berbasis rule-based classification memanfaatkan hubungan antar kategori dari kedua variabel untuk menghasilkan kategori akhir (Sangat Baik, Baik, Cukup Baik, Kurang Baik). Hasil klasifikasi divisualisasikan secara spasial menggunakan paket `ggplot2`, yang memetakan distribusi geografis `Kategori_Baru`. Metode ini tidak hanya meningkatkan kualitas data input melalui fungsi feature engineering, seperti `klorofil_to_kategori`, `SST_to_kategori`, dan `mapply`, tetapi juga memberikan wawasan yang lebih sistematis dalam memahami interaksi multifaktor ekologis secara menyeluruh. Keunggulan metode ini terletak pada fleksibilitasnya dalam menganalisis data kompleks dengan variabel yang saling berhubungan, menjadikannya sangat berguna dalam berbagai bidang seperti ekologi, lingkungan, dan manajemen sumber daya. Dengan pendekatan ini, DFC mampu menggambarkan hubungan multifaktorial secara konsisten, memungkinkan analisis yang lebih sistematis dan pengambilan keputusan yang didasarkan pada pemahaman mendalam terhadap interaksi antar faktor. Output dari metode DFC di atas ditunjukkan pada Tabel 5.6 berikut.

Tabel 5.6 Kriteria kombinasi metode DFC

Chlo-a	SST	Kategori Baru	Keterangan
	Sangat Baik	Sangat Baik	Kombinasi tingkat Chlo-a yang tinggi dan suhu optimal mendukung produktivitas maksimum dan kondisi ekosistem yang ideal untuk perikanan (Doydee et

			al., 2010; Sartimbul et al., 2010).
Sangat Baik	Baik	Baik	Tingkat Chlo-a yang tinggi tetapi suhu sedikit kurang optimal masih mendukung produktivitas yang cukup baik (Adnan et al., 2022; Ningsih et al., 2021).
Sangat Baik	Cukup Baik	Cukup Baik	Suhu tidak sepenuhnya mendukung meskipun tingkat Chlo-a tinggi, sehingga kondisi perikanan menjadi kurang optimal (Sartimbul et al., 2010; Suchy et al., 2019).
Sangat Baik	Kurang Baik	Kurang Baik	Suhu terlalu rendah atau terlalu tinggi, menyebabkan ekosistem tidak mendukung meskipun tingkat Chlo-a tinggi (Doydee et al., 2010; Suchy et al., 2019).
Baik	Sangat Baik	Baik	Tingkat Chlo-a sedang, tetapi suhu optimal memungkinkan produktivitas tetap cukup tinggi untuk mendukung perikanan (Adnan et al., 2022; Sartimbul et al., 2010).
Baik	Baik	Baik	Kombinasi tingkat Chlo-a dan suhu yang moderat masih menciptakan kondisi yang stabil untuk aktivitas perikanan (Ningsih et al., 2021; Suchy et al., 2019).
	Cukup Baik	Cukup Baik	Suhu mulai kurang mendukung,



			sehingga meskipun tingkat Chlo-a moderat, ekosistem menjadi kurang ideal untuk aktivitas perikanan (Adnan et al., 2022; Doydee et al., 2010).
Baik	Kurang Baik	Kurang Baik	Suhu yang tidak mendukung (terlalu rendah atau terlalu tinggi) membatasi potensi Chlo-a moderat untuk mendukung ekosistem produktif (Sartimbul et al., 2010; Suchy et al., 2019).
Cukup Baik	Sangat Baik	Cukup Baik	Tingkat Chlo-a yang rendah membatasi produktivitas meskipun suhu mendukung, sehingga tetap berada di kategori 'Cukup Baik' (Doydee et al., 2010; Ningsih et al., 2021).
Cukup Baik	Baik	Cukup Baik	Kombinasi tingkat Chlo-a rendah dan suhu moderat hanya mendukung ekosistem pada level sedang (Cukup Baik) (Adnan et al., 2022; Sartimbul et al., 2010).
Cukup Baik	Cukup Baik	Cukup Baik	Kedua faktor berada di level moderat sehingga menghasilkan kondisi yang biasa saja dan tidak luar biasa (Ningsih et al., 2021; Doydee et al., 2010).
	Kurang Baik	Kurang Baik	Suhu yang tidak mendukung semakin membatasi tingkat Chlo-a yang sudah rendah,


			menghasilkan kondisi yang tidak cocok untuk aktivitas perikanan (Suchy et al., 2019; Sartimbul et al., 2010).
Kurang Baik	Sangat Baik	Kurang Baik	Tingkat Chlo-a yang terlalu rendah tidak dapat dimanfaatkan meskipun suhu berada di level optimal (Adnan et al., 2022; Suchy et al., 2019).
Kurang Baik	Baik	Kurang Baik	Kombinasi Chlo-a rendah dan suhu moderat tidak cukup mendukung produktivitas ekosistem yang baik untuk perikanan (Doydee et al., 2010; Ningsih et al., 2021).
Kurang Baik	Cukup Baik	Kurang Baik	Kedua faktor, Chlo-a dan suhu, berada di level yang tidak mendukung, sehingga menghasilkan kondisi yang tidak produktif (Sartimbul et al., 2010; Adnan et al., 2022).
Kurang Baik	Kurang Baik	Kurang Baik	Kedua faktor berada di level terendah (suhu dan Chlo-a), menyebabkan ekosistem sangat buruk dan tidak mendukung aktivitas perikanan sama sekali (Suchy et al., 2019; Sartimbul et al., 2010).

5.3.2 Final Map (MFC) potensi penangkapan cakalang




n kriteria Multifactor Classification di atas, dihasilkan peta Gambar 5.1 berikut (Gambar peta selengkapnya Terlampir 5.1, se Terlampir 6.1).

Final Map - Cakalang Januari




(a)

Final Map - Cakalang Maret



(b)





(c)

Gambar 5.1 Peta potensi penangkapan cakalang berdasarkan Kriteria MFC: (a) Mei, (b) Januari, dan (c) Februari

Berdasarkan data peta dan persentase area penangkapan ikan cakalang dari bulan Januari hingga Desember, analisis menunjukkan bahwa waktu dan lokasi penangkapan ikan mengalami fluktuasi yang signifikan, dipengaruhi oleh distribusi Chlo-a dan SST. Beberapa bulan terbaik untuk kegiatan penangkapan berdasarkan pemetaan area potensi penangkapan adalah Januari s.d. Juni dan Oktober s.d. Desember. Pada bulan Januari, area “Baik” mendominasi hingga 50.19% (bagian Utara, Timur s.d. Barat), “Cukup Baik” sebesar 37.00% (hampir merata di sebagian besar WPP 714), dan “Sangat Baik” sebesar 10,64%. Hal ini menunjukkan produktivitas primer yang tinggi dan SST yang sesuai untuk habitat ikan cakalang. Selanjutnya, pada bulan Maret, distribusi kategori “Baik” mencapai 64.30%, “Cukup Baik” sebesar 27.03%, dan “Sangat Baik” mencapai 7.65% mencerminkan kondisi perairan yang produktif.

Bulan Mei juga menjadi salah satu bulan terbaik dengan dominasi kategori “Cukup Baik” sebesar 56.84% dan “Baik” sebesar 33.07%. Wilayah optimal tersebar secara merata, dengan SST yang sesuai dan konsentrasi Chlo-a yang mendukung kelimpahan ikan. Sebaran lokasi kondisi perairan laut dengan kategori “Sangat Baik” pada bulan Januari (salah satu bulan dengan kondisi terbaik sepanjang tahun) ditunjukkan pada Gambar 5.2 berikut (Selengkapnya




JanuariCK - Sangat Baik



Gambar 5.2 Sebaran lokasi "Sangat Baik" tangkapan cakalang (Januari)

Namun demikian, rata-rata tangkapan bulanan ikan cakalang di WPP 714 sejak tahun 2014 s.d. 2022 secara umum cenderung stabil sepanjang tahun. Walaupun demikian jumlah tangkapan tertinggi selain terjadi pada bulan Mei, dan Januari, justru tinggi pada bulan Juli sebagaimana ditunjukkan pada Gambar 5.3 berikut.







Gambar 5.3 Rata-rata berat tangkapan cakalang per bulan.

5.3.3 Final Map (MFC) Potensi Penangkapan Madidihang


Gambar 5.4 berikut adalah pemetaan potensi perikanan madidihang di WPP 714 berdasarkan kriteria Multi-Factor Classification (Gambar peta selengkapnya Terlampir 5.2, dan grafik persentase Terlampir 6.2).



(a)



(b)



(c)



Intensi penangkapan madidihang berdasarkan Kriteria MFC: (a) Januari, (b) April, dan (c) Mei

Berdasarkan analisis data lokasi penangkapan ikan madidihiang, kondisi area tangkapan dari Januari hingga Desember bervariasi secara signifikan. Secara umum, area dengan kategori "Cukup Baik", "Baik", dan "Sangat Baik" lebih dominan pada bulan Januari s.d. Mei dan Oktober s.d. Desember. Pada Januari, kondisi "Baik" (47.82%), "Cukup Baik" (40.26%), dan "Sangat Baik" (7.18%). Pada bulan Februari, kondisi "Baik" (45.64%), "Cukup Baik" (39.37%), dan "Sangat Baik" (10.34%). Adapun pada Mei, kondisi "Baik" (57.48%), "Cukup Baik" (27.51%), dan "Sangat Baik" (9.23%). Bulan-bulan tersebut menunjukkan kombinasi kondisi lingkungan yang lebih mendukung, seperti tingkat Chlo-a dan SST yang optimal untuk tangkapan ikan madidihiang. Sebaran lokasi tangkapan ikan madidihiang dengan kategori "Sangat Baik" pada bulan Mei (salah satu kondisi terbaik berdasarkan hasil pemodelan) ditunjukkan pada Gambar 5.5 berikut (Gambar peta selengkapnya Terlampir 9.2).

MeiMD - Sangat Baik




Gambar 5.5 Sebaran lokasi "Sangat Baik" tangkapan madidihiang (Mei)

Sebaliknya, pada Juli s.d. September didominasi area kategori "Kurang Baik", berkisar 47-51%. Dominasi ini mengindikasikan kondisi lingkungan yang kurang mendukung, sehingga hasil tangkapan cenderung menurun.

Adapun rata-rata tangkapan bulanan ikan madidihiang di WPP 714 sejak tahun 2014 s.d. 2022 secara umum cenderung stabil sepanjang tahun. Walaupun tangkapan tertinggi selain terjadi pada bulan Mei, justru tinggi Agustus sebagaimana ditunjukkan pada Gambar 5.6 berikut.






Gambar 5.6 Rata-rata berat tangkapan madidihiang per bulan

5.3.4 Final Map (MFC) Potensi Penangkapan Tuna Mata Besar

Potensi perikanan tuna mata besar di WPP 714 secara umum menunjukkan bahwa bulan terbaik untuk penangkapan adalah Januari s.d. Juni dan Oktober s.d. Desember. Adapun pemetaan tuna mata besar berdasarkan kriteria Multifactor Classification ditunjukkan pada Gambar 5.7 berikut (Gambar peta selengkapnya Terlampir 5.3, dan grafik persentase Terlampir 6.3).




Final Map - Tuna Mata Besar Februari




(a)

Final Map - Tuna Mata Besar Mei



(b)





(c)

Gambar 5.7 Peta potensi penangkapan tuna mata besar berdasarkan Kriteria MFC: (a) Januari, (b) Februari, dan (c) Mei

Berdasarkan data lokasi dan persentase area penangkapan tuna mata besar dari Januari hingga Desember, analisis menunjukkan variasi kualitas lokasi penangkapan sepanjang tahun. Bulan Januari hingga Juni memiliki peluang penangkapan yang relatif baik, terutama pada Januari, Februari, dan Mei, dengan kategori "Baik" (34.48% - 49.50%), "Cukup Baik" (30.92% - 46.38%), dan "Sangat Baik" (13.92% - 19.09%). Sebaran lokasi tangkapan tuna mata besar dengan kategori "Sangat Baik" pada bulan Mei ditunjukkan pada Gambar 5.8 berikut (Gambar peta selengkapnya Terlampir 9.3).




MeiTMB - Sangat Baik



Gambar 5.8 Sebaran lokasi "Sangat Baik" tangkapan tuna mata besar (Mei)

Sebaliknya, Juli s.d. September mencerminkan potensi perairan yang "Kurang Baik", yakni berkisar 44.99% - 63.04%. Namun demikian, berdasarkan rata-rata bulanan tangkapan ikan madidihang di WPP 714 sejak tahun 2014 s.d. 2022, secara umum justru tinggi pada bulan Agustus, sebagaimana ditunjukkan pada Gambar 5.9 berikut.







Gambar 5.9 Rata-rata berat tangkapan tuna mata besar per bulan

5.3.4 Overlay Final Map Potensi Penangkapan Cakalang, Madidihang, dan Tuna Mata Besar di WPP 714


Pada Gambar 5.10 berikut adalah peta overlay area potensi penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714 (Gambar selengkapnya Terlampir VII, dan grafik persentase Terlampir VIII).



(a)




(b)




(c)



Optimized using
trial version
www.balesio.com




(d)



(e)





(f)

Gambar 5.10 Peta overlay area potensi penangkapan ikan cakalang, madidihang, dan tuna mata besar di WPP 714: (a) Januari, (b) Presentase Januari, (c) Februari, (d) Presentase Februari, (e) Mei, dan (f) Presentase Mei

Pada penelitian ini akronim CMT adalah Cakalang (C), Madidihang (M), dan Tuna Mata Besar (T). Adapun kategori-kategori didefinisikan sebagai berikut: S adalah “Sangat Baik”, B adalah “Baik”, C mewakili “Cukup Baik”, dan K artinya “Kurang Baik”. Jadi CMT-SBC artinya Cakalang dalam perairan terkategori “Sangat Baik” untuk penangkapan, Madidihang dalam kondisi perairan “Baik”, dan Tuna Mata Besar adalah “Cukup Baik” untuk penangkapan.

Potensi area penangkapan ikan gabungan (Cakalang, Madidihang, dan Tuna Mata Besar) memperlihatkan perubahan yang menarik sepanjang tahun, dengan pola spasio-temporal yang mencerminkan variasi kondisi lingkungan. Dari bulan Januari s.d. Mei, status 10 peringkat kategori tertinggi untuk CMT-BBB muncul sekitar 1.3% - 8.5% dari luas wilayah WPP 714. Ini menunjukkan bahwa semua spesies memiliki potensi perairan yang Baik. Meski bukan kategori dominan, area dengan potensi ini cukup signifikan, terutama tersebar di bagian tengah dan utara wilayah, yang menandakan adanya kondisi lingkungan yang cukup mendukung pada bulan-bulan ini.

Kategori CMT-CBB pada bulan Juni mencakup sekitar 2.8%, kategori CMT-CCC pada Juli s.d. September mencakup 1.8% - 4.1%. Adapun kategori terbaik pada Oktober adalah CMT-CBB (4.5%), November adalah CMT-BBC ber adalah CMT-BCB (3.2%).

airan di Wilayah Pengelolaan Perikanan (WPP) 714 untuk pelagis seperti Cakalang, Madidihang, dan Tuna Mata Besar si signifikan sepanjang tahun 2023. Pada Januari hingga



Februari, kondisi perairan relatif baik dengan dominasi kategori CMT-BBB (Baik untuk ketiga spesies) dan CMT-BBC (Baik untuk Cakalang dan Madidihiang, Cukup Baik untuk Tuna Mata Besar). Persentase kategori dominan pada Januari menunjukkan CMT-BCC sebesar 11,1%, diikuti CMT-BBC (10,5%) dan CMT-BBB (7,9%). Pada Februari, kondisi membaik dengan CMT-BBB mencapai 8,5%, CMT-CBB 8,4%, dan CMT-CBC 7,6%. Wilayah barat dan tengah menunjukkan kondisi perairan yang lebih baik dibanding wilayah timur.


Memasuki Maret hingga Mei, terjadi penurunan kualitas perairan yang signifikan. Pada Maret, CMT-BCC meningkat drastis menjadi 19,8%, diikuti CMT-BBC (12,1%) dan CMT-CCC (8,0%). April menunjukkan kondisi terburuk dengan dominasi CMT-CCC sebesar 35,1%, menandakan kondisi Kurang Baik secara menyeluruh, sementara CMT-BCC mencapai 23,9%. Namun, Mei memperlihatkan sedikit pemulihan dengan CMT-CBB sebagai kategori dominan sebesar 18%, diikuti CMT-CBC (10,5%) dan CMT-BBB (7,8%). Wilayah barat dan selatan menunjukkan pemulihan lebih cepat dibanding wilayah tengah dan timur yang masih mengalami penurunan kualitas.

Periode Juni hingga Agustus menandai penurunan kualitas perairan yang paling drastis, terutama selama musim kemarau. Pada Juni, CMT-KCC mendominasi dengan 16,9%, diikuti CMT-KCK (9,7%) dan CMT-CCC (7,2%). Juli menjadi salah satu bulan terburuk dengan CMT-KKK (Kurang Baik untuk ketiga spesies) mencapai 29,3%, disusul CMT-KCK (21,7%) dan CMT-KCC (17,5%). Kondisi semakin memburuk pada Agustus, dengan CMT-KKK melonjak ke 47,5%, hampir setengah dari wilayah perairan dalam kondisi buruk. Dominasi kategori Kurang Baik terlihat merata di seluruh WPP 714.

Pada September hingga Oktober, kondisi perairan mulai menunjukkan tanda-tanda pemulihan parsial. CMT-KKK menurun menjadi 23% pada September, sementara CMT-KCK dan CMT-KCC masing-masing mencapai 17% dan 15,1%. Oktober memperlihatkan peningkatan kategori CMT-CCC sebesar 10,1%, menunjukkan pemulihan di beberapa wilayah barat dan selatan, meskipun kategori Kurang Baik seperti CMT-KCC (8,5%) dan CMT-BCC (6,5%) masih signifikan.

Namun, November hingga Desember kembali menunjukkan penurunan kualitas perairan. Pada November, CMT-CCC mendominasi dengan 31,8%, diikuti CMT-BCC sebesar 28%, sedangkan CMT-SCC hanya 8,5%. Desember menjadi bulan dengan dominasi kondisi Kurang Baik yang signifikan, dengan CMT-CCC mencapai 43,4% dan CMT-BCC 15,2%. Meskipun ada sedikit peningkatan kategori Cukup Baik seperti CMT-CCB (9,4%), secara umum, kondisi perairan pada akhir tahun tetap buruk. Wilayah tengah dan timur tetap menjadi area dengan kualitas perairan terburuk, sementara wilayah barat menunjukkan beberapa tanda pemulihan kecil. Sebaran lokasi tangkapan ikan pelagis variatif terbaik (cakalang, madidihiang, dan tuna mata besar) dengan kategori "BBB" pada bulan Februari (salah satu terbaik berdasarkan pemodelan) ditunjukkan pada Gambar 5.11 (a selengkapnya Terlampir 9.4).





Gambar 5.11 Sebaran lokasi "Sangat Baik" tangkapan variatif (Mei)

5.4 Pembahasan

5.4.1 Metode Multifactor Classification

Metode Multifactor Classification pertama kali diperkenalkan oleh Fisher (1936) dalam konteks analisis statistik, terutama untuk mengkategorikan data berdasarkan kombinasi berbagai variabel. Metode ini kemudian berkembang dan diterapkan di berbagai bidang, termasuk ekologi, perikanan, pertanian, pengelolaan sumber daya alam, dan bahkan ekonomi. Dalam konteks ekologi dan perikanan, metode ini bisa digunakan untuk mengklasifikasikan kondisi suatu ekosistem berdasarkan parameter-parameter utama seperti Chlo-a (indikator produktivitas fitoplankton) dan SST. Multifactor Classification memungkinkan pemahaman mendalam mengenai bagaimana kombinasi berbagai faktor lingkungan memengaruhi hasil akhir, seperti produktivitas perikanan atau kesehatan ekosistem laut. Prinsip dasarnya adalah bahwa kelemahan pada salah satu faktor dapat memengaruhi keseluruhan sistem, bahkan ketika faktor lainnya berada dalam kondisi optimal (Fisher, 1936).

Prinsip dasar dalam penilaian multifaktor meliputi tiga elemen penting. Pertama, hubungan sinergis. Kedua faktor (Chlo-a dan SST) harus berada dalam kondisi yang mendukung untuk menghasilkan kategori Sangat Baik. Ketika salah satu faktor mendukung sementara yang lain tidak, hasil akhirnya akan turun, mencerminkan penurunan kualitas ekosistem. Kedua, hubungan pembatasan, yaitu jika salah satu faktor berada dalam kategori Kurang Baik, maka kondisi cenderung menurun ke kategori Kurang Baik, karena ekosistem pada sinergi antar faktor. Ketiga, interaksi kompleks, di mana lainnya, seperti salinitas, arus laut, dan nutrisi, juga dapat akhir. Namun, Chlo-a dan SST biasanya digunakan sebagai



indikator utama karena relevansi biologisnya yang tinggi (Adnan et al., 2022; Doydee et al., 2010; dan Sartimbul et al., 2010).

Dalam perikanan, penggunaan metode ini sangat relevan karena ekosistem laut merupakan sistem yang kompleks, di mana berbagai faktor fisik dan biologis saling memengaruhi. Dua parameter utama yang sering digunakan adalah Chlo-a dan SST. Tingkat Chlo-a yang tinggi menunjukkan keberadaan fitoplankton yang merupakan dasar rantai makanan laut, sementara SST memengaruhi metabolisme, distribusi, dan perilaku spesies ikan. Kombinasi optimal dari kedua faktor ini diperlukan untuk menghasilkan kondisi ekosistem yang produktif. Sebagai contoh, Chlo-a yang tinggi ($0.3\text{--}1.0\text{ mg/m}^3$) dan SST moderat hingga optimal ($27\text{--}31\text{ }^{\circ}\text{C}$) ditemukan sangat mendukung produktivitas perikanan di perairan Thailand dan Indonesia (Doydee et al., 2010; dan Sartimbul et al., 2010). Sebaliknya, jika salah satu faktor, seperti SST, berada di kategori Kurang Baik (misalnya, suhu terlalu rendah atau terlalu tinggi), produktivitas ekosistem akan menurun meskipun Chlo-a berada dalam kategori tinggi (Adnan et al., 2022).

Prinsip Multifactor Classification didasarkan pada hubungan sinergis dan pembatasan antara faktor-faktor yang dievaluasi. Kombinasi kedua faktor yang ideal akan menghasilkan kategori Sangat Baik, sementara salah satu faktor yang berada pada kategori Kurang Baik akan menurunkan kategori keseluruhan. Contohnya, Chlo-a rendah (Cukup Baik atau Kurang Baik) membatasi produktivitas meskipun SST berada di tingkat Sangat Baik. Selain itu, jika kedua faktor berada di tingkat Kurang Baik, kondisi ekosistem menjadi sangat buruk, tidak mendukung aktivitas perikanan, dan dapat menyebabkan kerusakan ekosistem lebih lanjut (Ningsih et al., 2021; dan Suchy et al., 2019).


Keunggulan metode Multifactor Classification terletak pada kemampuannya menyediakan kerangka logis untuk mengevaluasi kondisi ekosistem berdasarkan kombinasi parameter. Metode ini juga dapat diterapkan secara luas di berbagai bidang seperti perikanan, pertanian, dan pengelolaan sumber daya alam. Namun, pada penelitian ini, metode ini memiliki keterbatasan, seperti tidak mempertimbangkan faktor lingkungan lain (misalnya, salinitas, arus laut, atau tekanan antropogenik) yang memengaruhi hasil akhir. Selain itu, parameter seperti Chlo-a dan SST bersifat dinamis sehingga klasifikasi memerlukan pembaruan secara berkala untuk mengakomodasi variabilitas temporal (Adnan et al., 2022; dan Sartimbul et al., 2010). Dengan mempertimbangkan keunggulan dan keterbatasannya, metode ini tetap menjadi alat penting dalam analisis ekosistem laut dan pengelolaan perikanan berkelanjutan.

5.4.2 Final Map (MFC) potensi penangkapan ikan pelagis besar

Pada hasil pemodelan di atas, nampak bahwa secara umum model bisa menangkap kondisi aktual yang ditunjukkan oleh data logbook, hanya saja kondisi penangkapan pada bulan Juli dan September (cakalang), Juli dan Agustus (tuna mata besar), dan Agustus dan September (tuna mata besar) yang tercatat terbaca oleh pemodelan. Namun, kondisi spesifik pada bulan-bulan tersebut dapat dijelaskan oleh pemodelan MaxEnt. Model MaxEnt juga mengindikasikan fenomena upwelling, oleh karena kondisi




lingkungan perairan pada bulan tersebut lebih dingin (SST) dan konsentrasi Chlo-a cenderung meningkat. Namun fenomena tersebut tidak terbaca secara umum, yang dapat disebabkan oleh masking effect. Masking effect merupakan situasi di mana pengaruh observasi signifikan tertutupi oleh data lainnya (Wei et al., 2021). Kondisi tersebut nampak pada diagram kuantil distribusi Chlo-a dan SST pada Gambar 5.12 berikut.




(a)






(b)




(c)






(d)



(e)





(f)

Gambar 5.12 Distribusi Chlo-a dan SST berdasarkan data 2014-2022 di WPP 714: (a) Chlo-a cakalang, (b) SST cakalang, (c) Chlo-a madidihang, (d) SST madidihang, (e) Chlo-a tuna mata besar, dan (f) SST tuna mata besar

Berdasarkan grafik pada Gambar 5.12 di atas, nampak bahwa nilai mean untuk distribusi Chlo-a dan SST (cakalang) adalah 0.25 mg/m³ dan 29.65 °C, madidihang adalah 0.25 mg/m³ dan 29.67 °C, dan tuna mata besar adalah 0.25 mg/m³ dan 29.6 °C. Adapun nilai statistik sebaran Chlo-a dan SST di WPP 714 sepanjang tahun 2014-2022 ditunjukkan pada Tabel 5.7 berikut.

Tabel 5.7 Nilai min, mean, dan max Chlo-a dan SST per bulan di WPP 714

Bulan	Mean Chlo	Mean SST	Min Chlo	Min SST	Max Chlo	Max SST
Jan	0.16	30.05	0.03	26.64	12.42	34.56
Feb	0.16	29.83	0.04	26.62	9.77	35.62
Mar	0.15	30.23	0.04	26.97	81.09	33.69
Apr	0.15	30.52	0.05	27.69	40.43	34.08
May	0.18	29.6	0.04	27.42	26.78	33.22
Jun	0.28	28.58	0.06	25.32	18.0	32.25
Jul	0.38	27.63	0.09	24.55	73.76	32.38
Aug	0.41	27.4	0.08	24.32	41.33	33.48
		27.93	0.05	23.84	57.93	33.94
		29.25	0.04	25.66	9.94	34.51
		30.71	0.04	27.35	10.18	35.53
		30.93	0.03	26.96	28.74	37.13



Dengan demikian, nampak bahwa kondisi Chlo-a dan SST pada Juni, Juli, Agustus dan September tidak ditangkap secara penuh oleh definisi kondisi optimal yang dihasilkan oleh sintesis Multi-Factor Classification di atas, karena menggunakan data seluruh bulan, kondisi inilah yang disebut sebagai masking effect. Masking effect terjadi dalam model penangkapan ikan pelagis bulanan karena pola dominan dari bulan-bulan lainnya menutupi pola spesifik yang terjadi selama upwelling pada Juni, Juli, Agustus, dan September. Akibatnya, model gagal mengenali hubungan unik antara Chlo-a, SST, dan CPUE selama periode tersebut. Untuk mengatasi masalah tersebut, dapat dilakukan melalui pemodelan berbasis data per bulanan, agar pola spesifik tersebut dapat teridentifikasi secara efektif. Pendekatan temporal granularity memungkinkan model mempertimbangkan dinamika bulanan secara spesifik sehingga pola unik pada bulan-bulan tersebut tidak tersamarkan oleh data dari bulan lainnya.

Bukti tambahan terkait masking effect dapat dilihat pada rentang nilai optimal Chlo-a dan SST per bulan pada masing-masing ikan, nampak bahwa ada perbedaan, khususnya pada Juli s.d. September, seperti yang ditunjukkan pada Tabel 5.8 berikut.

Tabel 5.8 Nilai Chlo-a dan SST optimal dan signifikan per bulan

Bulan	Rentang Optimal Cakalang		Rentang Optimal Madidihiang		Rentang Optimal Tuna Mata Besar		Nilai Signifikan Cakalang		Nilai Signifikan Madidihiang		Nilai Signifikan Tuna Mata Besar	
	Chlo*	SST**	Chlo*	SST**	Chlo*	SST**	Chlo*	SST**	Chlo*	SST**	Chlo*	SST**
Jan	0.093	29.635	0.093	29.59	0.093	29.588	0.175	30.105	0.161	29.77	0.176	30.156
	0.433	30.162	0.442	30.142	0.458	30.143						
Feb	0.089	30 -	0.010	30 -	0.102	30 -	0.165	30	0.161	29	0.165	29
	0.179	30	0.286	30	0.272	30						
Mar	0.088	30 -	0.088	30 -	0.088	30 -	0.145	30	0.171	30	0.227	30
	0.205	30	0.375	30	0.249	30						
Apr	0.082	30.194	0.087	30.181	0.087	29.713	0.138	30.333	0.319	30.091	0.117	29.635
	0.211	30.63	0.360	30.608	0.214	- 30.1						
May	0.093	28.836	0.097	28.717	0.098	28.674	0.173	29.153	0.156	29.582	0.128	29.456
	0.218	29.343	0.282	29.168	0.274	29.045						
Jun	0.090	27 -	0.098	28.932	0.103	29 -	0.183	28	0.324	28.055	0.244	28
	0.259	28	0.250	30.689	0.372	30						
Jul	0.288	27 -	0.292	27 -	0.213	27 -	0.339	27	0.501	27	0.357	26
	0.431	27	0.443	27	0.384	27						
Aug	0.187	27.799	0.166	27.848	0.328	27.899	0.362	28.351	0.395	28.146	0.421	28.338
	0.325	28.433	0.365	28.435	0.459	28.435						
Sep	0.148	28.663	0.139	27.699	0.319	26.593	0.382	28.032	0.227	28.015	0.238	27.996
	0.340	29.52	0.398	28.692	0.522	27.256						
			0.095	29.562	0.103	29.174	0.158	29	0.158	29.699	0.244	29.145
			0.242	30.643	0.255	30.149						
			0.084	31 -	0.098	31 -						
			0.249	31	0.247	31						



Des	0.075	31 -	0.075	30.562	0.088	30.525						
	-	31	-	-	-	-	0.166	30	0.198	29.933	0.145	29.88
	0.201		0.193	31.084	0.248	31.557						

Ket.: * (mg/m³), dan ** (°C)

Selain itu, model MaxEnt mengidentifikasi adanya indikasi fenomena upwelling, oleh karena kondisi lingkungan perairan pada bulan tersebut lebih dingin (SST) dan konsentrasi Chlo-a cenderung meningkat. Namun fenomena tersebut tidak terbaca oleh model, yang dapat disebabkan oleh masking effect.

Upwelling di WPP 714 (Laut Banda) terjadi selama musim angin tenggara (Southeast Monsoon), yaitu pada bulan Juli hingga September, dengan intensitas puncak umumnya pada Agustus. Fenomena ini terjadi akibat angin musiman yang menyebabkan transportasi Ekman, di mana air permukaan terdorong dan digantikan oleh air dingin dari lapisan bawah yang kaya nutrisi. Proses ini meningkatkan konsentrasi Chlo-a dan menurunkan SST, menciptakan lingkungan yang sangat produktif untuk perikanan pelagis. Penelitian menunjukkan bahwa fenomena ini mengindikasikan adanya distribusi fitoplankton dan ikan pelagis di wilayah tersebut (Rachmayani et al., 2019).

Penelitian lain juga menunjukkan bahwa intensitas upwelling ini sangat dipengaruhi oleh pola monsun dan variabilitas iklim global seperti ENSO (El Niño dan La Niña). Selama tahun La Niña, intensitas upwelling cenderung lebih kuat, sedangkan pada tahun El Niño intensitasnya melemah. Selain itu, perubahan suhu permukaan laut yang dipengaruhi oleh fenomena seperti marine heatwaves dapat memengaruhi efektivitas upwelling, yang berimplikasi pada produktivitas primer di wilayah Laut Banda (Rachman et al., 2020).

Upwelling terjadi ketika terjadi penurunan SST yang signifikan (sekitar 25-26°C) dan peningkatan drastis Chlo-a di lapisan permukaan laut (Rintaka & Priyono, 2020). Saat terjadi upwelling selama musim tenggara (Southeast monsoon), kondisi oseanografi ditandai dengan SST yang rendah, berkisar antara 25.06°C hingga 26.44°C, serta konsentrasi Chlo-a yang tinggi, yaitu 0.8 mg/m³ hingga 3 mg/m³ (Suprianto et al., 2021).

5.4.3 Klaster potensi penangkapan cakalang, madidihang, dan tuna mata besar di WPP 714

Analisis spasio-temporal kondisi perairan di WPP 714 sepanjang tahun menunjukkan bahwa strategi penangkapan ikan pelagis seperti cakalang, madidihang, dan tuna mata besar perlu disesuaikan dengan fluktuasi musiman yang signifikan. Pada Januari hingga Februari, perairan memiliki kualitas yang relatif baik, didominasi oleh kategori CMT-BBB dan CMT-BBC. Ini merupakan periode optimal untuk meningkatkan aktivitas penangkapan di wilayah barat dan tengah, di mana konsentrasi ikan pelagis lebih tinggi. Penangkapan dapat dilakukan dengan intensitas tinggi menggunakan alat tangkap ramah lingkungan serta pancing ulur guna meminimalkan tangkapan sampingan. Kondisi perairan harus dilakukan secara rutin agar aktivitas berkelanjutan (Riadi et al., 2024).

hingga Mei, terjadi penurunan kualitas perairan ke kategori



CMT-BCC dan CMT-CCC. Oleh karena itu, strategi penangkapan perlu disesuaikan dengan mengurangi kuota tangkapan guna mencegah tekanan berlebih pada populasi ikan, terutama di wilayah tengah dan timur yang menunjukkan penurunan kualitas signifikan. Aktivitas penangkapan sebaiknya difokuskan di wilayah barat dan selatan yang menunjukkan perbaikan kondisi, terutama pada Mei. Selain itu, penggunaan alat tangkap yang lebih selektif diperlukan untuk mengurangi risiko menangkap ikan yang berada dalam kondisi stres. Regulasi terkait pembatasan penangkapan juga perlu diperkuat untuk menghindari eksploitasi yang berlebihan (Hermanto et al., 2019).


Pada periode Juni hingga Agustus, kondisi perairan memburuk secara drastis, dengan dominasi kategori Kurang Baik (CMT-KKK) yang mencapai puncaknya pada Agustus. Bulan September hingga Oktober, terjadi pemulihan parsial di beberapa wilayah, terutama di bagian barat dan selatan. Sistem rotasi wilayah penangkapan dapat diterapkan untuk memberi waktu pemulihan di area lain yang masih mengalami tekanan. Alat tangkap yang digunakan harus tetap selektif guna menjaga kelestarian populasi ikan. Selain itu, penerapan pemantauan berbasis GIS dapat meningkatkan efektivitas pengelolaan perikanan dengan memberikan data spasial yang lebih akurat untuk pengambilan keputusan (Saha et al., 2019).

Pada November hingga Desember, kualitas perairan mengalami penurunan dengan dominasi kategori CMT-CCC, terutama pada Desember ketika hampir separuh wilayah berada dalam kondisi kurang baik. Oleh karena itu, aktivitas penangkapan perlu dikurangi secara signifikan, dan difokuskan hanya pada wilayah yang menunjukkan kondisi lebih baik, seperti wilayah barat. Penangkapan harus difokuskan pada ikan dewasa untuk menjaga kelestarian populasi, serta evaluasi hasil penangkapan sepanjang tahun perlu dilakukan guna merencanakan strategi yang lebih baik di tahun berikutnya. Dengan pendekatan berbasis data spasio-temporal, pengelolaan sumber daya ikan dapat dilakukan lebih efisien guna menjaga keseimbangan ekosistem laut (Nurholis et al., 2020).


Secara keseluruhan, strategi penangkapan ikan pelagis di WPP 714 harus bersifat adaptif dan berkelanjutan, dengan penyesuaian kuota berdasarkan kondisi perairan yang berubah setiap bulan. Penerapan teknologi pemantauan seperti satelit dan GIS sangat penting untuk mendapatkan data real-time yang dapat mendukung pengambilan keputusan. Kolaborasi dengan nelayan lokal dalam pengelolaan sumber daya serta edukasi tentang praktik perikanan berkelanjutan juga sangat penting. Selain itu, diversifikasi jenis ikan yang ditangkap dan penguatan regulasi serta pengawasan terhadap praktik penangkapan ilegal akan membantu menjaga keseimbangan ekosistem laut dan mendukung keberlanjutan industri perikanan di WPP 714 (Gonzalez et al., 2021).

Adapun lokasi prediksi potensial untuk tangkapan ikan pelagis besar berdasarkan distribusi Chlo-a dan SST di WPP 714 digambarkan pada peta 5.13 berikut ini (Selnakapnya Terlampir 9.5 dan 9.6), khususnya Januari, Maret, dan






(a)




(b)






(c)




(d)






(e)




(f)



Optimized using
trial version
www.balesio.com




(g)




(h)






(i)




(j)





(k)



(l)

Gambar 5.13 Prediksi tangkapan ikan pelagis CMT-BBB (a) Januari, (b) Maret, (c) Mei, peta sebaran Chlo-SST: (d) Cakalang-Januari, (e) Madidihiang-Januari, (f) Tuna Mata Besar-Januari, (g) Cakalang-Maret, (h) Madidihiang-Maret, (i) Tuna Mata Besar-Maret, (j) Cakalang-Mei, (k) Madidihiang-Mei, dan (l) Tuna Mata Besar-Mei



3 (a-c) merupakan representasi hasil subset peta untuk kondisi asarkan analisis peta sebaran prediksi tangkapan ikan pelagis ang tahun tersebut, terlihat adanya dinamika distribusi lokasi

tangkapan bagi Cakalang, Madidihang, dan Tuna Mata Besar berdasarkan nilai data tes berat ikan (prediksi). Pola perubahan ini dipengaruhi oleh faktor lingkungan dan dinamika ekosistem laut yang mempengaruhi ketersediaan ikan di wilayah tersebut. Kategori lokasi prediksi diklasifikasikan menjadi Sangat Baik (S), Baik (B), Cukup Baik (C), dan Kurang Baik (K) untuk masing-masing spesies.

Pada awal tahun (Januari - Juni), cakalang dan madidihang banyak ditemukan di sekitar 124° - 126° BT dan 2° - 5° LS, sementara tuna mata besar lebih tersebar di bagian selatan perairan. Selama periode ini, lokasi tangkapan cukup stabil, menunjukkan bahwa kondisi lingkungan laut mendukung keberadaan ketiga spesies ini di wilayah tersebut.

Memasuki pertengahan tahun (Juli - September), mulai terjadi perubahan pola distribusi ikan, di mana subset kondisi perairan terbaik ditunjukkan oleh kondisi CMT-CCC. Secara umum, area tangkapan cakalang dan madidihang berada di area yang sama dengan sebelumnya, tetapi distribusinya mulai meluas. Sebaliknya, tuna mata besar mengalami pergeseran lebih signifikan, dengan beberapa lokasi tangkapan potensial berpindah ke bagian timur dan selatan. Perubahan ini dapat dikaitkan dengan faktor seperti suhu permukaan laut, pola arus, dan ketersediaan makanan yang berfluktuasi sepanjang tahun.

Pada akhir tahun (Oktober - Desember), pola distribusi semakin bervariasi. Pada bulan Oktober, subset area terbaik direpresentasikan oleh CMT-CBB yang mengindikasikan bahwa lokasi 'Cukup Baik' untuk cakalang, dan 'Baik' untuk madidihang dan tuna mata besar. Pada bulan November, lokasi dengan kategori BBC mengindikasikan bahwa kondisi 'Baik' untuk cakalang dan madidihang, tetapi 'Cukup Baik' untuk Tuna Mata Besar. Kemudian, pada bulan Desember, kategori lokasi berubah menjadi BCB, di mana perairan mengalami sedikit penurunan kualitas untuk madidihang dari 'Baik' menjadi 'Cukup Baik', sementara kondisi untuk tuna mata besar membaik dibandingkan bulan sebelumnya.

Secara keseluruhan, pola distribusi ikan pelagis di WPP 714 menunjukkan bahwa cakalang dan madidihang memiliki lokasi utama yang cukup stabil sepanjang tahun, meskipun terjadi perubahan tingkat kepadatan pada bulan-bulan tertentu. Sementara itu, tuna mata besar menunjukkan pola migrasi yang lebih dinamis, terutama pada pertengahan hingga akhir tahun. Perubahan ini menekankan pentingnya pemantauan berkala terhadap kondisi lingkungan laut serta pemanfaatan pemodelan prediktif untuk meningkatkan efektivitas penangkapan ikan. Oleh karena itu, strategi penangkapan perlu disesuaikan dengan perubahan lokasi dan kategori habitat setiap bulannya agar dapat memaksimalkan hasil tangkapan secara berkelanjutan, dengan tetap menjaga keseimbangan ekosistem laut.

Untuk memahami lebih detail dinamika sebaran Chlo-SST dan prediksi berat ikan pelagis ekonomis penting, maka dilakukan telaah per jenis ikan sebagaimana pada Gambar 5.13 (d-l). Pada Januari hingga Desember, nampak bahwa cakalang terlihat mengalami perubahan pola spasial yang memengaruhi

si tangkapan di WPP 714. Sepanjang tahun, wilayah dengan ik dan Cukup Baik mengalami fluktuasi yang memengaruhi ksi berat ikan Cakalang tertinggi.

iri-Juni, sebagian besar wilayah perairan WPP 714 didominasi



oleh kategori Baik dan Cukup Baik, terutama di bagian utara dan barat laut. Konsentrasi prediksi berat ikan Cakalang yang tinggi cenderung berada di wilayah dengan kategori lingkungan yang mendukung. Pada periode ini, zona Sangat Baik tersedia, terutama di perairan barat daya dan selatan. Prediksi berat ikan Cakalang menunjukkan konsentrasi terbesar di sekitar perairan barat laut dan beberapa bagian tengah.

Memasuki pertengahan tahun (Juli–September), kondisi lingkungan laut mengalami perubahan. Pada Juli dan Agustus, umumnya wilayah berubah menjadi kategori Kurang Baik. Pada periode ini, prediksi berat ikan Cakalang lebih tersebar, tetapi dengan konsentrasi yang lebih rendah dibandingkan awal tahun. Wilayah barat laut dan tengah masih menjadi area utama, meskipun terdapat pengurangan berat ikan pada beberapa titik. Pada bulan September, kondisi perairan mulai mengalami pemulihan, dengan peningkatan kembali wilayah kategori Cukup Baik dan Baik, terutama di bagian utara dan barat daya.

Pada akhir tahun (Oktober–Desember), kondisi lingkungan laut menunjukkan perbaikan dengan semakin luasnya kategori Baik dan Cukup Baik dibandingkan bulan-bulan pertengahan tahun. Pada bulan Oktober, banyak titik dengan prediksi berat ikan Cakalang yang lebih tinggi dibandingkan bulan sebelumnya, terutama di wilayah barat laut. Perbaikan kondisi ini terus berlanjut hingga bulan November dan Desember, di mana wilayah kategori Kurang Baik semakin berkurang, dan prediksi berat ikan Cakalang semakin terkonsentrasi di perairan bagian barat dan tengah WPP 714.

Secara keseluruhan, pola distribusi ikan cakalang sangat dipengaruhi oleh variasi musiman dalam suhu permukaan laut dan ketersediaan klorofil. Semester pertama dan akhir tahun lebih stabil, dengan dominasi kategori Baik dan Cukup Baik, sementara pertengahan tahun mengalami kondisi yang kurang menguntungkan bagi kelimpahan ikan. Oleh karena itu, strategi penangkapan ikan harus disesuaikan dengan perubahan kondisi perairan ini, dengan fokus utama pada perairan barat laut dan tengah, yang secara konsisten menjadi area dengan prediksi berat ikan Cakalang tertinggi.

Nilai optimal penangkapan ikan cakalang di WPP 714 berdasarkan penelitian ini adalah 0.04–0.64 mg/m³ untuk konsentrasi Chlo-a dan 28.48–31.05 °C untuk SST, yang secara umum masih relevan dengan hasil penelitian sebelumnya di WCPO (Tang et al., 2013) dengan kisaran SST 28–30 °C dan Chlo-a 0.01–0.20 mg/m³, di Teluk Bone (Zainuddin et al., 2013) dengan SST 28.75–31.5 °C dan Chlo-a 0.10–0.20 mg/m³, serta di WPP 573 (Nursan et al., 2022) dengan SST 26.76–32.32 °C dan Chlo-a 0.08–0.95 mg/m³, menunjukkan kesesuaian ekologis dan adaptasi ikan cakalang terhadap variasi parameter oseanografi antarwilayah.

Adapun pada madidihang, terlihat adanya pola fluktuasi kondisi lingkungan laut yang mempengaruhi distribusi dan bobot tangkapan ikan. Pada bulan Januari–Maret, wilayah dengan kategori "baik" dan "cukup baik" sebagian besar perairan, dengan distribusi ikan Madidihang yang a di perairan barat dan tengah. Tangkapan dengan bobot lebih berada di zona dengan kondisi lingkungan yang lebih stabil dan



Memasuki pertengahan tahun (April-Juni), terjadi perubahan signifikan pada sebaran Chlo-SST, di mana area dengan kategori "sangat baik" tersedia, terutama di wilayah pesisir dan zona transisi perairan. Meskipun masih terdapat daerah dengan kondisi "cukup baik" yang mendukung keberadaan Madidihang, beberapa wilayah mulai mengalami peningkatan kategori "kurang baik", khususnya di bagian selatan. Distribusi ikan masih menunjukkan pola yang mengikuti area dengan produktivitas tinggi, dengan beberapa titik tangkapan yang lebih besar tersebar lebih luas dibandingkan pada awal tahun.

Pada periode Juli-September, terjadi penurunan kualitas lingkungan laut secara umum, yang menunjukkan kondisi "kurang baik". Pada Oktober - Desember, kondisi lingkungan laut kembali membaik dengan meningkatnya area kategori "cukup baik" dan "baik" yang tersebar lebih merata di seluruh perairan. Hal ini berdampak pada peningkatan kembali jumlah dan bobot tangkapan ikan Madidihang, terutama di wilayah barat dan tengah perairan. Pada bulan Desember, distribusi ikan cenderung lebih stabil, dengan banyak titik tangkapan berada di area yang memiliki kondisi lingkungan yang mendukung.

Secara keseluruhan, hasil analisis menunjukkan bahwa distribusi dan bobot ikan Madidihang sangat dipengaruhi oleh kondisi lingkungan perairan, terutama parameter Chlo-SST. Wilayah dengan kategori "baik" hingga "cukup baik" sepanjang tahun menjadi area potensial untuk penangkapan ikan ini. Oleh karena itu, pemanfaatan data lingkungan laut dapat membantu optimalisasi strategi penangkapan bagi nelayan agar dapat menargetkan lokasi dengan hasil tangkapan yang lebih tinggi dan lebih berkelanjutan.

Nilai optimal penangkapan ikan madidihang di WPP 714 berdasarkan penelitian ini adalah 0.04–0.33 mg/m³ untuk konsentrasi klorofil-a dan 26.92–30.50 °C untuk suhu permukaan laut (SST). Temuan ini memiliki relevansi kuat dengan beberapa studi sebelumnya, seperti penelitian Bahri et al. (2017) di perairan Aceh yang menunjukkan kisaran SST 26–30 °C dan Chlo-a 0.01–3.7 mg/m³, meskipun rentang Chlo-a-nya lebih lebar karena kemungkinan kondisi eutrofik lokal. Studi Dita et al. (2024) di Sendang Biru memperlihatkan kisaran SST 28.72–29.65 °C dan Chlo-a 0.15–0.5 mg/m³, sedangkan Paillin et al. (2020) di Laut Seram melaporkan SST 29.13–30.12 °C dan Chlo-a 0.16–0.25 mg/m³.

Pada ikan tuna mata besar, distribusi Chlo-SST dan prediksi berat ikan menunjukkan variasi musiman yang signifikan, yang mempengaruhi potensi penangkapan ikan. Pada awal tahun, Januari - Maret, kondisi perairan didominasi oleh kategori Chlo-SST "Baik" dan "Cukup Baik", dengan wilayah tangkapan utama berada di bagian tengah dan selatan perairan. Distribusi ikan Tuna Mata Besar pada periode ini cukup merata, dengan beberapa area menunjukkan bobot ikan yang lebih tinggi. Pada bulan April hingga Mei, kondisi perairan tetap stabil, menandakan bahwa lingkungan masih mendukung pertumbuhan dan keberadaan ikan Tuna Mata Besar.

Pada Juni hingga Agustus, terjadi perubahan drastis pada kondisi lingkungan yang mengalami penurunan. Pada September dan Oktober, kondisi lingkungan kembali membaik dengan peningkatan area "Cukup Baik" dan "Baik", yang meningkatkan potensi tangkapan di beberapa wilayah utama. Pada akhir tahun Desember, memperlihatkan pemulihan kondisi lingkungan



laut, menandakan perairan yang lebih optimal untuk keberadaan ikan Tuna Mata Besar. Pada periode ini, sebaran ikan kembali meningkat, terutama di area dengan konsentrasi klorofil yang lebih tinggi, yang menjadi indikator baik bagi aktivitas perikanan.

Secara keseluruhan, pola sebaran Chlo-SST menunjukkan pengaruh besar terhadap prediksi berat ikan Tuna Mata Besar sepanjang tahun. Pada musim dengan kondisi lingkungan yang baik, cenderung menghasilkan potensi tangkapan yang lebih besar. Oleh karena itu, pemantauan berkala terhadap dinamika lingkungan laut menjadi hal yang sangat penting dalam menentukan strategi penangkapan yang optimal agar hasil tangkapan dapat dimaksimalkan sesuai dengan kondisi perairan yang mendukung.

Nilai optimal penangkapan ikan tuna mata besar di WPP 714 berdasarkan penelitian ini adalah 0.06–0.33 mg/m³ untuk konsentrasi klorofil-a (Chlo-a) dan 27–30.66 °C untuk suhu permukaan laut (SST). Hasil ini memiliki relevansi dengan beberapa studi sebelumnya, seperti Semedi et al. (2021) di perairan Selatan Jawa yang menunjukkan kisaran SST 25–30 °C dan Chlo-a 0.08–0.30 mg/m³, yang sangat dekat dengan hasil penelitian ini. Sementara itu, studi Arta et al. (2024) di Sumatera Barat mencatat SST 29.5–30.8 °C dan rata-rata Chlo-a 2.01 mg/m³, dengan tingkat produktivitas primer yang lebih tinggi, menunjukkan kemungkinan pengaruh lokal seperti upwelling yang kuat. Di sisi lain, penelitian Vaihola & Kininmonth (2023) di perairan Tonga melaporkan SST 18–30 °C dan Chlo-a 0.03–0.1 mg/m³, mencerminkan toleransi suhu yang lebih luas namun tingkat produktivitas primer yang lebih rendah. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa kisaran nilai oseanografi yang ditemukan di WPP 714 masih selaras dengan preferensi ekologis tuna mata besar di wilayah tropis, dan dapat dijadikan dasar dalam pengembangan model prediksi zona potensial penangkapan.

Berdasarkan analisis prediksi tangkapan ikan pelagis di Wilayah Pengelolaan Perikanan (WPP) 714 dari Januari hingga Desember pada peta di atas, nampak bahwa terdapat hubungan yang kuat antara distribusi ikan dengan konsentrasi Chlo-a dan SST. Perubahan musiman memengaruhi pola distribusi ikan. Pada awal tahun (Januari-Maret), ikan lebih terkonsentrasi di bagian barat laut, yang memiliki tingkat Chlo-a sedang hingga tinggi. Memasuki pertengahan tahun (Juni-Agustus), terdapat pergeseran distribusi ikan yang lebih luas, dengan peningkatan jumlah tangkapan di bagian timur laut seiring dengan meningkatnya konsentrasi Chlo-a di wilayah tersebut (Zikri et al., 2023). Pada akhir tahun (September-Desember), penyebaran ikan semakin merata di seluruh wilayah, dengan kecenderungan peningkatan tangkapan di bagian timur yang mengalami peningkatan produktivitas perairan (Elepathage & Tang, 2019).

SST juga berperan dalam menentukan distribusi ikan pelagis. Secara umum, cakalang lebih banyak ditemukan di daerah bersuhu lebih hangat (28°C - 32°C), sementara tuna mata besar lebih memilih wilayah dengan suhu lebih rendah (Arias et al., 2022). Hal ini menunjukkan fleksibilitas mereka, dengan distribusi yang lebih luas di berbagai zona termal. Hingga Desember, SST menunjukkan pola fluktuatif dengan suhu tinggi di bagian barat dan lebih rendah di bagian timur. Pada



pertengahan tahun (Juli-Agustus), terjadi peningkatan suhu di bagian barat daya, yang menyebabkan perubahan pola distribusi ikan (Hidayat et al., 2022). Namun, pada bulan-bulan akhir tahun (November-Desember), suhu menjadi lebih stabil, memungkinkan sebaran ikan yang lebih merata di seluruh wilayah.

Secara keseluruhan, pola distribusi ikan pelagis di WPP 714 dipengaruhi oleh interaksi antara Chlo-a dan SST, dengan kecenderungan ikan berpindah mengikuti perubahan produktivitas perairan dan suhu yang sesuai dengan preferensi spesies masing-masing. Pergeseran musiman dalam pola distribusi ini dapat dimanfaatkan oleh nelayan dan pengelola perikanan untuk menentukan area potensial penangkapan ikan yang lebih efektif dan berkelanjutan sepanjang tahun (Zainuddin et al., 2023).

5.4.4 Validasi model pada penangkapan cakalang, madidiang, dan tuna mata besar di WPP 714

Untuk mengevaluasi kinerja model yang telah dibangun maka dilakukan validasi pada data yang tidak digunakan saat pelatihan (data yang terpisah atau disebut juga sebagai data uji). Tujuannya adalah untuk memastikan bahwa model yang dibuat dapat menggeneralisasi dan memberikan hasil yang akurat pada data yang belum pernah dilihat sebelumnya. Validasi dilakukan dengan melihat persentase overlay berat ikan dengan area nilai optimal faktor oseanografis.

Validasi dilakukan pada periode bulan yang dianggap representatif, yakni pada Januari, Maret, dan Mei untuk semua jenis ikan. Hasil validasi menunjukkan bahwa penangkapan ikan cakalang pada bulan Januari berdasarkan kategori berat ikan dan nilai optimal sebagai berikut. Nilai optimal merujuk pada kisaran Chlo-a antara 0,04 - 0,64 mg/m³ dan SST antara 28,48 - 31,05°C. Hasil menunjukkan bahwa, kategori Sangat Rendah (< 58.672 kg) adalah nilai validasi tertinggi sebesar 98,214%, yang mengindikasikan bahwa ikan dalam kategori ini lebih banyak ditemukan pada kondisi oseanografis yang berada dalam rentang optimal. Sebaliknya, kategori Tinggi (323.623 - 567.501 kg) memiliki nilai validasi terendah yaitu 85,833%, yang menunjukkan bahwa ikan dengan berat tersebut lebih jarang ditemukan dalam rentang kondisi oseanografis optimal. Kategori Kurang Tinggi (58.672 - 134.212 kg) dan Cukup Tinggi (134.212 - 323.623 kg) masing-masing memiliki nilai validasi 94,393% dan 89,767%, yang menunjukkan bahwa ikan dengan berat dalam rentang ini masih ditemukan dalam kondisi oseanografis yang optimal, meskipun sedikit lebih rendah dibandingkan dengan kategori Sangat Rendah. Sementara itu, kategori Sangat Tinggi (> 567.501 kg) menunjukkan nilai validasi sebesar 96,290%, yang meskipun tinggi, masih sedikit lebih rendah dibandingkan dengan kategori berat Sangat Rendah. Secara keseluruhan, analisis ini mengindikasikan bahwa ikan dengan berat yang lebih kecil lebih sering ditemukan pada kondisi oseanografis optimal, sedangkan ikan yang lebih berat cenderung kurang tervalidasi dalam kondisi oseanografis optimal tersebut.



Validasi penangkapan ikan cakalang pada bulan Maret berdasarkan kategori berat ikan dan nilai optimal menunjukkan hasil yang sangat baik. Untuk kategori Sangat Rendah (< 58.672 kg), nilai validasi mencapai 100%, yang menunjukkan bahwa ikan dengan berat ini sepenuhnya ditemukan dalam kondisi oseanografis yang berada dalam rentang optimal. Ini menunjukkan bahwa

ikan yang lebih kecil sangat sesuai dengan kondisi oseanografis yang ideal. Kategori Kurang Tinggi (58.672 - 134.212 kg) memiliki nilai validasi sebesar 85,354%, yang menunjukkan bahwa meskipun ikan dalam kategori ini masih sering ditemukan dalam kondisi oseanografis optimal, ada penurunan dibandingkan dengan kategori Sangat Rendah. Kategori Cukup Tinggi (134.212 - 323.623 kg) menunjukkan nilai validasi 98,872%, yang berarti ikan dengan berat ini hampir seluruhnya ditemukan dalam rentang oseanografis yang optimal, meskipun sedikit lebih rendah dibandingkan dengan kategori Sangat Rendah. Kategori Tinggi (323.623 - 567.501 kg) memiliki nilai validasi sebesar 99,645%, yang sangat tinggi, mengindikasikan bahwa ikan dengan berat ini sebagian besar ditemukan dalam kondisi oseanografis yang ideal, meskipun masih sedikit lebih rendah dibandingkan dengan kategori berat Cukup Tinggi. Terakhir, kategori Sangat Tinggi (> 567.501 kg) memiliki nilai validasi 99,835%, yang hampir identik dengan kategori Tinggi, menunjukkan bahwa ikan yang lebih berat juga umumnya ditemukan dalam kondisi oseanografis yang optimal, meskipun sedikit lebih tinggi dari kategori Tinggi.

Adapun validasi penangkapan ikan cakalang pada bulan Mei menunjukkan hasil yang bervariasi berdasarkan kategori berat ikan dan kesesuaian dengan kondisi oseanografis optimal. Untuk kategori Sangat Rendah (< 58.672 kg), nilai validasi mencapai 90,000%, yang menunjukkan bahwa ikan dengan berat ini sebagian besar ditemukan dalam kondisi oseanografis yang berada dalam rentang optimal, meskipun sedikit lebih rendah dibandingkan dengan bulan Januari dan Maret. Kategori Kurang Tinggi (58.672 - 134.212 kg) memiliki nilai validasi 94,118%, yang menunjukkan bahwa ikan dalam kategori ini lebih sering ditemukan dalam kondisi oseanografis optimal, meskipun tetap ada penurunan dibandingkan dengan kategori Sangat Rendah. Kategori Cukup Tinggi (134.212 - 323.623 kg) menunjukkan nilai validasi 84,000%, yang mengindikasikan bahwa ikan dalam rentang berat ini lebih jarang ditemukan dalam kondisi oseanografis yang optimal, dibandingkan dengan kategori yang lebih kecil. Kategori Tinggi (323.623 - 567.501 kg) memiliki nilai validasi 79,268%, yang menandakan bahwa ikan dengan berat lebih tinggi ini lebih sedikit ditemukan dalam rentang kondisi oseanografis yang optimal. Terakhir, kategori Sangat Tinggi (> 567.501 kg) menunjukkan nilai validasi 86,301%, yang sedikit lebih tinggi dibandingkan dengan kategori Tinggi, namun tetap lebih rendah daripada kategori lainnya. Ini menunjukkan bahwa ikan dengan berat sangat tinggi masih sering ditemukan dalam kondisi oseanografis yang cukup optimal, meskipun kurang sering dibandingkan dengan kategori ikan yang lebih kecil.

Penelitian menunjukkan bahwa berat ikan berhubungan dengan kondisi lingkungan tempat mereka hidup, terutama di laut. Ikan yang lebih kecil cenderung ditemukan di tempat dengan kondisi lingkungan yang lebih baik untuk pertumbuhannya, seperti yang ditemukan dalam studi oleh Ferraz et al. (2021) di Brasil dan Puiari et al. (2024) di Mumbai, yang menunjukkan bahwa ikan besar < seimbang di tempat dengan kondisi buruk. Penelitian oleh) di Vietnam juga mengungkapkan bahwa pemahaman tentang dan berat ikan dapat memberi petunjuk apakah lingkungan | pertumbuhannya. Secara keseluruhan, ikan kecil lebih sering



tumbuh optimal di lingkungan yang baik, sementara ikan besar sering ditemukan di tempat yang kurang ideal, menunjukkan bahwa kondisi lingkungan mempengaruhi pertumbuhan ikan, terutama yang lebih kecil.

Pada madidihiang, validasi penangkapan pada bulan Januari berdasarkan kategori berat ikan dan nilai optimal menunjukkan hasil yang bervariasi. Untuk kategori Sangat Rendah (< 71.753 kg), nilai validasi mencapai 95,402%, yang menunjukkan bahwa ikan dengan berat ini ditemukan dengan sangat baik pada kondisi oseanografis yang optimal. Ini menunjukkan bahwa ikan dengan berat lebih kecil cenderung lebih sering berada dalam kondisi lingkungan yang mendukung. Kategori Kurang Tinggi (71.753 - 92.050 kg) memiliki nilai validasi sebesar 95,161%, yang hampir identik dengan kategori Sangat Rendah, mengindikasikan bahwa ikan dalam rentang berat ini juga sering ditemukan dalam kondisi oseanografis optimal, meskipun sedikit lebih rendah. Kategori Cukup Tinggi (92.050 - 133.943 kg) memiliki nilai validasi 78,505%, yang menunjukkan penurunan yang cukup signifikan dibandingkan dengan kategori berat yang lebih rendah. Ini mengindikasikan bahwa ikan dalam rentang berat ini lebih jarang ditemukan dalam kondisi oseanografis yang optimal, meskipun masih cukup sering. Kategori Tinggi (133.943 - 204.834 kg) menunjukkan nilai validasi 83,846%, yang lebih tinggi dibandingkan dengan kategori Cukup Tinggi, tetapi tetap lebih rendah daripada kategori Sangat Rendah dan Kurang Tinggi, yang mengindikasikan bahwa ikan dengan berat lebih besar ini kurang sering ditemukan pada kondisi oseanografis yang optimal. Terakhir, kategori Sangat Tinggi (> 204.834 kg) memiliki nilai validasi 86,061%, yang meskipun lebih tinggi daripada kategori Tinggi, masih menunjukkan bahwa ikan dengan berat sangat tinggi ini cenderung lebih jarang ditemukan pada kondisi oseanografis yang optimal, meskipun tetap memenuhi sebagian besar kriteria oseanografis.

Validasi penangkapan ikan madidihiang pada bulan Maret menunjukkan hasil yang relatif serupa dengan bulan Januari, meskipun ada sedikit perbedaan dalam distribusi nilai optimal. Untuk kategori Sangat Rendah (< 71.753 kg), nilai validasi mencapai 94,444%, yang mengindikasikan bahwa ikan dengan berat ini ditemukan dalam kondisi oseanografis yang optimal, meskipun sedikit lebih rendah dibandingkan dengan bulan Januari. Kategori Kurang Tinggi (71.753 - 92.050 kg) menunjukkan nilai validasi sebesar 94,565%, yang hampir identik dengan kategori Sangat Rendah, menunjukkan bahwa ikan dalam rentang berat ini juga ditemukan dalam kondisi oseanografis yang hampir sama baiknya. Kategori Cukup Tinggi (92.050 - 133.943 kg) memiliki nilai validasi 95,122%, yang merupakan nilai tertinggi dalam tabel ini, mengindikasikan bahwa ikan dalam rentang berat ini lebih sering ditemukan dalam kondisi oseanografis yang optimal. Kategori Tinggi (133.943 - 204.834 kg) menunjukkan nilai validasi 88,106%, yang sedikit lebih rendah dibandingkan dengan kategori Cukup Tinggi, menandakan bahwa ikan dengan berat yang lebih tinggi ini lebih jarang ditemukan dalam kondisi oseanografis optimal. Terakhir, kategori Sangat Tinggi (> 204.834 kg) memiliki nilai

yang merupakan nilai validasi tertinggi pada kategori berat ini, lebih tinggi dibandingkan dengan kategori Tinggi.

Validasi penangkapan ikan madidihiang pada bulan Mei yang bervariasi berdasarkan kategori berat ikan dan



kesesuaian dengan kondisi oseanografis optimal. Untuk kategori Sangat Rendah (< 58.672 kg), nilai validasi mencapai 90,000%, yang mengindikasikan bahwa ikan dengan berat ini sebagian besar ditemukan dalam kondisi oseanografis yang berada dalam rentang optimal, meskipun sedikit lebih rendah dibandingkan dengan bulan Januari dan Maret. Kategori Kurang Tinggi (58.672 - 134.212 kg) menunjukkan nilai validasi 94,118%, yang hampir identik dengan kategori Sangat Rendah, mengindikasikan bahwa ikan dalam rentang berat ini juga sering ditemukan dalam kondisi oseanografis optimal, meskipun sedikit lebih rendah. Kategori Cukup Tinggi (134.212 - 323.623 kg) memiliki nilai validasi 84,000%, yang menunjukkan penurunan yang cukup signifikan dibandingkan dengan kategori berat yang lebih rendah. Ini mengindikasikan bahwa ikan dalam rentang berat ini lebih jarang ditemukan dalam kondisi oseanografis yang optimal, meskipun masih cukup sering. Kategori Tinggi (323.623 - 567.501 kg) menunjukkan nilai validasi 79,268%, yang menandakan bahwa ikan dengan berat lebih tinggi ini lebih sedikit ditemukan dalam rentang kondisi oseanografis yang optimal. Terakhir, kategori Sangat Tinggi (> 567.501 kg) memiliki nilai validasi 86,301%, yang meskipun lebih tinggi dibandingkan dengan kategori Tinggi, masih menunjukkan bahwa ikan dengan berat sangat tinggi ini cenderung lebih jarang ditemukan dalam kondisi oseanografis yang optimal.

Secara keseluruhan, hasil validasi pada ikan madidihang menunjukkan bahwa ikan dengan berat lebih kecil lebih sering ditemukan dalam kondisi oseanografis yang optimal, sementara ikan yang lebih berat cenderung lebih jarang berada dalam rentang kondisi oseanografis yang mendukung sebagaimana pada ikan cakalang.

Adapun hasil validasi penangkapan ikan tuna mata besar pada bulan Januari berdasarkan kategori berat ikan dan nilai optimal adalah sebagai berikut. Nilai optimal merujuk pada kondisi oseanografis yang ideal, dengan sebagian besar kategori berat ikan mencapai 100% dalam kesesuaian dengan kondisi optimal. Kategori Sangat Rendah (< 66.792 kg), Kurang Tinggi (66.792 - 80.896 kg), dan Cukup Tinggi (80.896 - 93.095 kg) masing-masing memiliki nilai validasi 100%, yang mengindikasikan bahwa ikan dalam rentang berat ini sepenuhnya ditemukan dalam kondisi oseanografis yang ideal. Kategori Tinggi (93.095 - 117.216 kg) sedikit lebih rendah dengan nilai validasi 92,982%, namun masih menunjukkan hasil yang sangat baik, sementara kategori Sangat Tinggi (> 117.216 kg) kembali mencapai 100%, menunjukkan bahwa ikan dengan berat sangat tinggi juga sepenuhnya ditemukan dalam kondisi optimal. Secara keseluruhan, hasil validasi ini menunjukkan bahwa ikan tuna mata besar pada bulan Januari sangat sering ditemukan dalam kondisi oseanografis yang mendukung, dengan sedikit penurunan pada kategori berat yang lebih tinggi.

Hasil validasi penangkapan ikan tuna mata besar pada bulan Maret berdasarkan kategori berat ikan dan nilai optimal. Pada bulan Januari untuk kategori Sangat Rendah (< 66.792 kg), nilai validasi mencapai 96,970%, yang

ia ikan dengan berat ini sebagian besar ditemukan dalam s yang optimal, meskipun sedikit lebih rendah dibandingkan gori Kurang Tinggi (66.792 - 80.896 kg) memiliki nilai validasi a sangat baik, namun sedikit menurun dibandingkan dengan



kategori Sangat Rendah. Kategori Cukup Tinggi (80.896 - 93.095 kg) menunjukkan nilai validasi 97,297%, yang merupakan nilai tertinggi dalam tabel ini, menandakan bahwa ikan dalam rentang berat ini lebih sering ditemukan dalam kondisi oseanografis yang optimal. Kategori Tinggi (93.095 - 117.216 kg) memiliki nilai validasi 91,228%, yang meskipun lebih rendah, masih menunjukkan hasil yang baik dan menunjukkan bahwa ikan dalam rentang berat ini cukup sering ditemukan dalam kondisi oseanografis yang optimal. Terakhir, kategori Sangat Tinggi (> 117.216 kg) memiliki nilai validasi yang jauh lebih rendah, yaitu 60,000%, yang mengindikasikan bahwa ikan dengan berat sangat tinggi ini kurang sering ditemukan dalam kondisi oseanografis yang optimal pada bulan Maret.

Adapun validasi penangkapan ikan tuna mata besar pada bulan Mei menunjukkan hasil yang sangat baik untuk sebagian besar kategori berat ikan. Untuk kategori Sangat Rendah (< 66.792 kg), nilai validasi mencapai 100%, yang mengindikasikan bahwa ikan dalam kategori ini sepenuhnya ditemukan dalam kondisi oseanografis yang optimal. Kategori Kurang Tinggi (66.792 - 80.896 kg) memiliki nilai validasi 81,250%, yang sedikit lebih rendah, menunjukkan bahwa ikan dalam rentang berat ini masih ditemukan dalam kondisi oseanografis optimal, meskipun tidak sebaik kategori yang lebih kecil. Kategori Cukup Tinggi (80.896 - 93.095 kg) memiliki nilai validasi 100%, yang menunjukkan bahwa ikan dengan berat ini sepenuhnya sesuai dengan kondisi oseanografis optimal. Kategori Tinggi (93.095 - 117.216 kg) memiliki nilai validasi 87,500%, yang sedikit lebih rendah, mengindikasikan bahwa ikan dalam rentang berat ini cukup sering ditemukan dalam kondisi oseanografis yang mendukung, meskipun tidak seoptimal kategori lainnya. Terakhir, kategori Sangat Tinggi (> 117.216 kg) kembali memiliki nilai validasi 100%, yang menunjukkan bahwa ikan dengan berat sangat tinggi juga ditemukan sepenuhnya dalam kondisi oseanografis optimal pada bulan Mei.

Secara keseluruhan, hasil validasi pada ikan tuna mata besar menunjukkan bahwa ikan dengan berat lebih kecil lebih sering ditemukan dalam kondisi oseanografis yang optimal, sementara ikan yang lebih berat cenderung lebih jarang berada dalam rentang kondisi oseanografis yang mendukung sebagaimana pada ikan cakalang dan madidihang.

5.5 Kesimpulan

Berdasarkan pembahasan di atas, dapat disimpulkan sebagai berikut:

1. Metode Multifactor Classification menilai ekosistem berdasarkan kombinasi faktor utama seperti Chlorophyll-a (Chlo-a) dan Sea Surface Temperature (SST), dengan prinsip sinergis, pembatasan, dan interaksi kompleks. Meskipun efektif dalam evaluasi ekosistem dan perikanan, metode ini memiliki keterbatasan karena tidak mempertimbangkan faktor lingkungan lain yang turut memengaruhi produktivitas ekosistem.

2. Model yang dibuat secara umum mampu menangkap kondisi aktual tangkapan ikan tuna mata besar mengenali lonjakan hasil tangkapan pada bulan Juli hingga September. Model ini memiliki kelemahan yaitu mengalami masking effect, namun dapat dijelaskan oleh model MaxEnt dimana menutupi pola spesifik saat upwelling. Upwelling di Laut Jawa (10°S-14°S) terjadi selama musim angin tenggara (Juli–September), yang meningkatkan Chlo-a dan menurunkan SST, menciptakan kondisi produktif



bagi ikan pelagis. Intensitas upwelling dipengaruhi oleh monsun dan variabilitas iklim global seperti ENSO dan marine heatwaves. Untuk meningkatkan akurasi model, perlu diterapkan pendekatan temporal granularity dengan analisis berbasis data bulanan agar pola spesifik lebih terbaca.

3. Strategi penangkapan ikan pelagis di WPP 714 harus adaptif terhadap fluktuasi musiman yang memengaruhi distribusi ikan seperti cakalang, madidihang, dan tuna mata besar. Periode Januari–Mei umumnya merupakan waktu optimal untuk penangkapan, sementara Juni–Agustus pada model menunjukkan penurunan kualitas perairan untuk penangkapan ikan (namun telah terkoreksi berdasarkan data logbook dan model MaxEnt). Adapaun September–Oktober kondisi perairan menunjukkan kategori yang relevan juga untuk penangkapan. Adapun Pada November–Desember, terjadi penurunan kualitas perairan, sehingga strategi tangkapan harus disesuaikan. Peta klaster distribusi ikan dapat menjadi petunjuk untuk menjelaskan pola migrasi ikan, di mana faktor suhu air, kedalaman laut, dan arus berpengaruh, sehingga teknologi pemantauan GIS dan satelit sangat penting untuk mendukung pengelolaan yang berkelanjutan. Kolaborasi dengan nelayan, edukasi praktik perikanan ramah lingkungan, serta regulasi yang ketat diperlukan guna menjaga keseimbangan ekosistem dan keberlanjutan industri perikanan.
4. Hasil validasi model secara umum untuk semua jenis ikan menunjukkan akurasi yang sangat tinggi (60 – 100%), di mana berat ikan yang lebih rendah lebih banyak ditemukan di daerah dengan kondisi oseanografis optimum dibandingkan yang lebih berat.



BAB VI

PEMBAHASAN UMUM

6.1 Keterkaitan upwelling, Chlo-a, dan SST dalam dinamika ekosistem laut WPP 714

Konsentrasi klorofil-a (Chlo-a) dan suhu permukaan laut (SST) merupakan dua parameter utama yang saling terkait dalam mengindikasikan produktivitas perairan di WPP 714, khususnya dalam konteks fenomena upwelling. Upwelling, yang terjadi di Laut Banda dan Teluk Tolo selama Juli hingga September, menyebabkan kenaikan nutrisi dari dasar laut ke permukaan, yang meningkatkan pertumbuhan fitoplankton dan memperkaya konsentrasi Chlo-a. Sebaliknya, peningkatan massa air dingin dari kedalaman laut menyebabkan penurunan SST secara signifikan di wilayah tersebut (Fadli et al., 2020).

Fenomena ini secara langsung berdampak pada rantai makanan laut. Peningkatan produktivitas primer akibat upwelling memperkaya zooplankton, yang menjadi sumber makanan bagi ikan kecil seperti sarden dan teri, yang kemudian mendukung spesies predator besar seperti tuna dan cakalang (Purwanto et al., 2024). Secara spasial, distribusi Chlo-a dan SST menunjukkan pola yang dinamis sepanjang tahun. Pada bulan Januari-Maret, konsentrasi Chlo-a tinggi di barat laut, sementara wilayah timur menunjukkan pola peningkatan selama Juli-September, seiring dengan pengaruh upwelling. SST yang lebih rendah di musim kemarau memperkuat bukti bahwa wilayah ini mengalami dinamika oseanografi yang dipengaruhi oleh perubahan angin musiman dan arus laut (Faristyawan et al., 2020).

Namun, selain faktor alamiah, aktivitas manusia juga memengaruhi Chlo-a dan SST. Limbah industri, pertanian, dan pemukiman meningkatkan kadar nutrisi berlebih di perairan, yang dapat memicu blooming alga, menyebabkan ketidakseimbangan ekosistem (Fauzi et al., 2021). Selain itu, perubahan iklim global dan fenomena ENSO (El Niño-Southern Oscillation) dapat mengubah pola upwelling, sehingga mempengaruhi fluktuasi stok ikan dan produktivitas perairan (Ma'mun et al., 2022). La Niña, misalnya, dapat melemahkan upwelling dan menyebabkan penurunan produksi fitoplankton, yang berdampak negatif pada populasi ikan predator (Wouthuyzen et al., 2018).

Dari analisis ini, yang paling menarik adalah bagaimana upwelling di WPP 714 menjadi faktor penentu utama keseimbangan ekosistem laut, tetapi juga sangat rentan terhadap perubahan lingkungan dan aktivitas manusia. Pola Chlo-a dan SST tidak hanya mencerminkan dinamika oseanografi alami, tetapi juga dapat menjadi indikator penting bagi pengelolaan perikanan berkelanjutan. Pemantauan berbasis satelit, model prediksi oseanografi, dan kebijakan konservasi berbasis sains penting dalam mitigasi dampak perubahan iklim dan terhadap produktivitas perairan (Zainuddin et al., 2023).

Manajemen perikanan di WPP 714 sangat bergantung pada pemahaman tentang proses alami dan intervensi manusia. Jika upwelling



terganggu oleh perubahan iklim atau polusi, dampaknya bisa meluas dari populasi plankton hingga rantai makanan laut secara keseluruhan. Oleh karena itu, strategi pengelolaan berbasis pemantauan jangka panjang dan mitigasi dampak antropogenik menjadi kunci dalam menjaga kelangsungan ekosistem laut dan ekonomi berbasis perikanan di wilayah ini.

6.2 Dinamika pengelolaan perikanan berkelanjutan di WPP 714: tantangan dan strategi adaptasi

Pengelolaan perikanan di Wilayah Pengelolaan Perikanan (WPP) 714, yang mencakup Laut Banda dan sekitarnya, menghadapi tantangan kompleks dalam menjaga keberlanjutan stok ikan pelagis besar seperti cakalang, madidihiang, dan tuna mata besar. Kebijakan perikanan seperti Peraturan Menteri Kelautan dan Perikanan Nomor 26/PERMEN-KP/2020 telah diterapkan untuk mengatur aktivitas penangkapan ikan, namun implementasinya masih menghadapi kendala signifikan. Teknologi pemantauan kapal seperti Vessel Monitoring System (VMS) dan Automatic Identification System (AIS) diusulkan sebagai solusi untuk meningkatkan efektivitas regulasi, mengurangi pelanggaran, dan menyediakan data spasial yang lebih akurat mengenai aktivitas penangkapan ikan (Pangerang & Nur, 2024).

Dari segi peralatan tangkap, WPP 714 menunjukkan diversifikasi alat tangkap yang mencerminkan upaya adaptasi nelayan terhadap kondisi lingkungan dan spesies target. Purse seine efektif dalam menangkap ikan pelagis dalam jumlah besar, sementara rawai digunakan untuk penangkapan selektif tuna berkualitas tinggi. Di sisi lain, alat tradisional seperti huhate dan pancing ulur masih memiliki peran penting dalam perikanan skala kecil karena selektivitasnya yang lebih baik dalam mengurangi tangkapan sampingan dan dampak negatif terhadap ekosistem (Rumpa et al., 2024). Namun, alat tangkap dengan tingkat selektivitas rendah seperti jaring insang oseanik dan pukot cincin dua kapal masih menimbulkan ancaman terhadap keberlanjutan perikanan karena dapat menangkap spesies non-target, termasuk yang dilindungi.

Analisis sebaran penangkapan ikan berdasarkan data logbook menunjukkan bahwa cakalang lebih banyak ditangkap di bagian utara dan barat laut WPP 714, dengan puncak aktivitas pada awal dan akhir tahun. Madidihiang, yang masuk dalam kategori overfishing, mengalami eksploitasi berlebih dengan rasio kematian akibat penangkapan yang tinggi. Distribusinya lebih terkonsentrasi di barat laut dan bagian tengah perairan, dengan pola migrasi yang mengikuti perubahan lingkungan oseanografi. Sementara itu, tuna mata besar, yang lebih banyak ditemukan di kedalaman 155–222 meter, lebih terdistribusi di bagian tengah dan selatan WPP 714, dengan variasi musiman yang dipengaruhi oleh upwelling dan kondisi suhu laut (Munier & Mamka, 2024).

Dalam evaluasi CPUE, madidihiang menunjukkan efisiensi penangkapan tertinggi dibandingkan cakalang dan tuna mata besar, yang menunjukkan tekanan terhadap stok atau efektivitas metode penangkapan yang digunakan. SPSS digunakan untuk menganalisis faktor teknis seperti ukuran alat tangkap, dan durasi melaut (*hari_laut*). Hasil menunjukkan bahwa alat tangkap selektif seperti Hand Line Tuna memiliki dampak positif



terhadap hasil tangkapan, sementara alat yang tidak selektif seperti jaring insang oseanik berkontribusi terhadap penurunan efisiensi tangkapan dan degradasi ekosistem (Pangerang & Nur, 2024). Model juga mengungkapkan bahwa durasi melaut yang lebih lama meningkatkan hasil tangkapan hingga titik tertentu sebelum mulai menurun akibat biaya operasional yang meningkat dan berkurangnya efektivitas pencarian ikan.

Pemodelan lebih lanjut menggunakan metode Random Forest dan BRT mengidentifikasi bahwa variabel utama yang mempengaruhi CPUE berbeda antar spesies. Untuk cakalang, durasi melaut menjadi faktor dominan, sedangkan untuk madidihang dan tuna mata besar, alat tangkap menjadi variabel yang paling menentukan hasil tangkapan. Model BRT menunjukkan bahwa optimalisasi alat tangkap dapat meningkatkan prediksi CPUE hingga 20% dibandingkan metode konvensional, yang menegaskan pentingnya pemilihan alat tangkap yang lebih ramah lingkungan dan efisien (Munier & Mamka, 2024).

Dalam konteks keberlanjutan, pendekatan berbasis ekosistem perlu diterapkan untuk mengatur penggunaan alat tangkap yang lebih selektif dan mengurangi tekanan eksploitasi pada stok ikan yang rentan. Pengelolaan berbasis data, termasuk pemantauan perubahan lingkungan oseanografi seperti suhu permukaan laut (SST) dan fenomena upwelling, juga penting untuk memahami pola migrasi dan distribusi stok ikan secara lebih akurat. Regulasi yang lebih ketat, seperti pembatasan ukuran tangkapan minimum dan perlindungan habitat kritis, dapat membantu memastikan bahwa perikanan di WPP 714 tetap berkelanjutan dalam jangka panjang.

6.3 Sintesis dan perspektif dalam pemodelan area penangkapan ikan berbasis oseanografi

Penelitian tentang pemodelan area penangkapan ikan di WPP 714 banyak memanfaatkan parameter oseanografi, seperti konsentrasi Chlo-a dan SST, dalam menentukan habitat potensial bagi ikan pelagis seperti cakalang, madidihang, dan tuna mata besar. Berbagai metode pemodelan telah digunakan, termasuk GAM, ECDF, RF, BRT, k-means clustering, dan MaxEnt, untuk memahami hubungan antara faktor lingkungan dan CPUE (Haruna et al., 2020; Syahailatua & Wouthuyzen, 2023).

Model ECDF berperan penting dalam mengelompokkan area dengan nilai D tinggi, yang menunjukkan kondisi optimal untuk aktivitas feeding ikan pelagis. Keunggulan ECDF terletak pada kemampuannya dalam mengidentifikasi pola spasial tanpa asumsi distribusi data, menjadikannya lebih fleksibel dibandingkan model statistik lainnya (Zainuddin et al., 2024). Sementara itu, pemodelan GAM mengungkapkan bahwa SST memiliki hubungan lebih signifikan terhadap CPUE dibandingkan Chlo-a, terutama pada ikan madidihang dan tuna mata besar, yang menunjukkan respons kuat terhadap perubahan suhu perairan (Mohamad, 2022).

Metode machine learning seperti Random Forest dan BRT menunjukkan variasi prediksi CPUE. Model RF cenderung memberikan prediksi untuk cakalang, dengan Chlo-a sebagai variabel dominan, lebih akurat dalam memprediksi CPUE madidihang dan tuna mata besar sebagai faktor utama (Purwanto et al., 2024). MaxEnt



digunakan untuk memprediksi distribusi spasial ikan berdasarkan variabel lingkungan dan menunjukkan bahwa ikan pelagis lebih banyak ditemukan di daerah dengan kombinasi SST optimal ($29\text{--}31^{\circ}\text{C}$) dan Chlo-a dalam kisaran tertentu ($0.15\text{--}0.39\text{ mg/m}^3$) (Fitriana, 2024).

Analisis k-means clustering dan elbow method membantu menentukan jumlah kluster optimal berdasarkan variabilitas parameter oseanografi. Hasil menunjukkan bahwa kluster dengan CPUE tinggi berkorelasi erat dengan kondisi lingkungan yang lebih stabil, terutama dalam rentang suhu dan klorofil tertentu (Ma'mun et al., 2022). Variabilitas spasial dan temporal dari faktor oseanografi mempengaruhi pola migrasi ikan, yang membuat pemahaman terhadap dinamika lingkungan laut menjadi krusial dalam perencanaan operasional perikanan.

Perspektif menarik yang muncul dari sintesis ini adalah bagaimana kombinasi metode pemodelan statistik dan machine learning dapat meningkatkan efisiensi pengelolaan perikanan berbasis data. Pendekatan multifaktor seperti ECDF dan MaxEnt tidak hanya membantu dalam mengidentifikasi zona potensial penangkapan ikan, tetapi juga dapat digunakan sebagai alat prediksi dalam strategi mitigasi perubahan iklim dan eksploitasi berlebihan di perairan Indonesia (Pontoh et al., 2024). Dengan pemanfaatan data satelit dan model prediktif yang lebih kompleks, pengelolaan perikanan dapat beralih dari pendekatan berbasis pengalaman menuju pengelolaan adaptif yang lebih berbasis bukti.

6.4 Optimalisasi penangkapan ikan pelagis di WPP 714 melalui pendekatan spasial-temporal berbasis data

Penelitian ini mengintegrasikan berbagai metode pemodelan untuk mengidentifikasi potensi area penangkapan ikan pelagis di Wilayah Pengelolaan Perikanan (WPP) 714 dengan mempertimbangkan faktor oseanografi utama, yaitu suhu permukaan laut (SST) dan konsentrasi klorofil-a (Chlo-a). Pendekatan MFC digunakan sebagai metode utama untuk mengklasifikasikan kondisi perairan berdasarkan interaksi sinergis antar faktor lingkungan yang memengaruhi hasil tangkapan ikan. Hasil penelitian menunjukkan bahwa kombinasi optimal antara Chlo-a ($0.3\text{--}1.0\text{ mg/m}^3$) dan SST dalam kisaran $27\text{--}31^{\circ}\text{C}$ dapat meningkatkan produktivitas perikanan, sementara ketidakseimbangan pada salah satu faktor dapat menurunkan hasil tangkapan secara signifikan (Adnan et al., 2022; Doydee et al., 2010; Sartimbul et al., 2010). Model MaxEnt digunakan untuk memprediksi distribusi spasial ikan berdasarkan variabilitas lingkungan, namun mengalami keterbatasan dalam menangkap lonjakan hasil tangkapan selama periode upwelling pada bulan Juli hingga September, akibat masking effect, yaitu kondisi di mana pola dominan dari bulan-bulan lainnya menutupi pola spesifik yang muncul selama periode tersebut (Wei et al., 2021). Masking effect ini menyebabkan model gagal mengenali hubungan unik antara SST, Chlo-a, dan CPUE, terutama selama fenomena upwelling yang meningkatkan produktivitas fitoplankton dan mendukung kelimpahan ikan pelagis di Laut Banda (Rachmayani et al., 2019).



Untuk mengatasi keterbatasan tersebut, penelitian ini menggunakan final map, yang menggabungkan pemodelan spasial dengan data tangkapan guna mengidentifikasi pola distribusi ikan sepanjang tahun. Hingga Maret, ikan tuna mata besar lebih banyak ditemukan

di bagian barat, madidihang mendominasi wilayah tengah, dan cakalang lebih banyak berada di timur. Pada April hingga Juni, terjadi pergeseran posisi, di mana cakalang mulai mendominasi bagian barat daya, sementara madidihang lebih banyak terkonsentrasi di wilayah tengah. Juli hingga Oktober merupakan periode di mana cakalang semakin mendominasi wilayah timur, madidihang tetap di tengah, dan tuna mata besar mulai menyebar ke bagian barat. Pada akhir tahun (November hingga Desember), madidihang lebih dominan di bagian barat laut, tuna mata besar kembali ke barat daya, dan cakalang tetap berada di bagian tengah (Riadi et al., 2024). Hasil pemetaan ini menunjukkan bahwa pola migrasi ikan dipengaruhi oleh variasi musiman SST dan Chl-a, serta faktor oseanografi lain seperti pola arus laut dan kondisi monsun. Upwelling yang terjadi selama musim angin tenggara mempercepat pergerakan massa air kaya nutrisi dari lapisan bawah ke permukaan, meningkatkan produktivitas perikanan pada bulan Juli hingga September. Namun, intensitas upwelling ini sangat dipengaruhi oleh variabilitas iklim global seperti ENSO (El Niño-Southern Oscillation), di mana pada tahun La Niña, intensitasnya cenderung lebih kuat, sedangkan pada tahun El Niño, intensitasnya melemah, yang berdampak pada distribusi ikan pelagis di wilayah tersebut (Rachman et al., 2020).

Pemetaan spasio-temporal ini memberikan wawasan penting bagi pengelolaan perikanan berbasis data. Dengan memahami pola distribusi ikan sepanjang tahun, nelayan dapat mengoptimalkan lokasi penangkapan dan menyesuaikan strategi berdasarkan kondisi oseanografi yang berubah-ubah. Sebagai contoh, pada bulan Januari hingga Februari, kondisi perairan menunjukkan kategori "Sangat Baik" untuk penangkapan, sehingga nelayan dapat meningkatkan intensitas tangkapan di wilayah barat dan tengah. Sebaliknya, pada Maret hingga Mei, terjadi penurunan kualitas habitat yang mengharuskan pengurangan kuota tangkapan guna mencegah eksploitasi berlebihan. Pada periode Juni hingga Agustus, kondisi perairan semakin memburuk dengan dominasi kategori "Kurang Baik", yang memerlukan penerapan strategi rotasi wilayah tangkapan serta pembatasan aktivitas perikanan guna mendukung pemulihan ekosistem. Pada akhir tahun (November hingga Desember), wilayah perairan kembali mengalami penurunan kualitas, sehingga strategi penangkapan perlu difokuskan pada wilayah dengan kondisi yang lebih baik, terutama di bagian barat (Hermanto et al., 2019; Nurholis et al., 2020).

Selain memberikan manfaat bagi industri perikanan, pemodelan ini juga memberikan wawasan ekologis tentang pola migrasi dan distribusi ikan pelagis besar seperti cakalang, madidihang, dan tuna mata besar. Studi terbaru menunjukkan bahwa migrasi ikan di Samudra Pasifik dan Hindia sangat bergantung pada perubahan suhu permukaan laut dan faktor oseanografi lainnya (Artetxe-Arrate et al., 2021). Distribusi spesies seperti madidihang dan tuna mata besar di Zona Ekonomi Eksklusif Tonga juga dipengaruhi oleh suhu laut dan kedalaman dasar laut, sementara cakalang lebih terkait dengan perubahan musim

(Vaiholo et al., 2023). Lebih lanjut, penelitian mengenai pola Phoenix Islands Protected Area menunjukkan bahwa ketiga yang biak secara aktif di kawasan konservasi laut, meskipun ungkan seperti peristiwa El Niño (Hernández et al., 2019).



Implikasi dari studi ini sangat penting bagi manajemen perikanan global, karena pemahaman tentang pola migrasi dan pemijahan dapat membantu menentukan strategi konservasi dan optimalisasi perikanan yang lebih berkelanjutan.

Secara keseluruhan, penelitian ini menegaskan bahwa strategi penangkapan ikan pelagis di WPP 714 harus bersifat adaptif dan berkelanjutan, dengan mempertimbangkan dinamika spasial-temporal yang kompleks. Teknologi pemantauan berbasis satelit dan GIS menjadi sangat penting dalam mendukung pengambilan keputusan berbasis data real-time. Kolaborasi antara nelayan, pemerintah, dan lembaga penelitian dalam pengelolaan sumber daya perikanan juga diperlukan untuk memastikan keseimbangan ekosistem laut tetap terjaga. Selain itu, diversifikasi spesies tangkapan, peningkatan pengawasan terhadap praktik penangkapan ilegal, serta edukasi tentang praktik perikanan yang ramah lingkungan akan membantu menjaga keberlanjutan industri perikanan di Indonesia. Dengan pemanfaatan pemodelan berbasis data ini, strategi perikanan dapat dioptimalkan untuk meningkatkan hasil tangkapan tanpa mengorbankan keseimbangan ekosistem laut.

6.6 Konfigurasi model machine learning untuk pemetaan area penangkapan ikan


Machine learning memiliki beragam model yang dapat digunakan untuk melakukan prediksi dengan tingkat akurasi dan goodness of fit yang bervariasi. Oleh karena itu, dalam pemetaan area penangkapan ikan, perbandingan akurasi dan goodness of fit dari berbagai model perlu dilakukan guna menentukan metode yang paling optimal. Pada penelitian ini, digunakan beberapa model, yaitu GAM, ECDF, RF, BRT, k-means clustering, dan MaxEnt. Model-model seperti GAM, RF, BRT, k-means clustering, dan MaxEnt merupakan bagian dari algoritma machine learning yang digunakan untuk mengidentifikasi pola kompleks dalam data lingkungan perairan, sedangkan ECDF lebih mencerminkan pendekatan statistik non-parametrik yang dapat menangkap distribusi empiris data tanpa memerlukan asumsi distribusi teoretis tertentu (Hastie et al., 2017; James et al., 2021).

Dalam proses pemetaan, ECDF dan metode elbow digunakan untuk menentukan nilai optimal parameter yang kemudian difungsikan sebagai batas kategori dalam merumuskan kualitas perairan berdasarkan nilai-nilai lingkungan yang dihasilkan. ECDF memberikan gambaran distribusi data secara empiris, sedangkan elbow method digunakan dalam k-means clustering untuk menentukan jumlah kluster optimal berdasarkan variabilitas parameter lingkungan seperti SST dan konsentrasi Chlo-a (Xu & Tian, 2015). Selanjutnya, sintesis nilai parameter lingkungan dikoreksi menggunakan pendekatan statistik seperti mean dan standar deviasi guna memastikan representasi data yang lebih akurat (Bishop, 2006). Setelah itu, kategori area perairan yang telah diklasifikasikan dengan pendekatan statistik ini disintesis lebih lanjut menggunakan metode MFC, yang memungkinkan evaluasi kondisi ekosistem berdasarkan kombinasi berbagai faktor (et al., 2017).



ini memastikan bahwa model machine learning yang digunakan tidak hanya bergantung pada satu metode, tetapi menggabungkan beberapa model, sehingga hasil pemetaan area penangkapan

ikan menjadi lebih akurat dan dapat digunakan untuk pengelolaan perikanan yang lebih efektif dan berkelanjutan. Dalam konteks keberlanjutan, pemanfaatan teknologi machine learning dapat meningkatkan efisiensi pemetaan area penangkapan ikan, yang pada akhirnya akan berdampak pada optimasi sumber daya dan mitigasi eksploitasi berlebihan (Schickele et al., 2020). Proses konfigurasi model ditunjukkan pada Gambar 6.1 berikut.



Gambar 6.1 Konfigurasi model machine learning untuk pemetaan

Namun, penelitian ini masih memiliki kelemahan, salah satunya adalah belum mengintegrasikan hasil pemodelan MaxEnt ke dalam sintesis nilai baru yang dihasilkan. Padahal, model MaxEnt memiliki kemampuan yang cukup baik dalam menangkap variabilitas data, khususnya dalam menganalisis pola spasio-temporal berdasarkan kondisi lingkungan bulanan. Keunggulan MaxEnt terletak pada kemampuannya dalam menangani masking effect, yaitu ketika pola spesifik dari suatu variabel tertutupi oleh variabel lainnya dalam analisis data tahunan (Wei et al., 2021). Dalam penelitian ini, MaxEnt belum diintegrasikan dalam sintesis utama karena terdapat perbedaan metrik dengan model machine learning lainnya, serta penelitian ini lebih mengutamakan analisis data tahunan dibandingkan bulanan. Dengan demikian, MaxEnt lebih banyak digunakan sebagai pembanding membaca pola distribusi berdasarkan asumsi temporal bulanan, terutama dalam klasifikasi ekosistem perairan.

Di lanjut model MaxEnt dalam analisis tahunan dapat menjadi untuk meningkatkan presisi pemetaan, terutama dalam



mendukung strategi pengelolaan perikanan berbasis data yang lebih adaptif dan akurat (Warton et al., 2022). Dengan meningkatkan integrasi antara model machine learning dan metode statistik, pendekatan ini dapat menjadi landasan bagi pengelolaan perikanan yang lebih efektif, efisien, dan berbasis ekosistem. Selain itu, penggunaan MaxEnt yang lebih luas, dikombinasikan dengan model lainnya seperti RF, BRT, dan GAM, dapat memberikan hasil yang lebih komprehensif dalam menentukan area optimal untuk penangkapan ikan yang berkelanjutan (Elith et al., 2011).

6.7 Hasil validasi model

Validasi model dilakukan untuk mengevaluasi kinerja prediksi distribusi ikan berdasarkan beratnya terhadap kondisi oseanografis optimal, menggunakan data uji yang terpisah. Validasi dilakukan pada bulan Januari, Maret, dan Mei untuk semua jenis ikan. Hasil validasi ikan cakalang menunjukkan bahwa ikan dengan berat lebih kecil (kategori Sangat Rendah) lebih sering ditemukan pada kondisi oseanografis optimal, dengan nilai validasi tertinggi di Januari dan Maret mencapai hingga 100%. Sedangkan berat ikan yang lebih besar memiliki kecenderungan nilai validasi lebih rendah, mengindikasikan bahwa ikan lebih besar kurang optimal terkait kondisi oseanografis. Tren serupa juga terjadi pada bulan Mei, meskipun nilai validasinya sedikit lebih rendah dibandingkan Januari dan Maret.

Pada ikan madidihiang, hasil validasi menunjukkan pola yang hampir sama. Ikan dengan berat lebih kecil memiliki nilai validasi yang tinggi, menunjukkan keterkaitannya dengan kondisi lingkungan yang lebih mendukung. Pada bulan Januari dan Maret, nilai validasi untuk kategori berat rendah tetap mendekati atau di atas 94%, sedangkan pada kategori berat yang lebih besar terjadi penurunan nilai validasi. Kondisi serupa terlihat pada bulan Mei, dengan penurunan nilai validasi yang lebih nyata untuk kategori berat yang lebih tinggi. Penelitian sebelumnya mendukung hasil ini, dimana pertumbuhan ikan besar sering tidak optimal di lingkungan dengan kondisi oseanografis yang kurang baik, sebagaimana ditunjukkan oleh studi di Brasil, Mumbai, dan Vietnam.

Validasi pada ikan tuna mata besar memperlihatkan kecenderungan yang sedikit berbeda. Pada bulan Januari, hampir seluruh kategori berat menunjukkan nilai validasi 100%, kecuali kategori Tinggi. Namun, pada bulan Maret, terdapat penurunan signifikan terutama pada kategori berat sangat tinggi (>117,216 kg) dengan nilai validasi hanya 60%. Pada bulan Mei, ikan dengan berat sangat rendah dan sangat tinggi kembali menunjukkan nilai validasi 100%, sedangkan kategori berat menengah menunjukkan penurunan. Secara keseluruhan, baik ikan cakalang, madidihiang, maupun tuna mata besar menunjukkan pola bahwa ikan dengan berat lebih kecil lebih sering ditemukan dalam kondisi oseanografis yang optimal, sedangkan ikan yang lebih berat lebih jarang berada dalam kondisi lingkungan yang mendukung.



BAB VII

KESIMPULAN UMUM

6.1 Kesimpulan

Berdasarkan uraian pada masing-masing bab di atas, disimpulkan sebagai berikut:

1. Distribusi spasio-temporal Chlo-a menunjukkan pola musiman yang dinamis, dengan konsentrasi tinggi di barat laut pada Januari-Maret, pergeseran ke wilayah timur pada Juli-September, dan penurunan signifikan pada Oktober-Desember, sementara distribusi SST menunjukkan suhu dingin di barat laut selama Januari-Maret dan suhu dingin akibat upwelling selama Juli-September.
2. Pemodelan GAM, RF, dan BRT menunjukkan keunggulan berbeda dalam memprediksi hasil tangkapan ikan pelagis, dengan masing-masing model menyoroti variabel spesifik seperti durasi melaut, alat tangkap, dan jenis spesies. Rentang optimal tonase kapal dan hari melaut yang diperoleh melalui pendekatan machine learning dapat digunakan untuk strategi penangkapan yang efisien dan berkelanjutan. Namun, masih ditemukan pelanggaran regulasi larangan penangkapan madidiang di WPP 714 selama Oktober–Desember, sehingga diperlukan pengawasan lebih ketat dan penegakan kebijakan yang konsisten.
3. Model Generalized Additive Model (GAM) menunjukkan performa terbaik dalam memprediksi konsentrasi Chlorophyll-a dan suhu permukaan laut untuk ikan madidiang dan tuna mata besar, dibandingkan dengan model BRT dan RF. Pemetaan area penangkapan menggunakan metode ECDF, K-means, dan Elbow Method berhasil mengidentifikasi zona dengan kondisi lingkungan optimal berdasarkan rentang Chlo-a dan SST yang sesuai untuk masing-masing spesies. Hasil ini mendukung penggunaan model machine learning dan spasial sebagai dasar dalam perencanaan penangkapan yang lebih efisien dan berbasis kondisi oseanografi aktual.
4. Distribusi penangkapan ikan pelagis di WPP 714 sangat dipengaruhi oleh perubahan lingkungan laut sepanjang tahun. Waktu dan lokasi terbaik untuk penangkapan terjadi pada Januari hingga Mei, terutama di wilayah barat dan tengah. Fenomena upwelling yang terjadi pada pertengahan tahun meningkatkan kesuburan perairan, namun menyebabkan penyebaran ikan menjadi lebih luas dan tidak terkonsentrasi, sehingga strategi penangkapan an dengan rotasi wilayah untuk mengoptimalkan hasil a meningkatkan tekanan berlebih pada ekosistem. Kondisi September–Oktober, namun kembali menurun pada akhir



tahun. Validasi model menunjukkan akurasi tinggi, dengan ikan berukuran kecil lebih banyak ditemukan di wilayah dengan kondisi oseanografis yang optimal, menegaskan pentingnya pemetaan spasial dan strategi penangkapan adaptif.

6.2 Saran

Untuk meningkatkan optimasi pengelolaan perikanan di WPP 714, disarankan sebagai berikut:

1. Perlunya integrasi data spasio-temporal Chlo-a dan SST dalam sistem pemantauan perikanan berbasis satelit secara real-time, guna mendukung pengambilan keputusan yang cepat dan adaptif terhadap perubahan kondisi lingkungan laut, serta mengoptimalkan waktu dan lokasi penangkapan ikan secara berkelanjutan.
2. Diperlukan integrasi hasil pemodelan dengan sistem pemantauan berbasis teknologi seperti Vessel Monitoring System (VMS), Automatic Identification System (AIS), dan logbook digital, untuk mendukung pengawasan yang lebih akurat serta memastikan implementasi strategi penangkapan yang sesuai dengan rekomendasi model dan regulasi yang berlaku, khususnya dalam periode larangan penangkapan.
3. Pengelolaan perikanan di WPP 714 dapat mengadopsi pemodelan machine learning untuk mengidentifikasi zona penangkapan yang optimal berdasarkan kondisi lingkungan aktual. Hal ini dapat meningkatkan efisiensi dan keberlanjutan operasi penangkapan ikan, serta memungkinkan penyesuaian strategi berdasarkan perubahan kondisi oseanografi yang dinamis.
4. Pentingnya mempertimbangkan pengimplementasian strategi rotasi wilayah yang adaptif dan berbasis pemetaan spasial guna mengoptimalkan hasil tangkapan ikan pelagis di WPP 714. Hal ini penting untuk menyesuaikan dengan perubahan musiman dan fenomena upwelling yang memengaruhi distribusi ikan, serta untuk mencegah tekanan berlebih pada ekosistem dengan menjaga keberlanjutan perikanan.

