

TESIS

**DETEKSI PERKEMBANGAN UDANG VANAME PADA SISTEM
BIOFLOK MENGGUNAKAN DATA SONAR**

Detection Of Vannamei Shrimp Growth in Biofloc Systems Through Sonar Data

**DWI BAGUS FITRIYANTO
D082201011**



**PROGRAM STUDI MAGISTER TEKNIK INFORMATIKA
DEPERTEMEN TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

PENGAJUAN TESIS

DETEKSI PERKEMBANGAN UDANG VANAME PADA SISTEM BIOFLOK MENGGUNAKAN DATA SONAR

Tesis

Sebagai Salah Satu Syarat Untuk Mencapai Gelar Magister

Program Studi Teknik Informatika

Disusun dan diajukan oleh

DWI BAGUS FITRIYANTO

D082201011

Kepada

**FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN**

GOWA

2024

TESIS

DETEKSI PERKEMBANGAN UDANG VANAME PADA SISTEM BIOFLOK MENGGUNAKAN DATA SONAR

DWI BAGUS FITRIYANTO
D082201011

Telah dipertahankan di hadapan Panitia Ujian Magister pada tanggal 31 Januari 2025
dan dinyatakan telah memenuhi syarat kelulusan

pada
Program Studi S2 Teknik Informatika
Fakultas Teknik
Universitas Hasanuddin

Menyetujui,

Pembimbing Utama



Dr. Ir. Zahir Zainuddin, M.Sc.
NIP. 19640427 198910 1 002

Pembimbing Pendamping



Prof. Dr. Ir. H. Andani Achmad, M.T.
NIP. 19601231 198703 1 022

Dekan Fakultas Teknik
Universitas Hasanuddin



Dr. Eng. Ir. Muhammad Isran Ramli, M.T.IPM., ASEAN.Eng.
NIP. 19730926 200012 1 002

Ketua Program Studi
S2 Teknik Informatika



Dr. Ir. Zahir Zainuddin, M.Sc.
NIP. 19640427 198910 1 002



Sertifikasi
Elektronik

• Dokumen ini telah ditandatangani secara elektronik menggunakan sertifikat elektronik yang diterbitkan BSrE
• UU ITE No 11 Tahun 2008 Pasal 5 Ayat 1
"Informasi Elektronik dan/atau Dokumen Elektronik dan/atau hasil cetaknya merupakan alat bukti hukum yang

PERNYATAAN KEASLIAN TESIS DAN PELIMPAHAN HAK CIPTA

Saya yang bertanda tangan dibawah ini:

Nama : Dwi Bagus Fitriyanto

NIM : D082201011

Program Studi : Teknik Informatika

Dengan ini menyatakan bahwa tesis yang berjudul “Deteksi Perkembangan Udang Vaname pada Sistem Bioflok Menggunakan Data Sonar” adalah benar karya Saya dengan arahan dari komisi pembimbing Dr. Ir. Zahir Zainuddin, M.Sc. sebagai Pembimbing Utama dan Prof. Dr. Ir. H. Andani Achmad, M.T. sebagai Pembimbing Pendamping. Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apapun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya Saya yang telah diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari isi tesis ini telah didaftarkan pada *International Journal of Intelligent Engineering and Systems* sebagai artikel dengan judul “*Sonar Imaging for Real-Time Monitoring of Litopenaeus Vannamei Shrimp Growth in Biofloc System Mini Pond Using Faster R-CNN Algorithm*”. Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan tesis ini adalah karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut berdasarkan aturan yang berlaku.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya berupa tesis ini kepada Universitas Hasanuddin.

Gowa, 24 Januari 2025



Dwi Bagus Fitriyanto

NIM. D082201011

KATA PENGANTAR

Alhamdulillah rabbil'alamin, segala puji bagi Allah Subhanahu Wa Ta'ala Yang Maha Sempurna, yang telah memberikan rahmat, hidayah dan pertolongan-Nya sehingga penulis dapat menyelesaikan tesis dengan judul “Deteksi Perkembangan Udang Vaname Pada Sistem Bioflok Menggunakan Data Sonar”. Shalawat dan salam kami ucapkan kepada Nabi Muhammad Shallahu ‘Alaihi Wasallam yang telah menyinari dunia ini dengan keindahan ilmu dan akhlak yang diajarkan kepada seluruh umatnya.

Tesis ini disusun untuk memenuhi persyaratan untuk memperoleh gelar Magister Komputer (M. Kom.) pada Program Pascasarjana Departemen Teknik Informatika Universitas Hasanuddin Makassar. Penyelesaian tesis ini tidak terlepas dari dukungan dan bantuan dari semua pihak, dengan penuh kerendahan hati penulis menyampaikan terima kasih setulus-tulusnya dan setinggi-tingginya kepada:

1. Ayahanda penulis Almarhum Syahidan Roief, ibunda Ghoniatu Rochmah, dan istri tercinta Novi Nurlaela yang telah memberikan dukungan materil, doa dan motivasi yang kuat kepada penulis, hingga penulis dapat menyelesaikan tesis ini.
2. Bapak Dr. Ir. Zahir Zainuddin, M.Sc. sebagai pembimbing pertama sekaligus sebagai Ketua Program Studi S2 Teknik Informatika dan Bapak Prof. Dr. Ir. H. Andani Achmad, M.T. selaku dosen pembimbing kedua yang telah meluangkan waktunya untuk membimbing, memberikan masukan, memotivasi tiada henti-hentinya hingga tahap penyelesaian tesis ini.
3. Bapak Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus.Sys., IPM, ASEAN. Eng., Bapak Prof. Dr. Eng. Muhammad Niswar, S.T., M.IT., dan Bapak Dr. Eng. Ir. Zulkifli Tahir, S.T., M.Sc. selaku penguji yang memberikan masukan dan saran yang membangun selama proses penelitian berlangsung.
4. Rekan-rekan di Balai Pengembangan Penjaminan Mutu Pendidikan Vokasi Bidang Kelautan Perikanan Teknologi Informasi dan Komunikasi merupakan Unit Pelaksana Teknis Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi yang menyediakan sarana dan prasarana dalam pengerjaan tesis ini.

5. Rekan-rekan Lab *Computer Based System* Teknik Informatika yang selalu saling mendukung dalam proses penyelesaian tesis ini.
6. Rekan-rekan mahasiswa S2 Teknik Informatika angkatan 2020-1 yang selalu memberikan dukungan dalam proses penyelesaian tesis ini.

Penulis menyadari bahwa dalam penyelesaian tesis ini masih belum sempurna dan selama proses penyelesaiannya masih menemui banyak kesulitan dan hambatan, sehingga penulis tetap mengharapkan saran dan kritik untuk pengembangan lebih lanjut, agar dapat memberikan manfaat yang banyak bagi semua pembaca.

Gowa, 29 Desember 2024

A handwritten signature in black ink, featuring a large, stylized loop at the top and several smaller, fluid strokes below it, ending in a small vertical mark.

Dwi Bagus Fitriyanto

DAFTAR ISI

	Halaman
HALAMAN SAMPUL.....	i
PENGAJUAN TESIS.....	ii
KATA PENGANTAR.....	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR.....	x
DAFTAR TABEL	xii
BAB I.....	1
1.1. Latar Belakang.....	1
1.2. Perumusan Masalah.....	3
1.3. Tujuan Penelitian.....	4
1.4. Manfaat Penelitian.....	4
1.5. Batasan Masalah.....	4
BAB II	5
2.1. Kajian Pustaka.....	5
2.1.1. Udang Vaname.....	5
2.1.2. Teknologi Bioflok	5
2.1.3. Sound Navigation and Ranging (SONAR)	7
2.1.3.1. Tradisional Echosounder	7
2.1.3.2. Side Scan Sonar (SSS).....	10
2.1.3.3. Down Scan SONAR	10
2.1.3.4. Dual frequency IDentfication SONar (DIDSON).....	11
2.1.4. Convolutional Neural Network (CNN)	11
2.1.4.1. Convolutional Layer	12
2.1.4.2. Stride.....	13
2.1.4.3. Padding	13
2.1.4.4. Pooling layer	14
2.1.4.5. Fully Connected layer	14

2.1.4.6.	Activation Function	15
2.1.4.7.	Softmax Function.....	15
2.1.5.	Region based Convolutional Neural Network (R-CNN)	16
2.1.6.	Faster Region based Convolutional Neural Network (Faster R-CNN).....	17
2.1.6.1.	Region Proposal Network (RPN).....	17
2.1.7.	You Only Look Once (YOLO)	20
2.1.8.	Depth Map.....	23
2.1.9.	<i>Google Colaboratory</i>	23
2.2.	Metode Penyelesaian Masalah	24
2.2.1.	State of The Art Penelitian	24
2.2.2.	Metode yang Diusulkan	37
2.2.3.	Tingkat Keaslian (Level Orosinalitas) Topik Penelitian yang Diusulkan.....	37
2.3.	Target Hasil Penelitian	41
2.4.	Kerangka Pikir	42
BAB III		43
4.1.	Jenis Penelitian	43
4.2.	Tahapan Penelitian	44
4.3.	Sumber Data	45
4.4.	Rancangan Sistem	46
4.5.	Pengujian Sistem	55
4.6.	Waktu dan Lokasi Penelitian.....	57
BAB IV		59
4.1.	CNN.....	59
4.2.	FASTER R-CNN.....	62
4.3.	YOLOv8.....	64
4.4.	Perbandingan Hasil.....	66
BAB V		67
5.1.	Kesimpulan.....	67
5.2.	Saran	68
DAFTAR PUSTAKA		69
LAMPIRAN		73

DAFTAR GAMBAR

Gambar 1. Kondisi air kolam tambak yang menggunakan pakan dengan sistem bioflok	3
Gambar 2. Udang Vaname.....	5
Gambar 3. Transmisi Frekuensi Sonar Singlebeam Echosounder.....	8
Gambar 4. Ilustrasi hasil scan singlebeam echosounder.....	8
Gambar 5. Transmisi Frekuensi dengan Teknologi CHIRP	9
Gambar 6. Ilustrasi hasil scan dengan teknologi CHIRP.....	9
Gambar 7. Proses Side Scan Sonar	10
Gambar 8. Perbedaan antara hasil Tradisional SONAR dan Down Scan SONAR.....	11
Gambar 9. Data Hasil citra sonar menggunakan teknologi DIDSON	11
Gambar 10. Arsitektur CNN	12
Gambar 11. Operasi Konvolusi.....	13
Gambar 12. Filter dengan nilai stride = 2	13
Gambar 13. Pemberian nilai padding = 1	14
Gambar 14. Perbedaan metode Max pooling dan Avg pooling.....	14
Gambar 15. Ilustrasi Fully Connected Layer.....	15
Gambar 16. Fungsi Aktivasi	15
Gambar 17. Fungsi Aktivasi Softmax.....	16
Gambar 18. Arsitektur R-CNN	16
Gambar 19. Arsitektur Fast R-CNN	17
Gambar 20. Region Proposal Network	18
Gambar 21. Arsitektur Faster R-CNN	18
Gambar 22. Arsitektur YOLOv8 (Ju & Cai, 2023)	22
Gambar 23. Antarmuka Google Colab pada browser.....	23
Gambar 24. Pilihan penggunaan Hardware Accelerator pada Google Colab Pro	24
Gambar 25. Kerangka Pikir	42
Gambar 26. Tahapan Pelaksanaan Penelitian	45
Gambar 27. Sudut Scan Transduser.....	46
Gambar 28. Bagan Rancangan Sistem.....	46

Gambar 29. Objek Target berdasarkan hasil singlebeam echosounder: (a) ilustrasi posisi transduser dan objek udang, (b) Citra singlebeam echosounder	47
Gambar 30. Pembacaan Data .RSD pada Aplikasi Garmin HomePort	48
Gambar 31. Visualisasi Citra singlebeam echosounder dalam satuan waktu	48
Gambar 32. Rancangan Proses	49
Gambar 33. Proses Cropping Citra Singlebeam Echosounder	50
Gambar 34. Proses Depth Map: (a) Citra asli singlebeam echosounder, (b) Citra setelah dilakukan proses depth map	52
Gambar 35. Dataset singlebeam echosounder dengan ukuran 600 x 600 piksel	53
Gambar 36. Proses Pelabelan data pada Label Studio	54
Gambar 37. Pelabelan data dalam 3 kelas	54
Gambar 38. Pilihan Format Export Data Hasil Pelabelan	55
Gambar 39. Blok Diagram Proses Faster RCNN deteksi udang	55
Gambar 40. Kategori Confusion Matrix	56
Gambar 41. Linimasa Penelitian	58
Gambar 42. Confusion Matrix dari hasil pelatihan menggunakan algoritma CNN	60
Gambar 43. Hasil perhitungan precision, recall, dan f1-score	62
Gambar 44. Sampling hasil deteksi menggunakan model hasil training Faster R-CNN	63
Gambar 45. Confusion Matrix dari hasil pelatihan menggunakan algoritma YOLOv8	65
Gambar 46. Sampling hasil deteksi menggunakan model hasil training YOLOv8	65

DAFTAR TABEL

Tabel 1. State of The Art.....	24
Tabel 2. Tabel Referensi dan Metode yang diusulkan.....	37
Tabel 3. Level Orisinalitas Proposal Magister Teknik Informatika UNHAS.....	40

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kebutuhan akan pangan, termasuk udang terus meningkat, seiring pertumbuhan populasi di perkotaan, sehingga peluang budidaya udang di perkotaan sangat besar dan sangat menjanjikan. Akses yang mudah di perkotaan merupakan nilai tambah bagi para pelaku budidaya udang karena para petambak dapat menjual hasil panen udang yang masih segar, karena dekatnya lokasi budidaya dengan pasar, hasil panen udang bisa langsung dijual ke pasar swalayan, restoran dan pasar ikan, sehingga mampu meningkatkan peluang dan juga harga udang yang dihasilkan di pasar.

Para pelaku budidaya perikanan yang berlokasi di perkotaan atau biasa disebut dengan *Urban Aquaculture* memiliki kesempatan dalam memelihara udang akan tetapi memiliki ruang terbatas dalam melakukannya. Masyarakat diperkotaan dapat memanfaatkan kolam *portable* untuk melakukan budidaya dengan sistem sirkulasi. Untuk memudahkan petambak memberikan pakan, maka kolam dibentuk menjadi lingkaran. Adapun ukuran kolam *portable* ini memiliki diameter yang bervariasi, sehingga bisa disesuaikan dengan kebutuhan. Metode atau teknik yang digunakan tidak memerlukan lahan yang luas serta penggalian tanah, sehingga kendali, pembersihan dan panen menjadi lebih mudah.

Udang vanamei (*Litopenaeus vannamei*) merupakan salah satu komoditas budidaya di perairan payau. Proses budidaya udang vaname dibagi menjadi dua yaitu proses pembenihan dan kegiatan pembesaran. Kegiatan pembenihan adalah kegiatan memijahkan udang vaname yang inputnya adalah induk dengan output dari proses tersebut adalah benih (benur). Benur yang dihasilkan dari proses pembenihan menjadi input untuk proses pembesaran udang vaname dengan outputnya adalah udang ukuran konsumsi. Pembesaran udang adalah kegiatan untuk memelihara dan/atau membesarkan udang windu (*Penaeus monodon*) dan vaname (*Litopenaeus vannamei*) serta memanen hasilnya dalam lingkungan yang terkontrol (*JDIH Kementerian Kelautan Dan Perikanan*, 2016). Benih udang atau Benur pada pembesaran udang merupakan benih udang yang berumur 10-15 hari dengan ukuran panjang 8.5 mm (*SNI 01-7252-2006*, 2007). Penebaran benih udang vaname umumnya 60-100 ekor/m².

Proses penghitungan benih udang dilakukan menggunakan metode sampling dengan menghitung jumlah bibit udang yang terdapat dalam volume tertentu kemudian dikalkulasikan dengan volume total air pada kolam. Prosedur ini diulangi tiga kali dan hasilnya dirata-ratakan (SNI 8678-4:2021, 2021). Sedangkan untuk menghitung *Survival Rate* (SR), Pendekatan yang digunakan petambak untuk mengetahui nilai SR adalah dengan menghitung rata-rata jumlah udang yang tertangkap dalam luasan jala tertentu yang dikalikan dengan luas petakan tambak dibandingkan dengan luasan jala yang digunakan.

Kegiatan pembenihan udang vanamei tidak terlepas dari ketersediaan benur yang berkualitas. Untuk mendapatkan benur yang berkualitas diperlukan ketersediaan pakan alami yang berkualitas pula, karena penggunaan pakan yang baik akan mempengaruhi kualitas budidaya benur yang baik. Pakan alami yang populer dalam pembenihan udang khususnya untuk larva udang adalah *Artemia*. *Artemia* merupakan salah satu pakan alami bagi larva udang yang banyak digunakan di hatchery udang di seluruh Indonesia. Penggunaan *artemia* dalam kegiatan pembenihan udang di Indonesia hampir semuanya menggunakan produk impor. Hal ini dikarenakan jasad renik ini bukan merupakan hewan asli Indonesia. Berkaitan dengan keunggulan dari *artemia* yaitu kandungan nutrisi yang tinggi serta praktis dalam penggunaannya, sehingga ada upaya akuakultaris di Indonesia dalam menghasilkan *artemia* versi produk lokal. *Artemia* produk impor dan *artemia* produk lokal memiliki kualitas nutrisi yang hampir sama.

Sistem bioflok dikembangkan untuk dapat meningkatkan produksi udang, meningkatkan efisiensi protein dan pakan serta menekan buangan limbah ke lingkungan perairan serta meningkatkan efisiensi penggunaan air dan lahan budidaya. Produksi udang vaname meningkat dengan memanfaatkan sistem bioflok sebagai pakan alami udang (Pantjara et al., 2010).

Penggunaan sistem bioflok sebagai salah satu metode pemberian pakan ke udang mengakibatkan warna air pada kolam tambak menjadi berubah. Perubahan warna ini diakibatkan karena pertumbuhan flok yang akan menjadi pakan alami udang. Seiring dengan pertumbuhan flok ini, tingkat kualitas kejernihan air dan jarak pandang visual bawah air yang ada pada kolam akan semakin berkurang sehingga untuk mendeteksi perkembangan benur udang tidak dapat dilakukan secara visual dengan menggunakan kamera dan memerlukan metode selain menggunakan pengamatan secara visual.



Gambar 1. Kondisi air kolam tambak yang menggunakan pakan dengan sistem bioflok

Dalam medium air, gelombang suara atau akustik memiliki transmisi yang lebih baik dibandingkan dengan medium udara. Kecepatan perambatannya mencapai empat hingga lima kali lebih besar dari cepat rambatnya dalam medium udara. Berbagai informasi yang berasal dari bawah permukaan air bisa diberikan oleh gelombang akustik. *Sound Navigation and Ranging* (SONAR) adalah teknologi untuk mendeteksi objek dan mengukur jarak dengan menggunakan gelombang akustik sebagai medianya. SONAR menggunakan metode perkiraan waktu kedatangan dari gelombang echo yang terkirim untuk mengetahui jarak terhadap objek tersebut.

Berdasarkan cakupan permasalahan pada penjelasan sebelumnya, penelitian ini mengusulkan penggunaan SONAR yang menggunakan metode pengamatan secara akustik untuk mendeteksi perkembangan benur udang vanamei pada kolam yang memiliki tingkat kualitas kejernihan dan jarak pandang yang sangat kurang sehingga dapat membantu petambak dalam memonitor perkembangan udang dan tingkat SR. Hasil data SONAR kemudian akan diubah kedalam bentuk *echogram* dan dilakukan proses segmentasi yang hasil prosesnya nanti digunakan untuk mendeteksi perkembangan objek udang dalam delay waktu tertentu. penelitian ini diharapkan mampu mempermudah para petambak pada perkotaan dalam melakukan monitoring perkembangan benur udang.

1.2. Perumusan Masalah

Berdasarkan latar belakang dan cakupan penelitian yang dilakukan, rumusan masalah yang diangkat pada penelitian ini adalah:

1. Bagaimana melakukan pemindaian bawah air menggunakan sonar untuk mendapatkan citra pada kolam bioflok pada budidaya udang vaname?

2. Bagaimana menggunakan citra hasil pemindaian sonar untuk proses deteksi objek udang vaname?
3. Bagaimana melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek udang vaname?

1.3. Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Melakukan pemindaian kolam bioflok untuk mendapatkan citra data sonar bawah air.
2. Menggunakan citra dari hasil pemindaian sonar bawah air untuk proses deteksi objek udang vaname
3. Melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek.

1.4. Manfaat Penelitian

Manfaat yang dapat diambil dari hasil penelitian ini adalah:

1. Membantu petambak dalam proses monitoring pertumbuhan benur udang vaname pada sistem bioflok. Proses monitoring menggunakan sonar bawah air sehingga dapat memantau kondisi isi kolam dikondisi air keruh yang memiliki visibility yang sangat kurang.
2. Menjadi literatur terkait pemanfaatan sonar bawah air dalam bidang budidaya perikanan

1.5. Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah:

1. Penelitian ini akan difokuskan pada deteksi pergerakan udang pada kolam tambak
2. Data sonar yang digunakan adalah dalam bentuk *singlebeam echosounder*

BAB II

TINJAUAN PUSTAKA

2.1. Kajian Pustaka

2.1.1. Udang Vaname

Udang vannamei (*Litopenaeus vannameii*) berasal dari daerah subtropis pantai barat Amerika, mulai dari Teluk California di Mexico bagian utara sampai ke pantai barat Guatemala, El Salvador, Nicaragua, Kosta Rika di Amerika Tengah hingga ke Peru di Amerika Selatan. Udang vannamei resmi diizinkan masuk ke Indonesia melalui SK Menteri Kelautan dan Perikanan RI. No. 41/2001, dimana produksi udang windu menurun sejak 1996 akibat serangan penyakit dan penurunan kualitas lingkungan. Pemerintah kemudian melakukan kajian pada komoditas udang laut jenis lain yang dapat menambah produksi udang selain udang windu di Indonesia[3].



Gambar 2. Udang Vaname

2.1.2. Teknologi Bioflok

Bioflok merupakan kumpulan atas berbagai mikroorganisme seperti bakteri, fungi, protozoa, fitoplankton, dan bahan organik dari limbah yang tidak terdekomposisi. Teknologi bioflok merupakan teknologi ramah lingkungan karena memanfaatkan bahan dari limbah dari sisa pakan yang ada menjadi pakan dari mikroba sehingga bahan dari limbah organik tersebut terdegradasi dan mikroba dapat berkembang membentuk sekumpulan mikroba yang bercampur dengan koloid

5. Rekan-rekan Lab *Computer Based System* Teknik Informatika yang selalu saling mendukung dalam proses penyelesaian tesis ini.
6. Rekan-rekan mahasiswa S2 Teknik Informatika angkatan 2020-1 yang selalu memberikan dukungan dalam proses penyelesaian tesis ini.

Penulis menyadari bahwa dalam penyelesaian tesis ini masih belum sempurna dan selama proses penyelesaiannya masih menemui banyak kesulitan dan hambatan, sehingga penulis tetap mengharapkan saran dan kritik untuk pengembangan lebih lanjut, agar dapat memberikan manfaat yang banyak bagi semua pembaca.

Gowa, 29 Desember 2024

A handwritten signature in black ink, featuring a large, stylized loop at the top and several smaller, fluid strokes below it, ending in a small vertical mark.

Dwi Bagus Fitriyanto

DAFTAR ISI

	Halaman
HALAMAN SAMPUL.....	i
PENGAJUAN TESIS.....	ii
KATA PENGANTAR.....	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR.....	x
DAFTAR TABEL	xii
BAB I.....	1
1.1. Latar Belakang.....	1
1.2. Perumusan Masalah.....	3
1.3. Tujuan Penelitian.....	4
1.4. Manfaat Penelitian.....	4
1.5. Batasan Masalah.....	4
BAB II	5
2.1. Kajian Pustaka.....	5
2.1.1. Udang Vaname.....	5
2.1.2. Teknologi Bioflok	5
2.1.3. Sound Navigation and Ranging (SONAR)	7
2.1.3.1. Tradisional Echosounder	7
2.1.3.2. Side Scan Sonar (SSS).....	10
2.1.3.3. Down Scan SONAR	10
2.1.3.4. Dual frequency IDentfication SONar (DIDSON).....	11
2.1.4. Convolutional Neural Network (CNN)	11
2.1.4.1. Convolutional Layer	12
2.1.4.2. Stride.....	13
2.1.4.3. Padding	13
2.1.4.4. Pooling layer	14
2.1.4.5. Fully Connected layer	14

2.1.4.6.	Activation Function	15
2.1.4.7.	Softmax Function.....	15
2.1.5.	Region based Convolutional Neural Network (R-CNN)	16
2.1.6.	Faster Region based Convolutional Neural Network (Faster R-CNN).....	17
2.1.6.1.	Region Proposal Network (RPN).....	17
2.1.7.	You Only Look Once (YOLO)	20
2.1.8.	Depth Map.....	23
2.1.9.	<i>Google Colaboratory</i>	23
2.2.	Metode Penyelesaian Masalah	24
2.2.1.	State of The Art Penelitian	24
2.2.2.	Metode yang Diusulkan	37
2.2.3.	Tingkat Keaslian (Level Orosinalitas) Topik Penelitian yang Diusulkan.....	37
2.3.	Target Hasil Penelitian	41
2.4.	Kerangka Pikir	42
BAB III		43
4.1.	Jenis Penelitian	43
4.2.	Tahapan Penelitian	44
4.3.	Sumber Data	45
4.4.	Rancangan Sistem	46
4.5.	Pengujian Sistem	55
4.6.	Waktu dan Lokasi Penelitian.....	57
BAB IV		59
4.1.	CNN.....	59
4.2.	FASTER R-CNN.....	62
4.3.	YOLOv8.....	64
4.4.	Perbandingan Hasil.....	66
BAB V		67
5.1.	Kesimpulan.....	67
5.2.	Saran	68
DAFTAR PUSTAKA		69
LAMPIRAN		73

DAFTAR GAMBAR

Gambar 1. Kondisi air kolam tambak yang menggunakan pakan dengan sistem bioflok.....	3
Gambar 2. Udang Vaname.....	5
Gambar 3. Transmisi Frekuensi Sonar Singlebeam Echosounder.....	8
Gambar 4. Ilustrasi hasil scan singlebeam echosounder.....	8
Gambar 5. Transmisi Frekuensi dengan Teknologi CHIRP	9
Gambar 6. Ilustrasi hasil scan dengan teknologi CHIRP.....	9
Gambar 7. Proses Side Scan Sonar	10
Gambar 8. Perbedaan antara hasil Tradisional SONAR dan Down Scan SONAR.....	11
Gambar 9. Data Hasil citra sonar menggunakan teknologi DIDSON	11
Gambar 10. Arsitektur CNN	12
Gambar 11. Operasi Konvolusi.....	13
Gambar 12. Filter dengan nilai stride = 2	13
Gambar 13. Pemberian nilai padding = 1	14
Gambar 14. Perbedaan metode Max pooling dan Avg pooling.....	14
Gambar 15. Ilustrasi Fully Connected Layer.....	15
Gambar 16. Fungsi Aktivasi	15
Gambar 17. Fungsi Aktivasi Softmax.....	16
Gambar 18. Arsitektur R-CNN	16
Gambar 19. Arsitektur Fast R-CNN	17
Gambar 20. Region Proposal Network	18
Gambar 21. Arsitektur Faster R-CNN	18
Gambar 22. Arsitektur YOLOv8 (Ju & Cai, 2023)	22
Gambar 23. Antarmuka Google Colab pada browser.....	23
Gambar 24. Pilihan penggunaan Hardware Accelerator pada Google Colab Pro	24
Gambar 25. Kerangka Pikir	42
Gambar 26. Tahapan Pelaksanaan Penelitian	45
Gambar 27. Sudut Scan Transduser.....	46
Gambar 28. Bagan Rancangan Sistem.....	46

Gambar 29. Objek Target berdasarkan hasil singlebeam echosounder: (a) ilustrasi posisi transduser dan objek udang, (b) Citra singlebeam echosounder	47
Gambar 30. Pembacaan Data .RSD pada Aplikasi Garmin HomePort	48
Gambar 31. Visualisasi Citra singlebeam echosounder dalam satuan waktu	48
Gambar 32. Rancangan Proses	49
Gambar 33. Proses Cropping Citra Singlebeam Echosounder	50
Gambar 34. Proses Depth Map: (a) Citra asli singlebeam echosounder, (b) Citra setelah dilakukan proses depth map	52
Gambar 35. Dataset singlebeam echosounder dengan ukuran 600 x 600 piksel	53
Gambar 36. Proses Pelabelan data pada Label Studio	54
Gambar 37. Pelabelan data dalam 3 kelas	54
Gambar 38. Pilihan Format Export Data Hasil Pelabelan	55
Gambar 39. Blok Diagram Proses Faster RCNN deteksi udang	55
Gambar 40. Kategori Confusion Matrix	56
Gambar 41. Linimasa Penelitian	58
Gambar 42. Confusion Matrix dari hasil pelatihan menggunakan algoritma CNN	60
Gambar 43. Hasil perhitungan precision, recall, dan f1-score	62
Gambar 44. Sampling hasil deteksi menggunakan model hasil training Faster R-CNN	63
Gambar 45. Confusion Matrix dari hasil pelatihan menggunakan algoritma YOLOv8	65
Gambar 46. Sampling hasil deteksi menggunakan model hasil training YOLOv8	65

DAFTAR TABEL

Tabel 1. State of The Art.....	24
Tabel 2. Tabel Referensi dan Metode yang diusulkan.....	37
Tabel 3. Level Orisinalitas Proposal Magister Teknik Informatika UNHAS.....	40

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kebutuhan akan pangan, termasuk udang terus meningkat, seiring pertumbuhan populasi di perkotaan, sehingga peluang budidaya udang di perkotaan sangat besar dan sangat menjanjikan. Akses yang mudah di perkotaan merupakan nilai tambah bagi para pelaku budidaya udang karena para petambak dapat menjual hasil panen udang yang masih segar, karena dekatnya lokasi budidaya dengan pasar, hasil panen udang bisa langsung dijual ke pasar swalayan, restoran dan pasar ikan, sehingga mampu meningkatkan peluang dan juga harga udang yang dihasilkan di pasar.

Para pelaku budidaya perikanan yang berlokasi di perkotaan atau biasa disebut dengan *Urban Aquaculture* memiliki kesempatan dalam memelihara udang akan tetapi memiliki ruang terbatas dalam melakukannya. Masyarakat diperkotaan dapat memanfaatkan kolam *portable* untuk melakukan budidaya dengan sistem sirkulasi. Untuk memudahkan petambak memberikan pakan, maka kolam dibentuk menjadi lingkaran. Adapun ukuran kolam *portable* ini memiliki diameter yang bervariasi, sehingga bisa disesuaikan dengan kebutuhan. Metode atau teknik yang digunakan tidak memerlukan lahan yang luas serta penggalian tanah, sehingga kendali, pembersihan dan panen menjadi lebih mudah.

Udang vanamei (*Litopenaeus vannamei*) merupakan salah satu komoditas budidaya di perairan payau. Proses budidaya udang vaname dibagi menjadi dua yaitu proses pembenihan dan kegiatan pembesaran. Kegiatan pembenihan adalah kegiatan memijahkan udang vaname yang inputnya adalah induk dengan output dari proses tersebut adalah benih (benur). Benur yang dihasilkan dari proses pembenihan menjadi input untuk proses pembesaran udang vaname dengan outputnya adalah udang ukuran konsumsi. Pembesaran udang adalah kegiatan untuk memelihara dan/atau membesarkan udang windu (*Penaeus monodon*) dan vaname (*Litopenaeus vannamei*) serta memanen hasilnya dalam lingkungan yang terkontrol (*JDIH Kementerian Kelautan Dan Perikanan*, 2016). Benih udang atau Benur pada pembesaran udang merupakan benih udang yang berumur 10-15 hari dengan ukuran panjang 8.5 mm (*SNI 01-7252-2006*, 2007). Penebaran benih udang vaname umumnya 60-100 ekor/m².

Proses penghitungan benih udang dilakukan menggunakan metode sampling dengan menghitung jumlah bibit udang yang terdapat dalam volume tertentu kemudian dikalkulasikan dengan volume total air pada kolam. Prosedur ini diulangi tiga kali dan hasilnya dirata-ratakan (SNI 8678-4:2021, 2021). Sedangkan untuk menghitung *Survival Rate* (SR), Pendekatan yang digunakan petambak untuk mengetahui nilai SR adalah dengan menghitung rata-rata jumlah udang yang tertangkap dalam luasan jala tertentu yang dikalikan dengan luas petakan tambak dibandingkan dengan luasan jala yang digunakan.

Kegiatan pembenihan udang vanamei tidak terlepas dari ketersediaan benur yang berkualitas. Untuk mendapatkan benur yang berkualitas diperlukan ketersediaan pakan alami yang berkualitas pula, karena penggunaan pakan yang baik akan mempengaruhi kualitas budidaya benur yang baik. Pakan alami yang populer dalam pembenihan udang khususnya untuk larva udang adalah *Artemia*. *Artemia* merupakan salah satu pakan alami bagi larva udang yang banyak digunakan di hatchery udang di seluruh Indonesia. Penggunaan *artemia* dalam kegiatan pembenihan udang di Indonesia hampir semuanya menggunakan produk impor. Hal ini dikarenakan jasad renik ini bukan merupakan hewan asli Indonesia. Berkaitan dengan keunggulan dari *artemia* yaitu kandungan nutrisi yang tinggi serta praktis dalam penggunaannya, sehingga ada upaya akuakultaris di Indonesia dalam menghasilkan *artemia* versi produk lokal. *Artemia* produk impor dan *artemia* produk lokal memiliki kualitas nutrisi yang hampir sama.

Sistem bioflok dikembangkan untuk dapat meningkatkan produksi udang, meningkatkan efisiensi protein dan pakan serta menekan buangan limbah ke lingkungan perairan serta meningkatkan efisiensi penggunaan air dan lahan budidaya. Produksi udang vaname meningkat dengan memanfaatkan sistem bioflok sebagai pakan alami udang (Pantjara et al., 2010).

Penggunaan sistem bioflok sebagai salah satu metode pemberian pakan ke udang mengakibatkan warna air pada kolam tambak menjadi berubah. Perubahan warna ini diakibatkan karena pertumbuhan flok yang akan menjadi pakan alami udang. Seiring dengan pertumbuhan flok ini, tingkat kualitas kejernihan air dan jarak pandang visual bawah air yang ada pada kolam akan semakin berkurang sehingga untuk mendeteksi perkembangan benur udang tidak dapat dilakukan secara visual dengan menggunakan kamera dan memerlukan metode selain menggunakan pengamatan secara visual.



Gambar 1. Kondisi air kolam tambak yang menggunakan pakan dengan sistem bioflok

Dalam medium air, gelombang suara atau akustik memiliki transmisi yang lebih baik dibandingkan dengan medium udara. Kecepatan perambatannya mencapai empat hingga lima kali lebih besar dari cepat rambatnya dalam medium udara. Berbagai informasi yang berasal dari bawah permukaan air bisa diberikan oleh gelombang akustik. *Sound Navigation and Ranging* (SONAR) adalah teknologi untuk mendeteksi objek dan mengukur jarak dengan menggunakan gelombang akustik sebagai medianya. SONAR menggunakan metode perkiraan waktu kedatangan dari gelombang echo yang terkirim untuk mengetahui jarak terhadap objek tersebut.

Berdasarkan cakupan permasalahan pada penjelasan sebelumnya, penelitian ini mengusulkan penggunaan SONAR yang menggunakan metode pengamatan secara akustik untuk mendeteksi perkembangan benur udang vanamei pada kolam yang memiliki tingkat kualitas kejernihan dan jarak pandang yang sangat kurang sehingga dapat membantu petambak dalam memonitor perkembangan udang dan tingkat SR. Hasil data SONAR kemudian akan diubah kedalam bentuk *echogram* dan dilakukan proses segmentasi yang hasil prosesnya nanti digunakan untuk mendeteksi perkembangan objek udang dalam delay waktu tertentu. penelitian ini diharapkan mampu mempermudah para petambak pada perkotaan dalam melakukan monitoring perkembangan benur udang.

1.2. Perumusan Masalah

Berdasarkan latar belakang dan cakupan penelitian yang dilakukan, rumusan masalah yang diangkat pada penelitian ini adalah:

1. Bagaimana melakukan pemindaian bawah air menggunakan sonar untuk mendapatkan citra pada kolam bioflok pada budidaya udang vaname?

2. Bagaimana menggunakan citra hasil pemindaian sonar untuk proses deteksi objek udang vaname?
3. Bagaimana melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek udang vaname?

1.3. Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Melakukan pemindaian kolam bioflok untuk mendapatkan citra data sonar bawah air.
2. Menggunakan citra dari hasil pemindaian sonar bawah air untuk proses deteksi objek udang vaname
3. Melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek.

1.4. Manfaat Penelitian

Manfaat yang dapat diambil dari hasil penelitian ini adalah:

1. Membantu petambak dalam proses monitoring pertumbuhan benur udang vaname pada sistem bioflok. Proses monitoring menggunakan sonar bawah air sehingga dapat memantau kondisi isi kolam dikondisi air keruh yang memiliki visibility yang sangat kurang.
2. Menjadi literatur terkait pemanfaatan sonar bawah air dalam bidang budidaya perikanan

1.5. Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah:

1. Penelitian ini akan difokuskan pada deteksi pergerakan udang pada kolam tambak
2. Data sonar yang digunakan adalah dalam bentuk *singlebeam echosounder*

BAB II

TINJAUAN PUSTAKA

2.1. Kajian Pustaka

2.1.1. Udang Vaname

Udang vannamei (*Litopenaeus vannameii*) berasal dari daerah subtropis pantai barat Amerika, mulai dari Teluk California di Mexico bagian utara sampai ke pantai barat Guatemala, El Salvador, Nicaragua, Kosta Rika di Amerika Tengah hingga ke Peru di Amerika Selatan. Udang vannamei resmi diizinkan masuk ke Indonesia melalui SK Menteri Kelautan dan Perikanan RI. No. 41/2001, dimana produksi udang windu menurun sejak 1996 akibat serangan penyakit dan penurunan kualitas lingkungan. Pemerintah kemudian melakukan kajian pada komoditas udang laut jenis lain yang dapat menambah produksi udang selain udang windu di Indonesia[3].



Gambar 2. Udang Vaname

2.1.2. Teknologi Bioflok

Bioflok merupakan kumpulan atas berbagai mikroorganisme seperti bakteri, fungi, protozoa, fitoplankton, dan bahan organik dari limbah yang tidak terdekomposisi. Teknologi bioflok merupakan teknologi ramah lingkungan karena memanfaatkan bahan dari limbah dari sisa pakan yang ada menjadi pakan dari mikroba sehingga bahan dari limbah organik tersebut terdegradasi dan mikroba dapat berkembang membentuk sekumpulan mikroba yang bercampur dengan koloid

organik lainnya[8]. Menurut Avnimelech[9], hasil perombakan tersebut jika terbentuk floks dapat digunakan udang dan menjadi sumber protein yang sangat baik bagi udang. Senyawa organik yang terdekomposisi mengandung senyawa karbon (C), hidrogen (H), oksigen (O₂), nitrogen (N) dengan sedikit fosfor (P) menjadi massa lumpur berupa biofloks dengan menggunakan bakteri pembentuk floks (Flocc Forming Bacteria).

Teknologi bioflok merupakan teknologi yang dikembangkan dengan memadukan penanganan buangan limbah hasil budidaya dan mereduksi jumlah penggunaan air. Secara umum, kelebihan dari teknologi ini adalah biaya operasional yang lebih kecil, tingkat kelangsungan hidup yang tinggi[10] dan nilai FCR (feed conversion ratio) yang lebih rendah. Prinsip teknologi ini adalah mengkonversi limbah budidaya yang mengandung unsur nitrogen yang cukup tinggi menjadi pakan tambahan bagi udang selama proses peliharaan[11].

Proses konversi tersebut terjadi jika jumlah kandungan nitrogen dan karbon dalam media budidaya seimbang. Sumber nitrogen dalam perairan diperoleh dari pakan yang diberikan dengan kandungan protein tinggi. Berdasarkan SNI (2000) kandungan protein yang diberikan untuk budidaya udang adalah 28%. Pemberian protein yang cukup tinggi ini tidak diimbangi dengan pemberian karbon yang seimbang dalam pakan. Untuk itu perlu upaya penambahan sumber karbon untuk menyeimbangkan jumlah nitrogen dalam perairan budidaya.

Terbentuknya flok karena adanya bakteri yang mampu merombak limbah bahan organik sehingga bakteri tersebut berkembang dan masing-masing sel bakteri berperan mensekresikan lendir metabolit dan biopolimer (polisakarida, peptide, dan lipida) atau senyawa kombinasinya. Secara alami terjadi gaya tarik antar sel dari sel bakteri dan mikroorganisme serta organik lainnya yang membentuk flok yang banyak mengandung protein tinggi. Beberapa mikroorganisme berfungsi sebagai bioflocculant antara lain *Zooglea ramigera*, *Paracolobacterium aerogenoids*, *Bacillus subtilis*, *Bacillus cereus*, *Flavobacterium*, *Pseudomonas alcaligenes*, *Sphaerotillus natans*, *Escherichia intermedia*. Keberadaan oksigen dalam pembentukan bioflok mutlak diperlukan agar flok dapat terbentuk sempurna. Kekurangan oksigen dapat menyebabkan berkembangnya bakteri dan flok kurang terbentuk sempurna. Pada kondisi pH yang rendah dapat menghambat terbentuknya bioflok karena akan mengurangi kandungan kation divalen dalam air untuk ikatan esterase, untuk itu, pada pH yang rendah diperlukan pemberian dolomit agar pH menjadi netral. Hasil dekomposisi bahan organik menghasilkan amonia yang dapat menyebabkan toksik bagi udang, namun masih dapat

ABSTRAK


DWI BAGUS FITRIYANTO. *Deteksi Perkembangan Udang Vaname pada Sistem Bioflok Menggunakan Data Sonar.* (dibimbing oleh **Zahir Zainuddin, Andani Achmad**)

Sistem bioflok dikembangkan untuk dapat meningkatkan produksi udang, meningkatkan efisiensi protein dan pakan. Penggunaan sistem bioflok sebagai salah satu metode pemberian pakan ke udang mengakibatkan warna air pada kolam tambak menjadi berubah. Perubahan warna ini diakibatkan karena pertumbuhan flok yang akan menjadi pakan alami udang. Seiring dengan pertumbuhan flok ini, tingkat kualitas kejernihan air dan jarak pandang visual bawah air yang ada pada kolam akan semakin berkurang sehingga untuk mendeteksi perkembangan benur udang tidak dapat dilakukan secara visual dengan menggunakan kamera. Penelitian ini mengusulkan penggunaan sonar yang menggunakan metode pengamatan secara akustik untuk mendeteksi perkembangan benur udang vanamei untuk dapat membantu petambak dalam memonitor perkembangan udang. Citra sonar yang digunakan yaitu citra *singlebeam echosounder* yang dianalisis dengan membandingkan tiga algoritma deteksi objek yang berbeda, yaitu *CNN*, *Faster R-CNN*, dan *YOLOv8*. Peningkatan pewarnaan untuk objek target dilakukan dengan *Depth Map* untuk representasi visual yang menunjukkan kedalaman objek di mana setiap piksel memiliki nilai yang mencerminkan jarak objek. Penelitian ini mengkategorikan objek yang dideteksi menjadi 3 kelas yaitu *single shrimp*, *multiple shrimp*, dan *shrimp groups*. Evaluasi hasil deteksi menggunakan Confusion Matrix dan Mean Average Precision (mAP). Hasil pengujian menunjukkan bahwa kinerja deteksi yang dicapai menggunakan model *YOLOv8* lebih baik daripada *CNN* dan *Faster R-CNN*.


Kata kunci: Akuakultur, Bioflok, Sonar, Pengolahan Citra, Deteksi Objek

Menyetujui,

Pembimbing I


Dr. Ir. Zahir Zainuddin, M.Sc.
NIP. 19640427 198910 1 002

Pembimbing II


Prof. Dr. Ir. H. Andani Achmad, M.T.
NIP. 19601231 198703 1 022

ABSTRACT


DWI BAGUS FITRIYANTO. *Detection Of Vannamei Shrimp Growth in Biofloc Systems Through Sonar Data.* (supervised by **Zahir Zainuddin, Andani Achmad**)

The biofloc system was developed to increase shrimp production and improve protein and feed efficiency. The use of the biofloc system as one of the feeding methods for shrimp resulted in the color of the water in the pond changing. This color change is caused by the growth of flocs that will become natural shrimp feed. Along with the growth of these flocs, the quality level of water clarity and underwater visual visibility in the pond will be reduced so that detecting the development of shrimp cannot be done visually using a camera. This study proposes the use of sonar that uses acoustic observation methods to detect the development of vanamei shrimp to help farmers monitor shrimp development. The sonar images used are single-beam echosounder images analyzed by comparing three different object detection algorithms, namely CNN, Faster R-CNN, and YOLOv8. Coloration enhancement for the target object is done with a Depth Map for visual representation showing the depth of the object, where each pixel has a value reflecting the distance of the object. This research categorizes the detected objects into 3 classes, namely single shrimp, multiple shrimp, and shrimp groups. Evaluation of detection results using confusion matrix and mean average precision (mAP). The test results showed that the detection performance achieved using the YOLOv8 model was greater than CNN and Faster R-CNN.

Keywords: Aquaculture, Biofloc, Sonar, Image Processing, Object Detection.


Menyetujui,

Pembimbing I



Dr. Ir. Zahir Zainuddin, M.Sc.
NIP. 19640427 198910 1 002

Pembimbing II



Prof. Dr. Ir. H. Andani Achmad, M.T.
NIP. 19601231 198703 1 022

Gambar 29. Objek Target berdasarkan hasil singlebeam echosounder: (a) ilustrasi posisi transduser dan objek udang. (b) Citra singlebeam echosounder.....	47
Gambar 30. Pembacaan Data .RSD pada Aplikasi Garmin HomePort	48
Gambar 31. Visualisasi Citra singlebeam echosounder dalam satuan waktu.....	48
Gambar 32. Rancangan Proses	49
Gambar 33. Proses Cropping Citra Singlebeam Echosounder	50
Gambar 34. Tahapan penanda pemisah objek tunggal	51
Gambar 35. Proses Depth Map: (a) Citra asli singlebeam echosounder, (b) Citra setelah dilakukan proses depth map.....	52
Gambar 36. Dataset singlebeam echosounder dengan ukuran 600 x 600 piksel	53
Gambar 37. Proses Pelabelan data pada Label Studio	54
Gambar 38. Pelabelan data dalam 3 kelas	54
Gambar 39. Pilihan Format Export Data Hasil Pelabelan	55
Gambar 40. Blok Diagram Proses Faster RCNN deteksi udang	55
Gambar 41. Kategori Confusion Matrix	56
Gambar 42. Linimasa Penelitian.....	58
Gambar 43. Confusion Matrix dari hasil pelatihan menggunakan algoritma CNN	60
Gambar 44. Hasil perhitungan precision, recall, dan f1-score.....	62
Gambar 45. Hasil deteksi menggunakan model hasil training Faster R-CNN	63
Gambar 46. Confusion Matrix dari hasil pelatihan menggunakan algoritma Faster R-CNN.....	64
Gambar 47. Confusion Matrix dari hasil pelatihan menggunakan algoritma YOLOv8.....	65
Gambar 48. Hasil deteksi menggunakan model hasil training YOLOv8	65

DAFTAR TABEL

Tabel 1. State of The Art.....	24
Tabel 2. Tabel Referensi dan Metode yang diusulkan.....	37
Tabel 3. Level Orisinalitas Proposal Magister Teknik Informatika UNHAS.....	40

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kebutuhan akan pangan, termasuk udang terus meningkat, seiring pertumbuhan populasi di perkotaan, sehingga peluang budidaya udang di perkotaan sangat besar dan sangat menjanjikan. Akses yang mudah di perkotaan merupakan nilai tambah bagi para pelaku budidaya udang karena para petambak dapat menjual hasil panen udang yang masih segar, karena dekatnya lokasi budidaya dengan pasar, hasil panen udang bisa langsung dijual ke pasar swalayan, restoran dan pasar ikan, sehingga mampu meningkatkan peluang dan juga harga udang yang dihasilkan di pasar.

Para pelaku budidaya perikanan yang berlokasi di perkotaan atau biasa disebut dengan *Urban Aquaculture* memiliki kesempatan dalam memelihara udang akan tetapi memiliki ruang terbatas dalam melakukannya. Masyarakat diperkotaan dapat memanfaatkan kolam *portable* untuk melakukan budidaya dengan sistem sirkulasi. Untuk memudahkan petambak memberikan pakan, maka kolam dibentuk menjadi lingkaran. Adapun ukuran kolam *portable* ini memiliki diameter yang bervariasi, sehingga bisa disesuaikan dengan kebutuhan. Metode atau teknik yang digunakan tidak memerlukan lahan yang luas serta penggalian tanah, sehingga kendali, pembersihan dan panen menjadi lebih mudah.

Udang vanamei (*Litopenaeus vannamei*) merupakan salah satu komoditas budidaya di perairan payau. Proses budidaya udang vaname dibagi menjadi dua yaitu proses pembenihan dan kegiatan pembesaran. Kegiatan pembenihan adalah kegiatan memijahkan udang vaname yang inputnya adalah induk dengan output dari proses tersebut adalah benih (benur). Benur yang dihasilkan dari proses pembenihan menjadi input untuk proses pembesaran udang vaname dengan outputnya adalah udang ukuran konsumsi. Pembesaran udang adalah kegiatan untuk memelihara dan/atau membesarkan udang windu (*Penaeus monodon*) dan vaname (*Litopenaeus vannamei*) serta memanen hasilnya dalam lingkungan yang terkontrol (*JDIH Kementerian Kelautan Dan Perikanan*, 2016). Benih udang atau Benur pada pembesaran udang merupakan benih udang yang berumur 10-15 hari dengan ukuran panjang 8.5 mm (*SNI 01-7252-2006*, 2007). Penebaran benih udang vaname umumnya 60-100 ekor/m².

Proses penghitungan benih udang dilakukan menggunakan metode sampling dengan menghitung jumlah bibit udang yang terdapat dalam volume tertentu kemudian dikalkulasikan dengan volume total air pada kolam. Prosedur ini diulangi tiga kali dan hasilnya dirata-ratakan (SNI 8678-4:2021, 2021). Sedangkan untuk menghitung *Survival Rate* (SR), Pendekatan yang digunakan petambak untuk mengetahui nilai SR adalah dengan menghitung rata-rata jumlah udang yang tertangkap dalam luasan jala tertentu yang dikalikan dengan luas petakan tambak dibandingkan dengan luasan jala yang digunakan.

Kegiatan pembenihan udang vanamei tidak terlepas dari ketersediaan benur yang berkualitas. Untuk mendapatkan benur yang berkualitas diperlukan ketersediaan pakan alami yang berkualitas pula, karena penggunaan pakan yang baik akan mempengaruhi kualitas budidaya benur yang baik. Pakan alami yang populer dalam pembenihan udang khususnya untuk larva udang adalah *Artemia*. *Artemia* merupakan salah satu pakan alami bagi larva udang yang banyak digunakan di hatchery udang di seluruh Indonesia. Penggunaan *artemia* dalam kegiatan pembenihan udang di Indonesia hampir semuanya menggunakan produk impor. Hal ini dikarenakan jasad renik ini bukan merupakan hewan asli Indonesia. Berkaitan dengan keunggulan dari *artemia* yaitu kandungan nutrisi yang tinggi serta praktis dalam penggunaannya, sehingga ada upaya akuakultaris di Indonesia dalam menghasilkan *artemia* versi produk lokal. *Artemia* produk impor dan *artemia* produk lokal memiliki kualitas nutrisi yang hampir sama.

Sistem bioflok dikembangkan untuk dapat meningkatkan produksi udang, meningkatkan efisiensi protein dan pakan serta menekan buangan limbah ke lingkungan perairan serta meningkatkan efisiensi penggunaan air dan lahan budidaya. Produksi udang vaname meningkat dengan memanfaatkan sistem bioflok sebagai pakan alami udang (Pantjara et al., 2010).

Penggunaan sistem bioflok sebagai salah satu metode pemberian pakan ke udang mengakibatkan warna air pada kolam tambak menjadi berubah. Perubahan warna ini diakibatkan karena pertumbuhan flok yang akan menjadi pakan alami udang. Seiring dengan pertumbuhan flok ini, tingkat kualitas kejernihan air dan jarak pandang visual bawah air yang ada pada kolam akan semakin berkurang sehingga untuk mendeteksi perkembangan benur udang tidak dapat dilakukan secara visual dengan menggunakan kamera dan memerlukan metode selain menggunakan pengamatan secara visual.



Gambar 1. Kondisi air kolam tambak yang menggunakan pakan dengan sistem bioflok

Dalam medium air, gelombang suara atau akustik memiliki transmisi yang lebih baik dibandingkan dengan medium udara. Kecepatan perambatannya mencapai empat hingga lima kali lebih besar dari cepat rambatnya dalam medium udara. Berbagai informasi yang berasal dari bawah permukaan air bisa diberikan oleh gelombang akustik. *Sound Navigation and Ranging* (SONAR) adalah teknologi untuk mendeteksi objek dan mengukur jarak dengan menggunakan gelombang akustik sebagai medianya. SONAR menggunakan metode perkiraan waktu kedatangan dari gelombang echo yang terkirim untuk mengetahui jarak terhadap objek tersebut.

Berdasarkan cakupan permasalahan pada penjelasan sebelumnya, penelitian ini mengusulkan penggunaan SONAR yang menggunakan metode pengamatan secara akustik untuk mendeteksi perkembangan benur udang vanamei pada kolam yang memiliki tingkat kualitas kejernihan dan jarak pandang yang sangat kurang sehingga dapat membantu petambak dalam memonitor perkembangan udang dan tingkat SR. Hasil data SONAR kemudian akan diubah kedalam bentuk *echogram* dan dilakukan proses segmentasi yang hasil prosesnya nanti digunakan untuk mendeteksi perkembangan objek udang dalam delay waktu tertentu. penelitian ini diharapkan mampu mempermudah para petambak pada perkotaan dalam melakukan monitoring perkembangan benur udang.

1.2. Perumusan Masalah

Berdasarkan latar belakang dan cakupan penelitian yang dilakukan, rumusan masalah yang diangkat pada penelitian ini adalah:

1. Bagaimana melakukan pemindaian bawah air menggunakan sonar untuk mendapatkan citra pada kolam bioflok pada budidaya udang vaname?

2. Bagaimana menggunakan citra hasil pemindaian sonar untuk proses deteksi objek udang vaname?
3. Bagaimana melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek udang vaname?

1.3. Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Melakukan pemindaian kolam bioflok untuk mendapatkan citra data sonar bawah air.
2. Menggunakan citra dari hasil pemindaian sonar bawah air untuk proses deteksi objek udang vaname
3. Melakukan estimasi perhitungan jumlah udang berdasarkan hasil deteksi objek.

1.4. Manfaat Penelitian

Manfaat yang dapat diambil dari hasil penelitian ini adalah:

1. Membantu petambak dalam proses monitoring pertumbuhan benur udang vaname pada sistem bioflok. Proses monitoring menggunakan sonar bawah air sehingga dapat memantau kondisi isi kolam dikondisi air keruh yang memiliki visibility yang sangat kurang.
2. Menjadi literatur terkait pemanfaatan sonar bawah air dalam bidang budidaya perikanan

1.5. Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah:

1. Penelitian ini akan difokuskan pada deteksi pergerakan udang pada kolam tambak
2. Data sonar yang digunakan adalah dalam bentuk *singlebeam echosounder*

BAB II

TINJAUAN PUSTAKA

2.1. Kajian Pustaka

2.1.1. Udang Vaname

Udang vannamei (*Litopenaeus vannameii*) berasal dari daerah subtropis pantai barat Amerika, mulai dari Teluk California di Mexico bagian utara sampai ke pantai barat Guatemala, El Salvador, Nicaragua, Kosta Rika di Amerika Tengah hingga ke Peru di Amerika Selatan. Udang vannamei resmi diizinkan masuk ke Indonesia melalui SK Menteri Kelautan dan Perikanan RI. No. 41/2001, dimana produksi udang windu menurun sejak 1996 akibat serangan penyakit dan penurunan kualitas lingkungan. Pemerintah kemudian melakukan kajian pada komoditas udang laut jenis lain yang dapat menambah produksi udang selain udang windu di Indonesia[3].



Gambar 2. Udang Vaname

2.1.2. Teknologi Bioflok

Bioflok merupakan kumpulan atas berbagai mikroorganisme seperti bakteri, fungi, protozoa, fitoplankton, dan bahan organik dari limbah yang tidak terdekomposisi. Teknologi bioflok merupakan teknologi ramah lingkungan karena memanfaatkan bahan dari limbah dari sisa pakan yang ada menjadi pakan dari mikroba sehingga bahan dari limbah organik tersebut terdegradasi dan mikroba dapat berkembang membentuk sekumpulan mikroba yang bercampur dengan koloid

organik lainnya[8]. Menurut Avnimelech[9], hasil perombakan tersebut jika terbentuk floks dapat digunakan udang dan menjadi sumber protein yang sangat baik bagi udang. Senyawa organik yang terdekomposisi mengandung senyawa karbon (C), hidrogen (H), oksigen (O₂), nitrogen (N) dengan sedikit fosfor (P) menjadi massa lumpur berupa biofloks dengan menggunakan bakteri pembentuk floks (Flocc Forming Bacteria).

Teknologi bioflok merupakan teknologi yang dikembangkan dengan memadukan penanganan buangan limbah hasil budidaya dan mereduksi jumlah penggunaan air. Secara umum, kelebihan dari teknologi ini adalah biaya operasional yang lebih kecil, tingkat kelangsungan hidup yang tinggi[10] dan nilai FCR (feed conversion ratio) yang lebih rendah. Prinsip teknologi ini adalah mengkonversi limbah budidaya yang mengandung unsur nitrogen yang cukup tinggi menjadi pakan tambahan bagi udang selama proses peliharaan[11].

Proses konversi tersebut terjadi jika jumlah kandungan nitrogen dan karbon dalam media budidaya seimbang. Sumber nitrogen dalam perairan diperoleh dari pakan yang diberikan dengan kandungan protein tinggi. Berdasarkan SNI (2000) kandungan protein yang diberikan untuk budidaya udang adalah 28%. Pemberian protein yang cukup tinggi ini tidak diimbangi dengan pemberian karbon yang seimbang dalam pakan. Untuk itu perlu upaya penambahan sumber karbon untuk menyeimbangkan jumlah nitrogen dalam perairan budidaya.

Terbentuknya flok karena adanya bakteri yang mampu merombak limbah bahan organik sehingga bakteri tersebut berkembang dan masing-masing sel bakteri berperan mensekresikan lendir metabolit dan biopolimer (polisakarida, peptide, dan lipida) atau senyawa kombinasinya. Secara alami terjadi gaya tarik antar sel dari sel bakteri dan mikroorganisme serta organik lainnya yang membentuk flok yang banyak mengandung protein tinggi. Beberapa mikroorganisme berfungsi sebagai bioflocculant antara lain *Zooglea ramigera*, *Paracolobacterium aerogenoids*, *Bacillus subtilis*, *Bacillus cereus*, *Flavobacterium*, *Pseudomonas alcaligenes*, *Sphaerotillus natans*, *Escherichia intermedia*. Keberadaan oksigen dalam pembentukan bioflok mutlak diperlukan agar flok dapat terbentuk sempurna. Kekurangan oksigen dapat menyebabkan berkembangnya bakteri dan flok kurang terbentuk sempurna. Pada kondisi pH yang rendah dapat menghambat terbentuknya bioflok karena akan mengurangi kandungan kation divalen dalam air untuk ikatan esterase, untuk itu, pada pH yang rendah diperlukan pemberian dolomit agar pH menjadi netral. Hasil dekomposisi bahan organik menghasilkan amonia yang dapat menyebabkan toksik bagi udang, namun masih dapat

dimanfaatkan bakteri dalam proses amonifikasi dan nitrifikasi sehingga kualitas air dapat lebih baik. Perkembangan pesat dari bakteri flok akan memungkinkan terjadinya gumpalan-gumpalan yang dapat dimanfaatkan kembali oleh biota. Namun demikian dibutuhkan kandungan oksigen yang cukup ($> 4 \text{ mg/L}$), pH 7,3–8,3 untuk mempertahankan flok karena susunan flok akan berubah kembali setelah 8 jam. Kebutuhan aerasi besar ini menyebabkan teknik bioflok hanya layak secara ekonomis untuk padat tebar tinggi.

2.1.3. Sound Navigation and Ranging (SONAR)

SONAR adalah sebuah teknologi yang menggunakan gelombang suara atau akustik untuk mendeteksi suatu benda dan mengukur jarak terhadap benda tersebut[12]. SONAR bekerja dengan cara mengirimkan gelombang akustik melalui perangkat yang disebut transduser. Ketika gelombang yang dikirimkan mengenai suatu objek, maka gelombang tersebut akan dipantulkan kembali yang disebut dengan gema atau echo. Terdapat dua jenis SONAR berdasarkan penerapan kerjanya, yaitu SONAR aktif dan pasif. Perbedaan dari kedua jenis SONAR ini terdapat pada fungsi perangkat transdusernya, untuk SONAR aktif, perangkat transdusernya bekerja sebagai pengirim gelombang sekaligus penerima pantulan gelombangnya. Sedangkan SONAR pasif hanya menerima gelombang suara yang dipancarkan dari sumber suara. Penerapan dan pemanfaatan teknologi SONAR sudah sangat banyak dan bervariasi, seperti navigasi bawah air, mendeteksi kumpulan ikan, pemetaan dasar laut, mendeteksi kapal selam, pencarian kapal tenggelam dan fungsi lainnya. Untuk sistem SONAR yang memancarkan sinyal akustik dari transduser tunggal disebut sebagai *singlebeam echosounder* atau biasa disebut juga echosounder tradisional.


2.1.3.1. Tradisional Echosounder

Tradisional *echosounder* hanya dapat menghasilkan citra dalam bentuk *echogram*. Sinyal transmisi yang dikirim hanya pada satu frekuensi tertentu sehingga hasil *echogram* yang dimuat tidak terlalu detail karena keterbatasan kedalaman dari tiap frekuensi. Misalnya untuk sinyal yang lebih tinggi pada 200 kHz dapat memberikan detail informasi yang lebih baik namun tidak dapat menembus terlalu dalam ke kedalaman air. Sedangkan pada sinyal dengan frekuensi rendah seperti 50 kHz dapat menembus lebih dalam tetapi hanya dapat menampilkan sedikit detail. Hal ini menjadi penyebab mengapa sebagian besar *echosounder* tradisional saat ini

menggunakan setidaknya transduser dengan frekuensi ganda atau bahkan tiga frekuensi untuk memberikan kombinasi kedalaman dan detail yang baik.




Gambar 3. Transmisi Frekuensi Sonar *Singlebeam Echosounder*




Gambar 4. Ilustrasi hasil scan *singlebeam echosounder*

Saat ini pengembangan pada perangkat transduser telah menggunakan teknologi CHIRP (*Compressed High-Intensity Radiated Pulse*) dengan mengirimkan sinyal secara terus menerus menggunakan beberapa rentang frekuensi per ping dari frekuensi rendah ke frekuensi yang lebih tinggi. Teknologi CHIRP pada beberapa jenis transduser ini memungkinkan untuk dapat menghasilkan gambar *echogram* yang lebih jelas, dengan resolusi yang lebih tinggi dan pemisahan target yang lebih baik. Transduser dengan teknologi CHIRP memiliki tiga pita frekuensi kHz yang dipecah antara kelompok yang berbeda: Rendah, Sedang, dan Tinggi.



Gambar 5. Transmisi Frekuensi dengan Teknologi CHIRP




Gambar 6. Ilustrasi hasil scan dengan teknologi CHIRP

CHIRP dengan frekuensi tinggi (150–240 kHz) dapat digunakan pada perairan darat atau air tawar. Transduser CHIRP dengan frekuensi tinggi merupakan pilihan terbaik untuk pelacakan umpan, mengidentifikasi target ikan, atau untuk target objek yang berada dekat struktur dasar perairan. Transduser ini dapat dipakai hingga kedalaman kurang dari 180 meter. Untuk teknologi transduser dengan frekuensi CHIRP sedang (80–160 kHz) dapat memindai lebih cepat dan menampilkan area cakupan yang lebih luas. Untuk objek ikan yang berada pada bagian atas dari struktur dasar perairan dapat ditunjukkan dengan lengkungan yang lebih besar namun memberikan detail yang lebih sedikit daripada CHIRP dengan frekuensi tinggi yang dapat memindai objek yang lebih kecil. Untuk penggunaan pada kedalaman perairan, sama seperti transduser dengan frekuensi CHIRP tinggi, transduser ini sangat baik digunakan untuk kedalaman kurang dari 180 meter. Sedangkan untuk transduser dengan teknologi frekuensi CHIRP rendah (di bawah 80 kHz) digunakan untuk memindai objek target pada perairan dalam yang memiliki kedalaman hingga 3 km.

2.1.3.2. Side Scan Sonar (SSS)

SSS adalah sebuah instrumen berbasis sistem SONAR yang mampu menampilkan citra permukaan dalam bentuk dua dimensi dengan kondisi kontur, topografi, dan target bawah air secara bersamaan. Sistem instrumen ini merupakan strategi penginderaan untuk merekam kondisi dasar air dengan memanfaatkan sifat media dasar air yang mampu memancarkan, memantulkan dan/atau menyerap gelombang suara.




Gambar 7. Proses Side Scan Sonar

SSS menggunakan konsep backscatter akustik dalam menggambarkan bentuk dasar laut atau objek di dasar laut. Material seperti besi, bongkahan, kerikil atau batuan vulkanik sangat efisien dalam merefleksikan sinyal akustik (backscatter kuat). Sedimen halus seperti tanah liat, lumpur tidak dapat merefleksikan sinyal suara dengan baik (backscatter lemah). Elemen dengan tingkat reflektor kuat akan menghasilkan pantulan backscatter yang kuat sedangkan reflektor lemah menghasilkan backscatter yang lemah.

2.1.3.3. Down Scan SONAR


Down Scan SONAR menggunakan frekuensi tinggi untuk menghasilkan gambar yang sangat detail tentang struktur yang ada di bawah air. Beberapa vendor penyedia perangkat *fishfinder* menyediakan hasil scan echosounder dengan teknologi *Down Scan Imaging* dengan menggunakan merek dagang yang berbeda, seperti vendor Humminbird mengeluarkan merek dagang *Down Imaging*, merek Lowrance mengeluarkan dengan merek dagang *DownScan Imaging* (DSI), sementara merek Garmin menyebutnya dengan *DownVü*. Perbedaan utama dari *Down Scan SONAR* dengan *Side Scan SONAR* adalah pada *Down Scan SONAR* menampilkan informasi gambar bawah air secara vertical, sedangkan pada *Side Scan SONAR* menampilkan gambar secara horizontal.



Gambar 8. Perbedaan antara hasil Tradisional SONAR dan Down Scan SONAR

2.1.3.4. Dual frequency IDentffication SONar (DIDSON)

DIDSON adalah jenis sonar yang mentransmisikan sinyal suara dan mengubahnya gema yang kembali menjadi gambar digital seperti sonogram yang bisa dipakai pada bidang medis. Kelebihan dari DIDSON adalah dapat menampilkan gambar bawah air dalam kondisi air yang gelap atau keruh dengan tingkat visibilitas 0.




Gambar 9. Data Hasil citra sonar menggunakan teknologi DIDSON

2.1.4. Convolutional Neural Network (CNN)

CNN merupakan salah satu algoritma dari *deep learning* yang sangat populer digunakan untuk melakukan deteksi dan klasifikasi objek. CNN sendiri adalah jenis *neural networks* yang umumnya digunakan untuk menyelesaikan tugas-tugas visi komputer seperti klasifikasi dan


segmentasi gambar. CNN bekerja dengan cara meniru prinsip kerja jaringan syaraf otak manusia. Arsitektur CNN dapat bervariasi tetapi sebagian besar terdiri dari lapisan *Convolution Layer*, *Activation ReLU Layer*, *Pooling Layer*, dan *Fully Connected Layer*.



Gambar 10. Arsitektur CNN

2.1.4.1. Convolutional Layer


Komputer melihat sebuah gambar sebagai kumpulan angka-angka dalam sebuah matriks, dimana setiap angkanya merupakan penanda intensitas cahaya pada titik tersebut, atau biasa disebut pixel. Gambar yang hanya terdiri dari tingkat kedalaman warna hitam ke putih direpresentasikan menjadi sebuah matriks dengan nilai 0-255, sedangkan gambar yang berwarna akan memiliki tiga buah matriks yang merepresentasikan warna merah, hijau, dan biru atau yang dikenal dengan *Red Green Blue* (RGB), sehingga dalam hal ini ketika komputer membaca sebuah gambar, maka ada 3 parameter yang dilihat yaitu tinggi, lebar, dan kedalaman warnanya (*depth*). Proses konvolusi memanfaatkan 3 parameter ini yang biasanya disebut dengan filter dimana akan diinisialisasi dengan nilai tertentu dan akan berubah nilainya ketika terjadi proses pembelajaran. Pada lapisan konvolusi ini akan menghasilkan gambar baru yang berisi fitur dari gambar yang telah diinputkan. Proses yang terjadi pada lapisan ini adalah konvolusi mengaplikasikan filter pada gambar berupa matriks yang dapat berukuran 1x1, 3x3, atau 5x5. Proses konvolusi ini menghasilkan feature map yang kemudian akan dipergunakan pada saat lapisan aktivasi (Activation Layer).



Gambar 11. Operasi Konvolusi

2.1.4.2. Stride


Stride (s) adalah nilai yang menentukan bagaimana filter dipindahkan di seluruh volume input. Misalnya nilai *stride* adalah 2, artinya proses akan melewati 2 piksel di setiap tahapannya. hal ini akan membuat dimensi output lebih kecil dari dimensi input (*down sampling*).



Gambar 12. Filter dengan nilai stride = 2

2.1.4.3. Padding


Padding (p) biasanya digunakan jika ukuran volume output yang diinginkan sama dengan volume input dimana tidak menggunakan proses *down sampling*. Salah satu cara untuk mencapai ini adalah melalui *zero-padding* atau mengisi batas luar gambar dengan nilai nol sehingga ukuran volume output sesuai dengan volume input.



Gambar 13. Pemberian nilai padding = 1

2.1.4.4. Pooling layer

Pooling layer digunakan untuk mengurangi ukuran representasi (mengurangi jumlah parameter input) dan mempercepat perhitungan dengan operasi down-sampling. Umumnya, metode pooling yang digunakan adalah *max pooling* atau mengambil nilai terbesar dari bagian tersebut. Namun terdapat metode pooling lain yang dapat digunakan seperti *average pooling* atau *L2-norm pooling*.




Gambar 14. Perbedaan metode Max pooling dan Avg pooling

2.1.4.5. Fully Connected layer

Fully connected layer adalah lapisan dimana semua neuron aktivitas dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan syaraf tiruan biasa. Setiap aktivitas dari lapisan sebelumnya perlu diubah menjadi data yang berbentuk satu dimensi sebelum dapat dihubungkan ke semua neuron di lapisan *fully connected*. Perbedaan antara *fully connected layer* dan *convolutional layer* adalah pada neuron dilapisan


konvolusi terhubung hanya ke daerah tertentu pada input. Sementara *fully connected layer* memiliki neuron yang terhubung secara keseluruhan.



Gambar 15. Ilustrasi Fully Connected Layer

2.1.4.6. Activation Function

Fungsi aktivasi berada pada tahapan sebelum melakukan *pooling layer* dan setelah melakukan proses konvolusi. Terdapat beberapa fungsi aktivasi yang sering digunakan pada *convolutional network*, di antaranya $\tanh()$ atau $reLU$, namun yang sering menjadi pilihan dalam penggunaan adalah aktivasi $reLU$. Fungsi $reLU$ adalah nilai output dari neuron dapat dinyatakan sebagai 0 jika inputnya adalah negatif. Jika nilai input dari fungsi aktivasi adalah positif, maka output dari neuron adalah nilai input aktivasi itu sendiri.



Gambar 16. Fungsi Aktivasi

2.1.4.7. Softmax Function

Softmax merupakan fungsi aktivasi yang digunakan pada layer output. Layer output memiliki banyak kesamaan dengan *fully connected layer*, yang membedakan kedua layer ini adalah penggunaan fungsi aktivasi *softmax* pada layer output dan fungsi aktivasi *ReLU* pada *fully connected layer*. Fungsi aktivasi *softmax* digunakan untuk menghitung probabilitas pada hasil output dimana akan diambil nilai probabilitas paling besar sebagai prediksi. *Softmax* digunakan


untuk menghitung probabilitas distribusi dari vektor bilangan real. Fungsi softmax menghasilkan output yang merupakan kisaran nilai antara 0 dan 1, dengan jumlah probabilitas sama dengan 1.

$$\text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

Gambar 17. Fungsi Aktivasi Softmax

2.1.5. Region based Convolutional Neural Network (R-CNN)


Pada CNN, permasalahan dengan menggunakan teknik *sliding window* adalah banyaknya potongan-potongan gambar yang harus diproses oleh CNN. Setiap potongan tersebut akan melalui proses konvolusi, untuk kemudian diklasifikasikan menjadi background atau objek. Hal ini akan menyebabkan proses komputasi akan sangat berat dikarenakan banyaknya lokasi gambar serta ukuran sliding window yang digunakan. Untuk mengatasi masalah ini, digunakan metode R-CNN dimana tahapan pada metode ini dimulai dengan mencari region atau bagian gambar yang mungkin merupakan sebuah objek, dengan menggunakan teknik region proposal seperti *selective search*. Setelah ditentukan region pada gambar, selanjutnya setiap region tersebut kemudian dijadikan input untuk CNN sebagai *feature extractors* dari tiap region tersebut. setiap fitur-fitur yang dihasilkan, kemudian menjadi input untuk metode yang akan dipakai menghasilkan kelas dari region tersebut dan yang akan menghasilkan bounding box.



Gambar 18. Arsitektur R-CNN

2.1.6. Faster Region based Convolutional Neural Network (Faster R-CNN)


Permasalahan berikutnya pada metode R-CNN adalah pada proses training yang memiliki banyak kendala dimana sebelum proses training dilakukan, penentuan region harus dapat dikeluarkan. Selain itu, proses training nantinya akan dilakukan untuk metode CNN dan juga perlu melakukan training untuk metode yang digunakan untuk menghasilkan kelas objek. Permasalahan ini kemudian dapat diatasi dengan metode Fast R-CNN. Alur kerja dari Fast R-CNN sedikit berbeda dari sebelumnya, dimana bila sebelumnya tiap region-region dari *region proposal method* dalam hal ini menggunakan *Selective Search* akan memiliki proses CNN untuk *feature extraction* masing-masing, Fast R-CNN hanya menggunakan satu CNN. *Feature map* yang dihasilkan kemudian akan dicocokkan dengan ROI yang didapat dari *Selective Search* tadi, untuk kemudian diklasifikasi kelasnya dan dideteksi serta diberikan bounding box. Dengan kata lain, Fast R-CNN melakukan *feature extraction* sebelum mengajukan penentuan region.



Gambar 19. Arsitektur Fast R-CNN


2.1.6.1. Region Proposal Network (RPN)

RPN yaitu proses pencarian secara cepat kemungkinan lokasi objek dari suatu input gambar. Posisi kemungkinan objek dalam gambar kemudian diberi *boundary* dan ditandai sebagai *region of interest* (ROI). RPN kemudian mengambil sub-citra dari ROI dengan berbagai ukuran sebagai input ke dalam jaringan CNN dengan output kumpulan persegi panjang dengan skor kemiripan objek.



Gambar 20. Region Proposal Network

Penggunaan *region proposal method* seperti *Selective Search* masih menjadi permasalahan dalam proses deteksi objek menggunakan R-CNN, karena metode seperti ini membutuhkan waktu yang relatif lama untuk menghasilkan region. Metode Faster R-CNN kemudian dibuat untuk mencoba menyelesaikan masalah *region proposal method* dengan menggunakan konsep RPN. RPN akan menggantikan peran *Selective Search* untuk mengajukan region dimana nantinya akan menghasilkan beberapa bounding box, setiap box memiliki 2 skor probabilitas apakah pada lokasi tersebut terdapat objek atau tidak. Region-region yang dihasilkan tersebut akan menjadi input untuk arsitektur yang mirip seperti Fast R-CNN.



Gambar 21. Arsitektur Faster R-CNN

2.1.6.2. *Library Pytorch*

PyTorch(Paszke et al., 2019) adalah sebuah *framework open source* untuk *machine learning* dan *deep learning* yang dikembangkan oleh *Facebook's AI Research Lab* (FAIR). diperkenalkan pada tahun 2016, PyTorch telah menjadi salah satu *library* paling populer untuk membangun dan melatih model *neural network* karena kemudahan penggunaan dan fleksibilitasnya. PyTorch menyediakan objek utama bernama Tensor, yang mirip dengan array NumPy tetapi memiliki dukungan untuk operasi GPU. Hal ini membuat komputasi menjadi sangat cepat dan efisien. PyTorch menyediakan berbagai model pre-trained yang dapat digunakan untuk berbagai tugas, seperti klasifikasi gambar, deteksi objek, segmentasi, dan lain-lain.

Untuk tujuan klasifikasi gambar, model pre-trained yang tersedia di PyTorch adalah *Model Residual Networks* (ResNet) terdiri dari berbagai varian seperti ResNet-18, ResNet-34, ResNet-50, ResNet-101, dan ResNet-152. ResNet dikenal karena arsitektur deep-nya dengan *shortcut connections*. Selain model ResNet, terdapat juga model *Visual Geometry Group* (VGG) terdiri dari dua varian utama, VGG-16 dan VGG-19. Model selanjutnya yang terdapat pada PyTorch adalah Model Inception (GoogLeNet) menggunakan modul Inception yang memungkinkan penggunaan filter dengan ukuran berbeda secara paralel. Kemudian ada juga Model MobileNet yang dirancang untuk efisiensi pada perangkat mobile, dengan varian seperti MobileNetV2 dan MobileNetV3. Pada PyTorch terdapat juga model DenseNet dan model EfficientNet. Model DenseNet terdiri dari beberapa varian seperti DenseNet-121, DenseNet-169, DenseNet-201, dan DenseNet-161. Sedangkan model EfficientNet menggunakan teknik scaling yang efisien dan memiliki beberapa varian seperti EfficientNet-B0 hingga EfficientNet-B7.

Untuk tujuan deteksi objek, Pytorch mendukung beberapa model seperti Faster R-CNN dengan beberapa pilihan *backbone* seperti ResNet-50 dan ResNet-101. Pytorch juga menyediakan model RetinaNet yang menggunakan Focal Loss untuk menangani ketidakseimbangan antara jumlah objek dan latar belakang. selanjutnya pada Pytorch terdapat juga *Single Shot MultiBox Detector* (SSD) dengan beberapa varian *backbone* seperti MobileNetV2.

2.1.7. You Only Look Once (YOLO)

Perkembangan deteksi objek berbasis *deep learning* saat ini secara umum diklasifikasikan ke dalam dua kelompok yaitu deteksi objek dalam dua tahapan dan deteksi objek dalam satu tahap (Sohan et al., 2024). Deteksi objek dalam dua tahapan, seperti Region-based CNN (R-CNN) dan variannya secara proses pada tahapan pertama menghasilkan proposal objek dan tahap selanjutnya kemudian mengklasifikasikan setiap proposal. Untuk Deteksi objek dalam satu tahap, seperti YOLO dan variannya, secara langsung memprediksi keberadaan dan lokasi objek dalam satu langkah.

YOLOv1 diusulkan oleh Joseph Redmon et al. pada tahun 2015 (Redmon et al., 2016), merupakan model deteksi objek satu tahap yang menggunakan jaringan saraf konvolusional tunggal untuk memprediksi kelas objek dan kotak pembatas secara langsung dari gambar. Pada penelitian tersebut dilakukan dengan membagi gambar menjadi *grid* sel dan memprediksi beberapa kotak pembatas dan kelas objek untuk setiap sel. Keterbatasan dari YOLOv1 adalah kinerjanya yang buruk pada objek kecil.

YOLOv2 diusulkan oleh Joseph Redmon dan Ali Farhadi pada tahun 2017 (Redmon & Farhadi, 2017), merupakan penyempurnaan dari YOLOv1 yang mengatasi keterbatasannya. Penelitian ini memperkenalkan kotak jangkar dan normalisasi batch untuk meningkatkan akurasi deteksi objek. Kotak jangkar digunakan untuk menangani objek dengan lebih baik pada skala dan rasio aspek yang berbeda, sementara normalisasi batch meningkatkan stabilitas jaringan selama pelatihan.

Pada tahun 2018, Joseph Redmon dan Ali Farhadi mengusulkan YOLOv3 (Redmon & Farhadi, 2018). YOLOv3 merupakan peningkatan lebih lanjut dari YOLOv2 yang memperkenalkan sejumlah perubahan untuk meningkatkan akurasi dan kecepatan. YOLOv3 menggunakan fitur jaringan piramida dan memprediksi kategori objek dan kotak pembatas pada tiga skala berbeda yang tujuannya untuk menangani objek dengan ukuran yang berbeda dengan lebih baik dari pada versi sebelumnya. YOLOv3 juga memperkenalkan teknik baru seperti pelatihan multi-skala dan penugasan jangkar dinamis untuk meningkatkan akurasi deteksi objek.

Dirilis pada April 2020, YOLOv4 (Bochkovskiy et al., 2020) dikembangkan untuk meningkatkan kinerja pendahulunya, YOLOv3, dengan meningkatkan kecepatan dan akurasi.


YOLOv4 dirancang agar dapat diakses untuk pelatihan pada GPU tunggal dan menggunakan CspDarkNet53 sebagai *backbone* yang merupakan peningkatan dari Darknet-53. Perubahan ini membantu ekstraksi fitur yang lebih baik dan meningkatkan kinerja model. YOLOv4 menggabungkan berbagai teknik untuk meningkatkan pelatihan dan inferensi tanpa meningkatkan biaya komputasi termasuk teknik augmentasi data, seperti Mosaic dan CutMix, dan metode seperti *CIoU loss* untuk regresi kotak pembatas yang lebih baik.

YOLOv5 diperkenalkan oleh Glenn Jocher dan tim pada tahun 2020 (J. Li & Hua, 2023), membawa beberapa kemajuan dibandingkan YOLOv3. YOLOv5 menggunakan arsitektur *novel backbone* yang meningkatkan ekstraksi fitur untuk kinerja deteksi objek yang lebih baik. Arsitektur ini dirancang agar lebih efisien, memungkinkan waktu pemrosesan yang lebih cepat. YOLOv5 memperkenalkan teknik seperti *focal loss*, *label smoothing*, dan *auto-augmentation* untuk meningkatkan akurasi. Arsitektur ini juga memperkenalkan teknik pelatihan seperti augmentasi data *CutMix* dan *learning rate schedulers* untuk meningkatkan laju konvergensi jaringan.

YOLOv6 dikembangkan oleh Chuyi Li dan tim pada tahun 2022 (C. Li et al., 2022). YOLOv6 dirancang khusus untuk aplikasi industri, dengan fokus pada pencapaian efisiensi dan kinerja tinggi. YOLOv6 menggunakan *backbone EfficientRep*, yang meningkatkan kemampuan model untuk mengekstrak fitur dari gambar. YOLOv6 juga menggunakan teknik seperti SimOTA (Simulated Optimal Transport Assignment) untuk penetapan tag, yang mengoptimalkan proses pencocokan antara kotak kebenaran yang diprediksi dan dasar. Teknik ini meningkatkan presisi model dalam mendeteksi objek. YOLOv6 menggunakan *SIoU (Smooth Intersection over Union) box regression loss* untuk meningkatkan akurasi prediksi kotak pembatas. Fungsi *box regression loss* ini membantu dalam menyempurnakan kotak yang diprediksi agar lebih cocok dengan batas objek aktual.

YOLOv7 diusulkan oleh Chien-Yao Wang dan Alexey Bochkovskiy pada tahun 2022 (C.-Y. Wang et al., 2022), merupakan penyempurnaan dari model sebelumnya Scaled-YOLOv4 dan YOLOR yang didasarkan pada YOLOv4. YOLOv7 memperkenalkan *E-ELAN (Extended Efficient Layer Aggregation Network)*, yang meningkatkan kemampuan model untuk belajar dan menggeneralisasi dari data.

YOLOv8 dikembangkan oleh Ultralytics dan diperkenalkan pada 10 Januari 2023 (Jocher et al., 2023; YOLOv8 - Ultralytics YOLO Docs, n.d.), dirancang untuk mendeteksi objek, mengklasifikasikan gambar, dan membedakan objek satu sama lain. YOLOv8 menggabungkan banyak peningkatan yang membuatnya lebih baik daripada pendahulunya YOLOv5. Perbaikan ini termasuk jaringan *backbone* yang dimodifikasi, *anchor-free detection head*, dan fungsi *loss* baru. YOLOv8 menggunakan pendekatan *anchor-free detection*, mirip dengan YOLOv6 dan YOLOv7. Metode ini memprediksi pusat objek secara langsung, daripada mengandalkan kotak jangkar. Perubahan ini mengurangi jumlah prediksi kotak dan mempercepat proses Non-Maximum Suppression (NMS), meningkatkan efisiensi secara keseluruhan. Arsitektur YOLOv8 mencakup lapisan konvolusi baru yang disebut C2f, yang menggantikan lapisan C3 yang digunakan di YOLOv5. Lapisan C2f menggabungkan output dari semua lapisan Bottleneck, tidak seperti lapisan C3, yang hanya menggunakan output dari lapisan Bottleneck terakhir. Modifikasi ini memungkinkan ekstraksi fitur yang lebih baik dan berkontribusi pada peningkatan kinerja model. Pada YOLOv8, ukuran kernel lapisan konvolusi pertama di bottleneck telah ditingkatkan dari 1x1 menjadi 3x3. Penyesuaian ini mirip dengan blok ResNet dan meningkatkan kemampuan model untuk menangkap fitur pada skala dan resolusi yang berbeda.



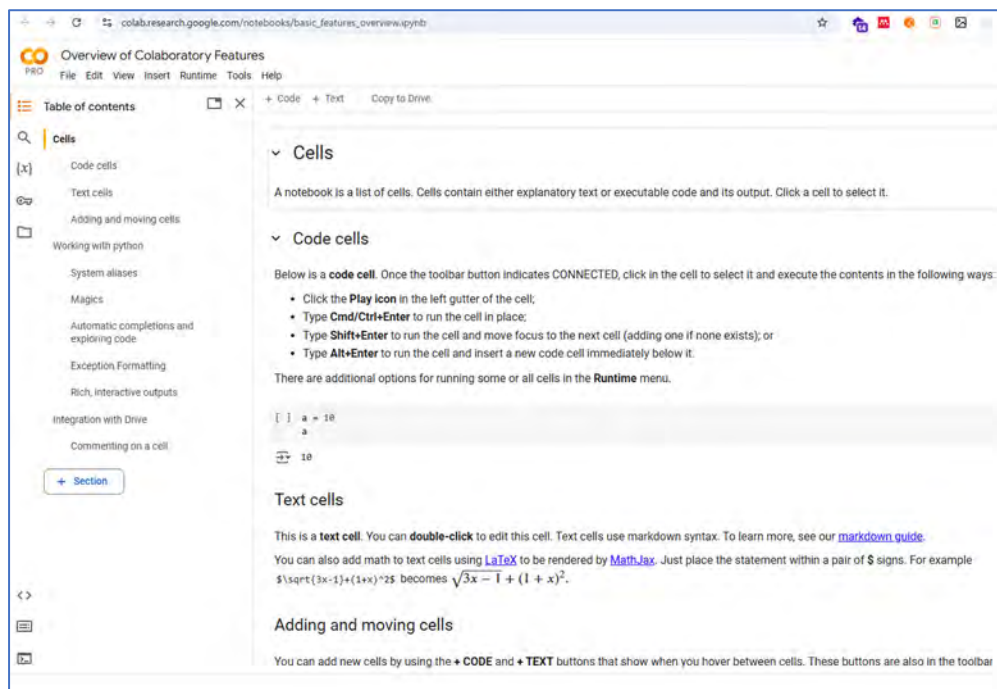
Gambar 22. Arsitektur YOLOv8 (Ju & Cai, 2023)

2.1.8. Depth Map

Banyak tugas visi komputer dapat memperoleh manfaat dari informasi kedalaman gambar, seperti deteksi, klasifikasi, dan segmentasi semantik (Yan et al., 2018). *Depth Map* adalah representasi visual yang menunjukkan jarak relatif dari permukaan objek dalam suatu gambar, di mana setiap piksel dalam citra grayscale mewakili kedalaman objek, dengan nilai yang lebih terang menunjukkan objek yang lebih dekat dan nilai yang lebih gelap menunjukkan objek yang lebih jauh.


2.1.9. Google Colaboratory

Google Colaboratory, sering disebut sebagai Colab, adalah platform berbasis cloud yang menyediakan lingkungan *notebook Jupyter* (Sukhdeve & Sukhdeve, 2023). Platform *Google Colab* memungkinkan pengguna untuk menulis dan mengeksekusi kode Python melalui browser web tanpa perlu pengaturan lokal komputer. *Google Colab* disediakan secara bebas oleh Google, sehingga dapat diakses oleh berbagai pengguna. Layanan ini terintegrasi langsung dengan layanan *Google Cloud Platform* (GCP), meningkatkan fungsionalitas dan kemudahan penggunaannya. *Google Colab* dapat diakses pada alamat <https://colab.research.google.com>



Gambar 23. Antarmuka Google Colab pada browser

Google Colab mendukung komputasi *Graphical Processing Unit* (GPU) dan *Tensor Processing Unit* (TPU), yang sangat bermanfaat untuk tugas-tugas yang membutuhkan daya komputasi yang signifikan, seperti pembelajaran mesin dan analisis data. *Google Colab* dilengkapi dengan *tools* dan *library* pembelajaran mesin seperti TensorFlow, Keras, dan scikit-learn. Platform ini mendukung *library* seperti Matplotlib dan Seaborn untuk melakukan berbagai manipulasi data, visualisasi data, dan memungkinkan impor dan ekspor data dengan mudah ke dan dari *Google Drive*. Hal ini menjadikan *Google Colab* sebagai platform yang dapat digunakan untuk membangun dan menjalankan model pembelajaran mesin.



Gambar 24. Pilihan penggunaan Hardware Accelerator pada Google Colab Pro

2.2. Metode Penyelesaian Masalah

2.2.1. State of The Art Penelitian

Tabel 1. State of The Art

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
----	--------------------	------------------------	---------------------	---------

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
1	Judul: Deteksi Perkembangan Udang Vaname Pada Sistem Bioflok dengan menggunakan data Sonar Penulis: Dwi Bagus Fitriyanto Tahun: 2022	Objek: Objek udang pada citra hasil sonar Permasalahan: Bagaimana mendeteksi objek udang pada kondisi air keruh dengan memanfaatkan citra hasil sonar	menggunakan depth map, Faster R-CNN	
2	Judul: A Robust and Fast Method for Sidescan Sonar Image Segmentation Based on Region Growing Penulis: Xuyang Wang, Luyu Wang, Guolin Li, Xiang Xie Tahun: 2021	Objek: seabed Permasalahan: melakukan segmentasi object secara unsupervised	menggunakan metode RGLT yaitu algoritma berdasarkan pertumbuhan wilayah dan karakteristik distribusi statistik apriori	Akurasi rata-rata dari metode segmentasi yang diusulkan untuk 100 × 400 gambar secara terpisah 95,90%

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
3	Judul: Detection of small objects in sidescan sonar images based on POHMT and Tsallis entropy Penulis: Liyang Zheng , Kai Tian Tahun: 2017	Objek: batu, ranjau, dan puing-puing Permasalahan: mendeteksi objek kecil menggunakan citra side scan sonar	menggunakan metode Percentage Occupancy Hit-or-Miss Transform (POHMT) dan entropi Tsallis	rata-rata tingkat deteksi dari metode yang diusulkan Untuk kelompok pertama masing-masing sekitar 86,42%
4	Judul: Environmental effects on seabed object bistatic scattering classification Penulis: Erin M. Fischell, Henrik Schmidt Tahun: 2017	Objek: target objek berbentuk bola dan silinder Permasalahan: komposisi lapisan dasar air untuk deteksi objek yang terbenam	menggunakan model klasifikasi SVM	kinerja dengan mengukur dalam 4 kategori kondisi objek: diatas sedimen, terbenam 25%, terbenam 50%, dan terbenam 100%. Kemudian dari level tinggi sedimen. Kombinasi dari 2 kondisi tersebut menghasilkan tingkat akurasi terbaik pada 96,4% dengan kategori

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
				kondisi tinggi sediman lebih dari 0.25 m - 1 m
5	Judul: Side Scan Sonar Images Based Ocean Bottom Sediment Classification Penulis: G. Annalakshmi,S. Sakthivel Murugan, K.Ramasundaram Tahun: 2019	Objek: ocean bottom sediment Permasalahan: fitur geologi dasar laut dan komposisi dari endapan sedimen dasar laut	menggunakan Support Vector Machine (SVM)	hasil pengukuran menggunakan LDR dan SR mendapatkan rate akurasi sebesar 83.4%
6	Judul: Target detection in sonar image based on faster RCNN Penulis: Fang Jie, Wang Pingbo Tahun:	Objek: echo sonar signal target data Permasalahan: ekstraksi fitur dari data echogram	menggunakan algoritma Faster R-CNN dan perbandingan fitur ekstraksi menggunakan AlexNET, GoogleNET, dan ResNET	penggunaan model Faster R-CNN dengan fitur ekstraksi AlexNet menghasilkan tingkat akurasi sebesar 86%

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
	2020			
7	Judul: Estimating shrimp body length using deep convolutional neural network Penulis: Hong-Yang Lina, Hsin-Chen Leea, Woei-Ling Ngb, Jyh-Nain Paic, Yuan-Nan Chua, Chyng-Hwa Lioub, Kuo-Chi Liaoa, Yan-Fu Kuoa Tahun: 2019	Objek: Udang Permasalahan: mengidentifikasi panjang badan udang	menggunakan YOLOv3 dan ekstraksi fitur Darknet-53	pengukuran menggunakan mean average precision (mAP) dan menghasilkan 85.08%
8	Judul: Baby Shrimp Counting via Automated Image Processing Penulis: Ramil Kesvarakul, Chamaporn Chianrabutra, Srisit Chianrabutra	Objek: bayi udang vanamei Permasalahan: menghitung jumlah benih udang dalam satu wadah	menggunakan algoritma blob detection	pengukuran menggunakan relative error yang menghasilkan tingkat akurasi sebesar 98%

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
	Tahun: 2017			
9	Judul: Seabed Sediment Classification of Side-scan Sonar Data Using Convolutional Neural Networks Penulis: Tim Berthold, Artem Leichter, Bodo Rosenhahn, Volker Berkhahn, Jennifer Valerius Tahun: 2017	Objek: sedimen bawah air Permasalahan: tekstur sedimen bawah air	menggunakan CNN	rata-rata tingkat akurasi pasir = 83 % sedimen halus = 11% sedimen kasar = 70% sedimen campuran = 61%

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
10	Judul: CNN Transfer Learning of Shrimp Detection for Underwater Vision System Penulis: Iza Sazanita Isa, Nor Nabilah Norzrin, Siti Noraini Sulaiman, Nur Azah Hamzaid, Mohd Ikmal Fitri Maruzuki Tahun: 2020	Objek: udang Permasalahan: deteksi objek udang	menggunakan Faster RCNN dan Inception V2	diukur menggunakan OA = 96%
11	Judul: Detecting Leftover Food and the Shrimp for Estimating of the Shrimp Body Length Based on CNN Penulis: Van Quy Hoang, Dinh Cong Nguyen Tahun:	Objek: Udang Permasalahan: mengidentifikasi udang dan sisa makanan serta mengukur panjang tubuh udang	menggunakan arsitektur YOLOv4	YOLOv3 deteksi udang dan sisa makanan, mAP = 79.3 % YOLOv4 deteksi udang dan sisa makanan, mAP = 87.3 %

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
	2021			
12	Judul: Acoustic classification in multifrequency echosounder data using deep convolutional neural networks Penulis: Olav Brautaset, Anders Ueland Waldeland, Espen Johnsen, Ketil Malde, Line Eikvil, Arnt-Børre Salberg, Nils Olav Handegard Tahun: 2020	Objek: fish school Permasalahan: mendeteksi jenis gerombolan ikan	menggunakan CNN dan arsitektur U-Net	kelas data dikategorikan menjadi 6 kelas. Kinerja diukur menggunakan F1 score dimana didapat nilai sebesar 0,87 untuk membedakan kelas tersebut, dan nilai F1 score 0,94 untuk membedakan sandeel school dan gerombolan bukan sandeel school

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
13	Judul: Classification of Southern Ocean krill and icefish echoes using random forests Penulis: Niall G. Fallon, Sophie Fielding, Paul G. Fernandes Tahun: 2016	Objek: Mackerel icefish, Krill, Mix Permasalahan: mendeteksi jenis ikan Mackerel icefish, Kril, dan gabungan ikan	menggunakan algoritma random forest	estimasi akurasi secara keseluruhan yang didapat sebesar 95%
14	Judul: Detecting Marine Species in Echograms via Traditional, Hybrid, and Deep Learning Frameworks Penulis: Tunai Porto Marques, Alireza Rezvanifar, Melissa Cote, Alexandra Branzan Albu, Kaan Ersahin, Todd Mudge, Stephane	Objek: <i>schools of herring</i> Permasalahan: mendeteksi spesies laut dalam bentuk echogram	SVM, ResNet-50, DenseNet-201, InceptionV3, YOLOv2, Faster R-CNN	diukur menggunakan nilai precision (P), recall (R), dan F1 score. Untuk nilai P tertinggi dengan menggunakan metode InceptionV3 sebesar 78.99, untuk nilai R tertinggi dengan menggunakan metode YOLOv2 sebesar 89.06, dan nilai F1 tertinggi menggunakan

No	Judul Karya Ilmiah	Objek dan Permasalahan	Metode Penyelesaian	Kinerja
	Gauthier Tahun: 2021			metode InceptionV3 sebesar 81.95
15	Judul: Automatic Bluefin Tuna (Thunnus thynnus) biomass estimation during transfers using acoustic and computer vision techniques Penulis: V. Puig-Ponsa, P. Muñoz-Benavent, V. Espinosa, G. Andreu-García, José M. Valiente-González, V.D. Estruch, P. Ordóñez, I. Pérez-Arjona, V. Atienza, B. Mèlich, F. de la Gándara, E. Santaella Tahun: 2017	Objek: bluefin tuna Permasalahan: estimasi biomass	menggunakan metode otsu, local thresholding, dan edge detection	Hasil penghitungan tuna dengan tingkat kesalahan di bawah 10%, dan presisi ukuran tuna lebih dari 20%.

Pemanfaatan sinyal sonar untuk melakukan proses segmentasi pada penelitian sebelumnya lebih banyak dilakukan pada area laut dan sungai.

Xuyang Wang et. al (X. Wang et al., 2021) melakukan penelitian untuk melakukan segmentasi pada gambar side scan sonar dengan meningkatkan SNR dan menghilangkan noise bintik dengan menerapkan standard deviation filtering (STDF) pada pre-processing filtering, kemudian menggunakan segmentasi berbasis region grow untuk mengurangi waktu segmentasi dan meningkatkan akurasi segmentasi. Eksperimen dilakukan pada tiga database sonar, yang menunjukkan bahwa RGLT telah meningkatkan metrik kuantitatif secara signifikan seperti akurasi, kecepatan, dan segmentasi efek visual. Akurasi rata-rata dan waktu berjalan dari metode segmentasi yang diusulkan untuk gambar dengan ukuran 100×400 piksel secara terpisah adalah 95,90% dan membutuhkan waktu selama 0,44 detik.

Fokus penelitian yang dilakukan oleh Liying Zheng et. al (Zheng & Tian, 2018) yaitu pada proses mendeteksi objek kecil pada gambar side scan sonar dimana objek terdapat bayangan. penelitian ini mengusulkan menggunakan Percentage Occupancy Hit-or-Miss Transform (POHMT) dan entropi Tsallis. POHMT diadopsi untuk meningkatkan piksel objek kecil yang redup dan entropi Tsallis digunakan untuk menentukan ambang batas POHMT yang optimal. tingkat deteksi rata-rata dari metode yang diusulkan sebesar 86,42%.

Erin M. Fischell et. al. (Fischell & Schmidt, 2017) mencoba melakukan klasifikasi lingkungan untuk dapat mendeteksi objek yang terkubur dibawah komposisi dasar air menggunakan machine learning. objek yang diujicoba berbentuk bola dan silinder yang terkubur pada komposisi dasar berupa lumpur dan pasir yang berada pada kedalaman 6 meter. objek dicoba deteksi dengan 4 kondisi yaitu objek diatas komposisi dasar, objek terkubur 25%, objek terkubur 50%, dan objek terkubur secara keseluruhan dimensi. data yang digunakan berupa data bistatic scattering dimana akan menggunakan SVM untuk melakukan klasifikasi hasil deteksi.

Pada penelitian yang dilakukan oleh G. Annalakshmi et. al. (Annalakshmi et al., 2019) tahapan dimulai dengan pre-processing untuk meningkatkan resolusi gambar side scan sonar akibat proses scattering dan hilangnya sinyal akustik. Untuk meningkatkan fitur tekstur gambar side scan sonar, teknik Super Resolution (SR) diterapkan menggunakan metode interpolasi. Kemudian fitur tekstur dari gambar yang telah ditingkatkan resolusinya diekstraksi

menggunakan Local Binary Pattern (LBP), Local Directional Pattern (LDP) dan Local Ternary Pattern (LTD). terakhir pada proses klasifikasi dengan menggunakan Support Vector Machine (SVM). LDP dengan SR menunjukkan tingkat akurasi yang lebih tinggi yaitu 83,4% dibandingkan dengan metode lainnya.

Fang Jie et. al. (Jie & Pingbo, 2020) mengusulkan metode deteksi menggunakan Faster RCNN dengan melakukan perbandingan pada ekstraksi fitur dari AlexNet, GoogleNet, dan ResNet. optimasi yang dilakukan pada nilai parameter ukuran batch dari region proposal adalah 256 dan ukuran dimensi pada tahap deteksi adalah 128. diujicoba pada nilai dropout dari 0,2 hingga 0,8 dan didapatkan maksimum mean Average Precision (mAP) pada nilai dropout 0,5 pada ekstraksi fitur menggunakan AlexNet dibandingkan GoogleNet dan ResNet.

Hong-Yang Lin et. al. (Lin et al., 2019) mengusulkan metode otomatis untuk mengestimasi panjang udang menggunakan kamera bawah air. model YOLOv3 dipakai dengan fitur ekstraksi menggunakan darknet-53. tahapan estimasi panjang tubuh udang dimulai dari potongan gambar udang yang terdeteksi oleh model YOLOv3. Area tersebut diburamkan menggunakan filter median 7×7 piksel. kemudian algoritma MSR digunakan untuk menghilangkan pengaruh pencahayaan yang tidak merata pada gambar. selanjutnya kontras area ditingkatkan menggunakan koreksi gamma dengan kekuatan 4,5 dan dilanjutkan dengan pemrosesan gambar menjadi gambar biner menggunakan metode otsu. Objek di area biner kemudian diidentifikasi menggunakan pelabelan dan objek dengan jumlah piksel terbesar kemudian ditentukan sebagai udang. objek kemudian diberikan kotak pembatas persegi panjang dari area minimum yang melingkupi objek udang dan estimasi panjang tubuh udang ditentukan berdasarkan panjang sisi kotak pembatas.

Pada penelitian yang dilakukan oleh Ramil Kesvaraku et. al. (Kesvarakul et al., 2017) bertujuan untuk melakukan perhitungan bayi udang. data berupa gambar berwarna 1920x1080 piksel. data diambil pada kotak cahaya untuk menghindari titik terang dari target jika menggunakan teknik direct light. gambar dikonversi ke tipe data biner, kemudian dengan menggunakan algoritma blob detection untuk mendeteksi perbedaan parameter warna di dalam area pada citra digital.

Tim Berthold et. al (Berthold et al., 2017) melakukan penelitian untuk mengklasifikasi sedimen pada dasar air dengan menggunakan gambar side scan sonar. hasil klasifikasi dibedakan

menjadi 4 kelas yaitu halus, pasir, kasar, dan sedimen campuran. proses deteksi menggunakan CNN. rata-rata akurasi yang didapat tertinggi adalah pasir dengan tingkat akurasi 83% dan untuk sedimen halus 11%.

Iza Sazanita Isa et. al. (Isa et al., 2020) menggunakan data citra udang yang didapat dari dataset yang dikumpulkan dan diunduh secara acak dari berbagai sumber dalam gambar RGB dan skala abu-abu dengan format file yang berbeda. gambar kemudian diresize pada ukuran 300x300 dan diconvert menjadi gambar jpg. Kumpulan data dengan rasio pemisahan 80:10:10 secara kasar dibagi menjadi set pelatihan, validasi, dan pengujian. proses pelabelan data dilakukan pada gambar dan selanjutnya digunakan algoritma faster RCNN untuk pengenalan. metode Inception V2 digunakan untuk meminimalkan kesulitan jaringan konvolusi dengan menerapkan konvolusi 3x3 untuk mempercepat proses komputasi. Hasilnya menunjukkan model yang diusulkan dapat berhasil mendeteksi udang dengan akurasi lebih dari 95%.

Olav Brautaset et. al. (Brautaset et al., 2020) mencoba untuk melakukan klasifikasi gerobolan ikan sandel dengan gerombolan spesies lain. data yang digunakan adalah data gambar echogram dari echosounder. dataset dikumpulkan dari hasil survey sejak tahun 2007 sampai dengan 2018 sejumlah jumlah anotasi sandeel school sebesar 20.405. kelas yang dibuat dikategorikan menjadi 6 kelas yaitu background, seabed, sandeel, other, seabed+sandeel, dan seabed+other. pada proses training data dipisah dan dipotong kedalam ukuran 4x256x256 pixel. kemudian dilakukan segmentasi menggunakan arsitektur U-Net.

Penelitian Tunai Porto Marques et. al. (Marques et al., 2021) melakukan perbandingan metode tradisional, hybrid, dan deep learning untuk mendeteksi spesies laut dengan menggunakan citra echogram. metode tradisional dilakukan dengan pendekatan mengembangkan ekstraksi ROI dan melakukan ekstraksi fitur menggunakan SVM. untuk metode hybrid, klasifikasi setiap ROI dilakukan menggunakan fitur visual yang dipelajari secara mandiri dan diekstraksi dengan sistem klasifikasi gambar berbasis CNN yang telah dilatih sebelumnya dalam hal ini menggunakan ResNet, DenseNet, dan Inception. dan metode perbandingan berikutnya menggunakan framework YOLO dan Faster RCNN. hasil akhir diukur menggunakan nilai precision (P), recall (R), dan F1 score. Untuk nilai P tertinggi dengan menggunakan metode InceptionV3 sebesar 78.99, untuk nilai R tertinggi dengan menggunakan metode YOLOv2 sebesar 89.06, dan nilai F1 tertinggi menggunakan metode InceptionV3 sebesar 81.95.

V. Puig-Pons et.al. (Puig-Pons et al., 2019) melakukan penelitian dengan menggunakan teknik akustik dan visi komputer untuk estimasi biomassa ikan tuna. digunakan citra side scan sonar dan kamera stereo yang diposisikan menghadap ke permukaan untuk merekam aspek perut ikan. Jumlah tuna diestimasi dari citra echogram menggunakan metode otsu dan Savitzky-Golay filter, sedangkan ukuran tuna dihitung dari video stereo menggunakan local thresholding dan algoritma edge detection.

2.2.2. Metode yang Diusulkan

Berdasarkan tabel *State of The Art*, terdapat beberapa potensi metode yang dapat digunakan untuk menjadi solusi terkait permasalahan yang diangkat. Pada penelitian ini akan menggunakan algoritma Faster R-CNN. Pada tahapan pre-processing, akan digunakan peningkatan warna objek dengan Depth Map. Data kemudian akan ditraining menggunakan 3 algoritma berbeda untuk dibandingkan tingkat akurasi dalam mendeteksi udang. Untuk kelas udang yang akan digunakan pada data latih dikategorikan dalam 3 kelas yaitu *single shrimp*, *multiple shrimp*, *goups shrim*.

2.2.3. Tingkat Keaslian (Level Orosinalitas) Topik Penelitian yang Diusulkan

Pengembangan dari model yang diusulkan berdasarkan beberapa referensi metode yang ada pada *State of The Art* ditunjukkan dalam tabel berikut:

Tabel 2. Tabel Referensi dan Metode yang diusulkan

No.	Metode Penyelesaian																					
Ref	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V
1	•					•				•	•											
2		•	•																			
3				•	•																	
4						•																
5						•	•	•	•	•	•											
6	•												•									
7												•		•								
8															•							

No.	Metode Penyelesaian																					
Ref	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V
9																•						
10	•																•					
11												•										
12																•		•				
13																			•			
14	`					•						•					•					
15																				•	•	•

Keterangan:

Nomor Referensi:

1	Deteksi Perkembangan Udang Vaname Pada Sistem Bioflok Menggunakan Data Sonar (Topik yang diusulkan)
2	<i>A Robust and Fast Method for Sidescan Sonar Image Segmentation Based on Region Growing</i>
3	<i>Detection of small objects in sidescan sonar images based on POHMT and Tsallis entropy</i>
4	<i>Environmental effects on seabed object bistatic scattering classification</i>
5	<i>Side Scan Sonar Images Based Ocean Bottom Sediment Classification</i>
6	<i>Target detection in sonar image based on faster RCNN</i>
7	<i>Estimating shrimp body length using deep convolutional neural network</i>
8	<i>Baby Shrimp Counting via Automated Image Processing</i>
9	<i>Seabed Sediment Classification of Side-scan Sonar Data Using Convolutional Neural Networks</i>
10	<i>CNN Transfer Learning of Shrimp Detection for Underwater Vision System</i>
11	<i>Detecting Leftover Food and the Shrimp for Estimating of the Shrimp Body Length Based on CNN</i>
12	<i>Acoustic classification in multifrequency echosounder data using deep convolutional</i>

	<i>neural networks</i>
13	<i>Classification of Southern Ocean krill and icefish echoes using random forests</i>
14	<i>Detecting Marine Species in Echograms via Traditional, Hybrid, and Deep Learning Frameworks</i>
15	<i>Automatic Bluefin Tuna (<i>Thunnus thynnus</i>) biomass estimation during transfers using acoustic and computer vision techniques</i>

Metode Penyelesaian:

A	<i>Faster R-CNN</i>
B	<i>region growing based segmentation (RGLT)</i>
C	<i>Standard Deviation Filtering (STDF)</i>
D	<i>Percentage Occupancy Hit-or-Miss Transform (POHMT)</i>
E	<i>Tsallis entropy</i>
F	<i>Support Vector Machine (SVM)</i>
G	<i>Local Binary Pattern (LBP)</i>
H	<i>Local Directional Pattern (LDP)</i>
I	<i>Local Ternary Pattern (LTD)</i>
J	<i>Bilinear Interpolation (BIL)</i>
K	<i>Bicubic Interpolation (BIC)</i>
L	<i>You Only Look Once (YOLO)</i>
M	<i>Arsitektur AlexNet</i>
N	<i>Arsitektur DarkNet</i>
O	<i>Blob Detection</i>
P	<i>CNN</i>
Q	<i>Inception</i>
R	<i>U-Net</i>
S	<i>Random Forest</i>
T	<i>Otsu Method</i>
U	<i>Local Thresholding</i>
V	<i>Edge Detection</i>

Berdasarkan usulan metode yang akan digunakan dalam penelitian ini, level orisinalitas yang dipenuhi adalah level 6 dengan memenuhi beberapa aspek sebagai berikut:

1. Objek Penelitian: (Terpakai)

Objek pada penelitian ini adalah udang vaname dimana sudah sering menjadi menjadi objek pada beberapa penelitian sebelumnya.

2. Jenis Permasalahan: (Baru)

Untuk permasalahan yang diangkat tergolong baru karena penggunaan data sonar pada sistem akuakultur untuk bidang budidaya khususnya untuk penggunaan pakan menggunakan system bioflok masih belum ada penelitian terkait yang ditemukan.

3. Metode Penyelesaian Masalah: (Tersedia)

Pada penelitian ini, metode yang diusulkan adalah menggunakan Faster R-CNN yang sudah banyak dipakai pada penelitian untuk melakukan deteksi objek.

Tabel 3. Level Orisinalitas Proposal Magister Teknik Informatika UNHAS


Level orisinalitas	Objek penelitian	Jenis permasalahan	Metode penyelesaian masalah	Status orisinal proposal/penelitian
1	xxxxx	Tidak jelas, Sangat minim untuk level S2	xxxxxx	Orisinalitas tidak ada
2	Terpakai (sudah digunakan sebelumnya)	Serupa dengan objek yang sama	Sudah digunakan untuk objek dan jenis permasalahan sebelumnya	Sangat tidak orisinal (replikasi)
3	Baru	Serupa dengan sebelumnya	Sama untuk masalah yang serupa	Kurang

Level orisinalitas	Objek penelitian	Jenis permasalahan	Metode penyelesaian masalah	Status orisinal proposal/penelitian
4	Terpakai (sudah digunakan sebelumnya)	Serupa dengan objek yang sama	Lain yang tersedia (belum digunakan untuk masalah yang sama)	Minimalis
5	Baru	Serupa dengan sebelumnya	Lain yang tersedia	Minimalis
6	Terpakai	Baru	Tersedia	Orisinal
7	Baru	Baru	Tersedia	Orisinal
8	Terpakai	Serupa	Baru	Orisinal + Novelty
9	Baru	Serupa	Baru	Orisinal + Novelty
10	Terpakai	Baru	Baru	Sangat orisinal + Novelty
11	Baru	Baru	Baru	Sangat orisinal + Novelty

2.3. Target Hasil Penelitian

Berdasarkan tabel *State of The Art* penelitian yang sudah dilakukan, target hasil yang diinginkan dari penelitian ini adalah mampu melakukan deteksi udang yang berada pada kolom air dengan menggunakan citra *singlebeam echosounder*. Proses deteksi menggunakan algoritma CNN, Faster R-CNN, dan YOLOv8

2.4. Kerangka Pikir



Gambar 25. Kerangka Pikir

BAB III

METODE PENELITIAN


4.1. Jenis Penelitian

Penelitian ini merupakan penelitian eksperimen yang bertujuan untuk menganalisis kebermanfaatan teknologi SONAR dalam bidang budidaya, dengan fokus pada objek yang diteliti yaitu udang vaname. Dalam penelitian ini, pengaturan kolam budidaya serta pengambilan sampel dataset berupa citra sonar dilakukan dalam kondisi lingkungan yang terkendali untuk memastikan akurasi dan konsistensi data yang diperoleh. Citra sonar yang digunakan yaitu citra *singlebeam echosounder*, yang memungkinkan peneliti untuk mendapatkan informasi mengenai objek yang terdapat di dalam kolam.

Proses analisis hasil citra sonar yang didapatkan akan dilakukan dengan membandingkan tiga algoritma deteksi objek yang berbeda, yaitu CNN, Faster R-CNN, dan YOLOv8. Setiap algoritma memiliki pendekatan dan keunggulan tersendiri dalam mendeteksi objek, sehingga perbandingan ini diharapkan dapat memberikan wawasan lebih terhadap efektivitas masing-masing metode dalam konteks deteksi udang dari gambar *singlebeam echosounder*. Hasil perbandingan dari ketiga algoritma tersebut bertujuan untuk menentukan metode yang paling optimal untuk digunakan dalam aplikasi nyata di lapangan. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan teknologi budidaya udang, serta membuka peluang untuk penelitian lebih lanjut dalam pemanfaatan teknologi sonar di sektor perikanan lainnya.

4.2. Tahapan Penelitian

Terdapat beberapa tahapan dalam melakukan penelitian ini. Tahapan pertama dalam penelitian ini adalah melakukan studi literatur dan analisis terkait topik permasalahan yang diangkat dan alternatif metode yang dapat digunakan untuk menyelesaikan permasalahan. Pada tahapan kedua, pengambilan dataset dilakukan dengan menggunakan perangkat sonar yang telah dikondisikan tata letaknya dan jalur gerakannya pada kolam tambak. Dataset akan terdiri dari citra *singlebeam echosounder*. Setelah dataset didapatkan, masuk ke tahapan ketiga dimana dilakukan proses pembuatan model dengan menggunakan 3 algoritma yaitu CNN, Faster R-CNN, dan YOLO. Pada pembuatan model ini akan dilakukan proses training dan ujicoba deteksi menggunakan model yang telah selesai dibuat. Dari data hasil ujicoba tersebut, pada tahapan keempat akan dilakukan perhitungan tingkat akurasi dimana jika masih terdapat kelemahan maka akan kembali ke tahap tiga untuk dilakukan evaluasi metode yang digunakan, evaluasi akan berupa treatment sehingga dapat meningkatkan akurasi nantinya. Pada tahapan terakhir akan dilakukan perbandingan tingkat efektifitas dari 3 metode tersebut.




Gambar 26. Tahapan Pelaksanaan Penelitian

4.3. Sumber Data

Dataset pada penelitian ini adalah citra *singlebeam echosounder* yang menampilkan keseluruhan isi kolam budidaya udang vaname. Data citra ini diambil dengan menggunakan perangkat sonar garmin GPSMAP 585 Plus. Untuk tipe transduser yang digunakan adalah Garmin GT20-TM yang dioperasikan dengan frekuensi 200 kHz.


4.4. Rancangan Sistem

Pada penelitian ini, pengambilan dataset dilakukan pada kolam berbentuk persegi panjang. Perangkat transduser Garmin GT20-TM yang akan digunakan untuk pengambilan data diletakkan pada posisi ujung kolam dengan dihadapkan mengarah pada sisi lain kolam untuk pemindaian secara horisontal.




Gambar 27. Sudut Scan Transduser

Perancangan system pada penelitian ini ditunjukkan dalam bentuk bagan rancangan sebagai berikut:




Gambar 28. Bagan Rancangan Sistem

Tahapan yang dilakukan sesuai yang ditunjukkan dalam gambar bagan rancangan sistem. Dataset yang nantinya akan diambil berupa gambar sonar *singlebeam echosounder*. Gambar sonar nantinya digunakan untuk mendeteksi objek udang yang berada dalam kolom air.



(a)




(b)

Gambar 29. Objek Target berdasarkan hasil *singlebeam echosounder*: (a) ilustrasi posisi transduser dan objek udang. (b) Citra *singlebeam echosounder*


Perekaman data gambar *singlebeam echosounder* menggunakan *Garmin GPSMAP 585 Plus*. Data perekaman tersimpan pada kartu memori yang terpasang pada perangkat. Data yang tersimpan dalam format file .RSD (Raw Sonar Data) selanjutnya dibaca dengan menggunakan aplikasi *Garmin HomePort* untuk memproses dan menampilkan data sonar. Data sonar yang

ditampilkan dalam bentuk playback sinyal ping dalam satu waktu pengambilan data.




Gambar 30. Pembacaan Data .RSD pada Aplikasi Garmin HomePort

Hasil dari proses pembacaan data akan direkam kedalam bentuk file dengan format *.mp4. Pengambilan data tiap frame akan dilakukan dalam satuan waktu detik untuk melihat pola objek yang terekam dalam data sonar.




Gambar 31. Visualisasi Citra singlebeam echosounder dalam satuan waktu

Setelah seluruh frame berhasil diambil, langkah selanjutnya dilakukan proses *pre-processing data*. Jumlah total frame yang diambil sejumlah 446 gambar, dan yang akan digunakan sebagai dataset untuk melatih model sejumlah 400 buah gambar. Keseluruhan tahapan proses diilustrasikan dalam gambar Rancangan Proses berikut:



Gambar 32. Rancangan Proses


Pada tahapan *pre-processing*, proses awal yang dilakukan data citra *singlebeam echosounder* yaitu melakukan cropping gambar untuk menghilangkan area surface dan bottom agar tidak menjadi noise dalam proses pelatihan nanti.



Gambar 33. Proses Cropping Citra Singlebeam Echosounder


Pada hasil citra singlebeam echosounder terdapat objek yang saling berdekatan sehingga dilakukan proses penandaan objek dengan pemisahan area yang diindikasikan sebagai objek tunggal. Proses yang terjadi pada tahapan ini dilakukan pertama dengan mengambil data gambar singlebeam echosounder, kemudian dilakukan proses perubahan gambar dari berwarna menjadi grayscale. Selanjutnya dilakukan perubahan gambar dari grayscale menjadi gambar biner. Pada proses ini ditetapkan nilai ambang batas adalah 182 dimana jika nilai piksel lebih besar dari nilai ambang batas, maka piksel tersebut diatur menjadi putih. Sebaliknya jika nilai piksel lebih kecil atau sama dengan nilai ambang batas, piksel tersebut diatur menjadi hitam. Setelah didapatkan gambar hasil thresholding, selanjutnya dilakukan proses deteksi tepi atau batas objek dalam gambar biner. Pada proses ini pemisahan objek dengan hasil batas tepi akan menjadi acuan dalam memberikan penanda pada objek tunggal. Dari tiap area akan diambil titik

pusat atau centroid dan diberikan penanda berupa sebuah titik pixel dengan warna merah.




Gambar 34. Tahapan penanda pemisah objek tunggal

Tahapan selanjutnya yaitu peningkatan warna objek yang muncul pada kolom air dengan pendekatan penerapan depth map pada gambar. Depth map adalah representasi visual yang menunjukkan kedalaman objek dalam suatu gambar, di mana setiap piksel memiliki nilai yang mencerminkan jarak objek. Dalam depth map, nilai piksel biasanya dinyatakan dalam skala grayscale, di mana piksel yang lebih terang menunjukkan objek yang lebih dekat, sedangkan piksel yang lebih gelap menunjukkan objek yang lebih jauh.




(a)



(b)

Gambar 35. Proses Depth Map: (a) Citra asli *singlebeam echosounder*, (b) Citra setelah dilakukan proses *depth map*

Tahapan terakhir dari proses *pre-processing* adalah mengubah mengubah dimensi gambar agar sesuai dengan ukuran input yang diharapkan oleh model atau algoritma yang akan digunakan. Seluruh gambar dalam dataset diubah kedalam ukuran 600 x 600 piksel.



Gambar 36. Dataset singlebeam echosounder dengan ukuran 600 x 600 piksel

Pada tahapan selanjutnya setelah *pre-processing* data dilakukan adalah proses pelabelan. Proses pelabelan ini dilakukan menggunakan aplikasi Label Studio, yang dirancang khusus untuk memudahkan dalam memberikan anotasi pada data.

