

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kebakaran hutan dan lahan (karhutla) merupakan salah satu bencana lingkungan yang kompleks dan seringkali sulit dikendalikan. Fenomena ini tidak hanya terjadi di wilayah hutan yang masih alami, tetapi juga meluas hingga ke lahan yang telah dimanfaatkan oleh masyarakat untuk pertanian, perkebunan, atau aktivitas lainnya. Secara umum, karhutla dipicu oleh dua faktor utama, yaitu faktor alamiah dan aktivitas manusia. Faktor alamiah seperti musim kemarau yang panjang, suhu tinggi, angin kencang, serta fenomena petir tanpa hujan dapat memicu kebakaran secara spontan. Namun demikian, sebagian besar kasus kebakaran hutan di Indonesia dan di banyak wilayah tropis lainnya lebih sering berkaitan dengan aktivitas manusia, seperti pembukaan lahan dengan teknik pembakaran yang tidak terkendali. Ironisnya, dalam lebih dari separuh kasus kebakaran yang tercatat secara global, termasuk di Indonesia, penyebab pasti terjadinya kebakaran tidak dapat diidentifikasi dengan jelas, yang menunjukkan adanya kelemahan dalam sistem pemantauan dan pelaporan (Hoover & Hanson, 2021; Rosit et al., 2023).

Salah satu aspek penting yang perlu diperhatikan dalam studi kebakaran hutan adalah peran faktor iklim sebagai pemicu alami yang sangat berpengaruh. Iklim tidak hanya berperan dalam menciptakan kondisi yang mendukung penyebaran api, tetapi juga dapat memengaruhi tingkat kekeringan bahan bakar permukaan, seperti serasah daun, ranting, dan vegetasi kering lainnya. Kondisi suhu tinggi, rendahnya kelembaban udara, curah hujan yang minim, dan angin kencang menjadi kombinasi yang memperbesar kemungkinan terjadinya kebakaran. Penelitian oleh Hero Saharjo dan Uswatun Hasanah (2023) menunjukkan bahwa perubahan iklim yang memicu kekeringan ekstrem turut memperpanjang musim rawan kebakaran di berbagai wilayah di Indonesia. Di sisi lain, faktor manusia seperti kedekatan dengan permukiman, jaringan jalan, serta perubahan penutupan lahan juga berkontribusi besar terhadap meningkatnya frekuensi karhutla. Kombinasi antara faktor alami dan antropogenik inilah yang menjadikan karhutla sebagai bencana ekologis yang sulit diprediksi dan ditanggulangi secara efektif.

Dampak kebakaran hutan sangat luas dan multidimensional. Secara ekologis, kebakaran dapat merusak habitat alami, menurunkan keanekaragaman hayati, serta mengganggu keseimbangan ekosistem. Dari segi ekonomi, karhutla menyebabkan kerugian besar akibat kerusakan hutan produksi, terganggunya aktivitas pertanian dan transportasi, serta meningkatnya biaya penanggulangan. Secara sosial dan kesehatan, asap dari kebakaran dapat menimbulkan gangguan pernapasan, menurunkan kualitas udara, dan bahkan menyebabkan krisis kemanusiaan, terutama di wilayah-wilayah yang terpapar secara langsung. Oleh karena itu, upaya mitigasi dan pencegahan menjadi sangat krusial, salah satunya dengan menyusun peta kerawanan kebakaran hutan dan lahan untuk mengidentifikasi wilayah yang paling rentan terhadap kejadian kebakaran, sehingga tindakan pencegahan dan respons darurat dapat dilakukan secara lebih tepat sasaran (Ikhwani, 2016; Mishra et al., 2023).

Perkembangan teknologi geospasial, khususnya penginderaan jauh dan Sistem Informasi Geografis (SIG), telah memberikan kemajuan signifikan dalam upaya pemantauan dan pemetaan kebakaran hutan. Penggunaan citra satelit memungkinkan pengawasan titik api (*hotspot*) secara *real-time* dan menyeluruh di wilayah yang luas, sehingga menjadi alat yang efektif dalam sistem peringatan dini. Dengan memanfaatkan data dari berbagai satelit serta variabel biofisik yang relevan, seperti indeks vegetasi (NDVI), topografi, suhu permukaan (LST), dan sejarah kebakaran, pemetaan daerah rawan karhutla dapat dilakukan secara komprehensif dan efisien (Samsuri et al., 2012; Verma et al., 2020). Teknologi *cloud computing* seperti *Google Earth Engine* juga memungkinkan analisis spasial dilakukan secara cepat dan dinamis, bahkan untuk wilayah yang sebelumnya sulit dijangkau secara konvensional. Integrasi antara penginderaan jauh dan SIG telah terbukti efektif dalam mendukung pengambilan keputusan berbasis data pada berbagai level kebijakan dan tata kelola hutan.

Salah satu pendekatan yang banyak digunakan dalam pemodelan spasial kerawanan kebakaran adalah metode *Maximum Entropy* (MaxEnt). Metode ini memiliki keunggulan karena hanya membutuhkan data kehadiran (*presence-only*) dan dapat mengestimasi distribusi spasial dari fenomena berdasarkan hubungan statistik dengan variabel lingkungan. Dalam konteks kebakaran hutan, MaxEnt digunakan untuk memodelkan potensi distribusi *hotspot* berdasarkan variabel iklim dan biofisik, seperti suhu, curah hujan, kelembaban, NDVI, dan faktor kedekatan dengan infrastruktur manusia (Yang et al., 2021). Model ini telah banyak diterapkan secara global dalam studi-studi zonasi risiko kebakaran, terutama di kawasan tropis dan sub-tropis yang memiliki dinamika kebakaran yang kompleks. Keunggulan MaxEnt terletak pada fleksibilitasnya dalam memanfaatkan data terbatas namun tetap menghasilkan prediksi yang kuat secara statistik.

Di Kabupaten Luwu Timur, Sulawesi Selatan, kejadian karhutla menjadi perhatian serius karena wilayah ini memiliki karakteristik biofisik dan iklim yang unik. Kondisi geografis yang dipengaruhi oleh pola curah hujan regional, suhu tinggi pada musim-musim tertentu, serta adanya tekanan dari aktivitas manusia menjadikan wilayah ini rentan terhadap kebakaran hutan dan lahan. Meskipun demikian, hingga saat ini belum ada kajian yang secara komprehensif menganalisis pengaruh faktor-faktor iklim terhadap distribusi spasial karhutla di wilayah ini. Informasi mengenai bagaimana suhu, curah hujan, kelembaban, dan kecepatan angin berinteraksi dalam memicu kebakaran masih terbatas, padahal pemahaman yang mendalam terhadap dinamika iklim sangat penting untuk menyusun strategi mitigasi yang berbasis data. Selain itu, belum diketahui secara pasti kontribusi relatif masing-masing variabel iklim terhadap risiko kebakaran di Luwu Timur, terutama dalam konteks perubahan iklim jangka panjang yang diprediksi akan memperburuk frekuensi dan intensitas karhutla di masa mendatang.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis faktor-faktor iklim yang paling berpengaruh terhadap kejadian kebakaran hutan dan lahan di Kabupaten Luwu Timur dengan memanfaatkan pendekatan pemodelan MaxEnt berbasis data penginderaan jauh dan sistem informasi geografis. Melalui penelitian ini, diharapkan dapat dihasilkan peta kerawanan kebakaran yang lebih akurat, serta informasi ilmiah yang dapat digunakan sebagai dasar dalam pengambilan kebijakan mitigasi dan sistem peringatan dini karhutla yang lebih efektif di masa depan.

1.2 Tujuan dan Manfaat

Tujuan dari penelitian ini adalah untuk:

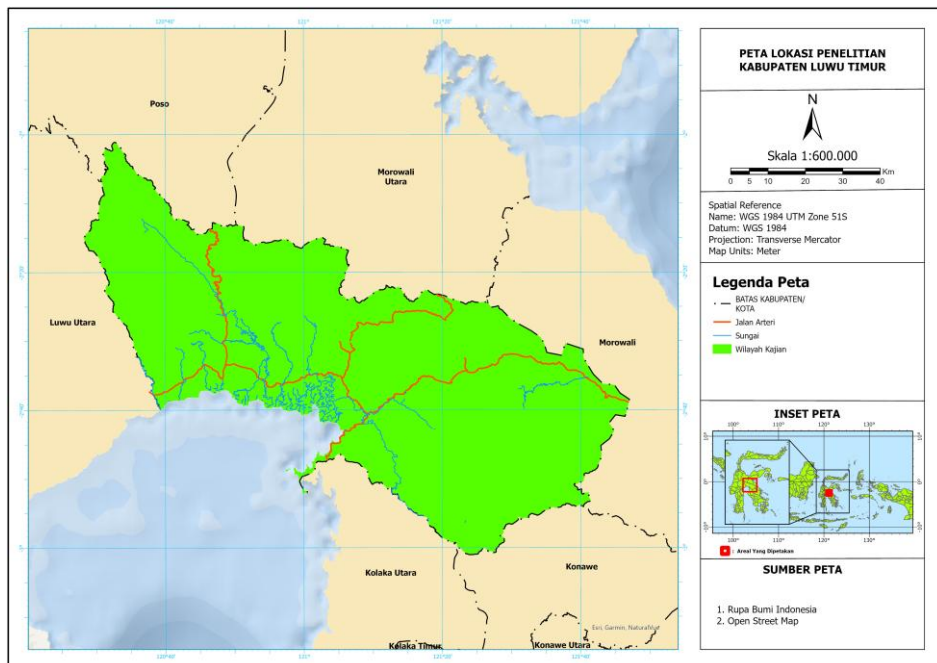
1. Mengidentifikasi variabel-variabel lingkungan yang berkontribusi terhadap terjadinya kebakaran hutan dan lahan di Kabupaten Luwu Timur.,
2. Memetakan kerawanan kebakaran hutan dan lahan dengan menggunakan algoritma *Maximum Entropy (MaxEnt)* berbasis data *Google Earth Engine*, sehingga dihasilkan peta probabilitas kerawanan yang akurat dan terukur.

Manfaat dari penelitian ini adalah untuk menyediakan dasar ilmiah dalam memahami faktor lingkungan penyebab kebakaran dengan mengidentifikasi variabel utama yang berkontribusi terhadap kejadian kebakaran hutan dan lahan di Luwu Timur. Selain itu, penelitian ini berfungsi untuk menghasilkan peta kerawanan kebakaran yang dapat digunakan sebagai alat prediksi dalam menentukan wilayah dengan risiko tinggi kebakaran, sehingga mendukung perencanaan mitigasi dan respon dini. Hasil penelitian ini juga diharapkan dapat berkontribusi dalam penyusunan strategi penanggulangan kebakaran berbasis data dengan menyediakan informasi yang akurat mengenai hubungan antara faktor iklim dan kejadian kebakaran, sehingga kebijakan pencegahan dan penanggulangan dapat lebih efektif dan tepat sasaran.

BAB II METODE PENELITIAN

2.1 Tempat dan Waktu

Penelitian dilakukan dari Bulan September tahun 2024 sampai Bulan Mei tahun 2025. Untuk kegiatan lapangan jika diperlukan akan dilakukan di Kabupaten Luwu Timur, Sulawesi Selatan. Sedangkan pengolahan data dilakukan di Laboratorium Perencanaan dan Sistem Informasi Kehutanan, Departemen Kehutanan, Fakultas Kehutanan Universitas Hasanuddin.



Gambar 1. Peta Lokasi Penelitian

2.2 Bahan dan Alat

2.2.1 Bahan

Adapun bahan-bahan yang digunakan dalam penelitian dapat dilihat pada Gambar 1.

Tabel 1. Bahan

No	Bahan	Kegunaan	Sumber
1.	Data <i>hotspot history</i> (<i>occurrence</i>)	Sebagai data titik kejadian kebakaran (<i>validasi</i>)	Sistem Pemantauan Karhutla (https://sipongi.menlhk.go.id/)

No	Bahan	Kegunaan	Sumber	
2.	Batas administrasi Kabupaten Luwu Timur	Sebagai batas wilayah kajian	Badan Informasi Geografis (https://tanahair.indonesia.go.id/)	
3.	Curah Hujan	Variabel Lingkungan	CHIRPS (https://chc.ucsb.edu/data/chirps/)	
4.	Kecepatan Angin		ERA 5 (https://cds.climate.copernicus.eu/)	
5.	<i>Land Surface Temperature</i> (Suhu Permukaan)		Faktor Alami Landsat-8 (https://www.usgs.gov/)	
6.	NDVI		Sentinel-2 (https://sentinewiki.copernicus.eu/)	
7.	NDWI		Sentinel-2 (https://sentinewiki.copernicus.eu/)	
8.	Slope		DEMNAS (https://tanahair.indonesia.go.id/)	
9.	Jarak Dari Sumber Air		Faktor Manusia	Badan Informasi Geografis (https://tanahair.indonesia.go.id/)
10.	Jarak Dari Jalan		Open Street Map (https://www.openstreetmap.org/)	

2.2.2 Alat

Alat yang digunakan dalam penelitian ini adalah:

1. Laptop, sebagai alat yang digunakan dalam pemrosesan di platform *Google Earth Engine* (GEE) atau *software*,
2. *Ms. Office* digunakan untuk membuat laporan hasil pemrosesan,
3. *Software* Pemetaan GIS (ArcGIS dan QGIS) digunakan untuk mengolah variabel yang tidak tersedia di *Google Earth Engine*.

2.3 Prosedur Penelitian

Adapun pada penelitian ini dimulai dengan tiga langkah utama yaitu: 1) Persiapan titik api (*hotspot*) yang diperoleh dari website resmi Sistem Pemantauan Karhutla, 2) persiapan data lingkungan, dan 3) Menjalankan model MaxEnt.

2.3.1 Persiapan titik api (*hotspot*)

Pemantauan “titik panas” (*hotspot*) merupakan salah satu upaya pengendalian kejadian bencana kebakaran hutan dan lahan (karhutla) dengan melakukan deteksi panas melalui bantuan satelit penginderaan jauh dan sistem informasi geografis. *Hotspot* memiliki ragam variasi yang tinggi baik secara temporal maupun spasial sebagai sebuah indikator terjadinya kebakaran disuatu tempat dengan tingkat kepercayaan tertentu (Putra et al., 2019). *Hotspot* yang digunakan saat ini di Indonesia diperoleh dari pengolahan data citra satelit berorbit polar (MODIS dan VIIRS) dengan resolusi temporal yang rendah, yaitu hanya 6 kali dalam sehari. Proses pembacaan data *hotspot* oleh satelit dimulai ketika sensor termal pada satelit mendeteksi adanya peningkatan signifikan suhu permukaan bumi pada waktu tertentu. Peningkatan suhu ini terekam sebagai sinyal radiasi termal yang intens, terutama pada kanal inframerah gelombang menengah. Ketika citra diproses oleh satelit, algoritma *onboard* maupun *ground-based* segera melakukan identifikasi terhadap piksel-piksel yang menunjukkan anomali suhu, yakni piksel dengan nilai kecerahan termal jauh lebih tinggi dibanding lingkungan sekitarnya (Sepriando et al., 2020).

Data titik api (*hotspot*) diperoleh dari website KLHK yaitu SiPongi+ (<https://sipongi.menlhk.go.id/>). Pada penelitian Julianti et al., (2023) mengungkapkan bahwa di Sulawesi Selatan mengalami 7 bulan basah (November-Mei), 3 bulan kering (Juli-September), dan 2 bulan peralihan (Juni dan Oktober) dengan tipe iklim agak basah. Pengunduhan akan dilakukan dari data 5 tahun terakhir (2020–2024). Data diakses secara manual pada menu pencarian dan mengatur rentang waktu sesuai musim yang ditentukan. Pengunduhan data dilakukan untuk setiap tahun secara terpisah. Dalam penelitian ini, data *hotspot* digunakan sebagai data kehadiran kebakaran.

2.3.2 Faktor-Faktor Penyebab Kebakaran Hutan dan Lahan

Kebakaran hutan dan lahan terjadi ketika tiga unsur segitiga api, yaitu bahan bakar, oksigen, dan sumber panas terpenuhi di satu lokasi (Bujangga Waisnawa et al., 2023). Kebakaran ini dapat disebabkan oleh faktor alam seperti kemarau panjang dan aktivitas manusia seperti pembukaan lahan (Ambarita, 2021). Berbagai penelitian telah mengidentifikasi berbagai sumber kebakaran, termasuk peternakan, perladangan berpindah, dan kombinasi keduanya (Dina, 2011). Aktivitas manusia, khususnya yang terkait dengan faktor spasial seperti jarak dari jalan, tutupan lahan, dan kepadatan penduduk, merupakan kontributor utama terjadinya kebakaran (Mapilata et al., 2013). Strategi pencegahan meliputi pembuatan waduk, pembangunan kanal untuk memudahkan akses air, dan penerapan sekat bakar (Ambarita, 2021). Pemetaan wilayah rawan kebakaran menggunakan teknik seperti Analisis Pemetaan Komposit dapat membantu dalam perencanaan tata ruang dan upaya pencegahan kebakaran (Mapilata et al., 2013).

Tingkat kerawanan suatu wilayah terhadap kebakaran dipengaruhi oleh berbagai faktor lingkungan yang berkaitan dengan segitiga api (Mapilata et al., 2013). Faktor-faktor seperti curah hujan, kecepatan angin, suhu permukaan (*Land Surface Temperature*), serta kondisi vegetasi yang tercermin dalam indeks NDVI dan NDWI berperan penting dalam menentukan tingkat kerawanan suatu wilayah terhadap kebakaran (Fitria et al., 2021; Kusuma et al., 2021). Selain itu, karakteristik topografi seperti kemiringan lahan

(*slope*), serta jarak dari sumber air dan jalan juga mempengaruhi penyebaran api dan kemudahan akses dalam upaya pemadaman (Lisda et al., 2024).

Kebakaran hutan dan lahan di Indonesia, terutama di Kalimantan, memiliki dampak negatif yang signifikan terhadap lingkungan, sosial, dan ekonomi (Saharjo, 2022). Faktor utama penyebab kebakaran adalah aktivitas manusia, yang diperparah oleh kondisi alam seperti kekeringan lahan gambut (Mapilata et al., 2013; Anhar et al., 2022). Dampak kebakaran meliputi pencemaran udara, gangguan penerbangan, dan masalah kesehatan (Meytriani & Kusuma, 2024). Di Desa Bunsur, Riau, tingkat keparahan kebakaran berhubungan positif dengan dampaknya terhadap masyarakat (Anhar et al., 2022). Untuk mengatasi masalah ini, diperlukan pengendalian kebakaran yang serius dan sistematis, didukung oleh kemauan politik pemerintah dan penelitian berbasis fakta lapangan (Saharjo, 2022). Analisis daerah rawan kebakaran dan penataan ruang juga penting dalam upaya pencegahan (Mapilata et al., 2013).

2.3.3 Analisis Data Penyebab Kebakaran Hutan dan Lahan

Persiapan data lingkungan pada penelitian ini menggunakan dua cara, yaitu: 1) memanggil koleksi citra yang tersedia dalam basis data *Google Earth Engine*, dan 2) melakukan pengolahan data menggunakan perangkat lunak GIS (ArcGIS maupun QGIS) pada data yang tidak tersedia dalam basis data *Google Earth Engine*. Dalam konteks ini, *Google Earth Engine* tidak hanya berfungsi sebagai penyedia data lingkungan, tetapi juga sebagai platform pemodelan karena telah menyediakan perintah untuk menjalankan algoritma MaxEnt secara langsung. Integrasi ini memungkinkan seluruh proses, mulai dari ekstraksi variabel hingga pemodelan distribusi kerawanan kebakaran, dilakukan secara efisien dalam satu sistem berbasis komputasi awan.

Pada awalnya, MaxEnt (*Maximum Entropy*) dikembangkan sebagai metode untuk memprediksi kesesuaian habitat satwa liar dengan menggunakan titik keberadaan (*presence-only data*) dan variabel lingkungan. Namun, prinsip dasarnya yang menghubungkan keberadaan suatu fenomena dengan kondisi lingkungannya menjadikan MaxEnt sangat fleksibel untuk berbagai bidang aplikasi. Dalam konteks kebakaran hutan dan lahan, *hotspot* kebakaran dapat diperlakukan sebagai data kehadiran (*presence*) yang kemudian diproyeksikan terhadap variabel lingkungan seperti suhu permukaan, indeks vegetasi, kelembapan, jarak dari jalan, maupun jarak dari sumber air. Dengan demikian, MaxEnt mampu menghasilkan peta probabilitas kerawanan kebakaran berdasarkan pola distribusi *hotspot* historis, sehingga model ini yang semula digunakan untuk ekologi kini juga efektif diterapkan pada analisis kerawanan kebakaran.

Curah Hujan. Dalam penelitian Itsnaini et al., (2017) dan Novita & Vonnisa, (2021) mengungkapkan bahwa curah hujan berpengaruh besar terhadap kebakaran hutan dan lahan karena menentukan kelembapan tanah dan vegetasi. Saat curah hujan tinggi, kandungan air dalam tanah meningkat, sehingga vegetasi tetap lembap dan sulit terbakar. Sebaliknya, saat curah hujan rendah atau terjadi kekeringan, dedaunan dan ranting menjadi kering serta mudah terbakar, meningkatkan risiko kebakaran. Data curah hujan pada penelitian diperoleh dari koleksi data CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station Data*) yang tersedia di *Google Earth Engine* dengan

resolusi temporal 5 hari dan resolusi spasial 5500 × 5500 m². Pengambilan data dilakukan dengan memfilter curah hujan pada satu musim tertentu, untuk periode yang sama dengan data *Hotspot*. Data tersebut kemudian di-clip menggunakan batas wilayah kajian untuk memastikan hanya data yang relevan dengan area penelitian yang digunakan. Dalam penelitian ini, data curah hujan musiman tersebut digunakan sebagai salah satu variabel utama dalam analisis, terutama untuk memahami hubungan antara pola curah hujan dan fenomena karhutla. Skrip untuk memanggil data curah hujan dapat dilihat pada Gambar 2.

```
// =====>>>> Variabel Lingkungan (1): Curah Hujan <<<<=====
// Data induk: Climate Hazard Group Infrared Precipitation 5500m
// Satuan dalam 'mm/pentad'
var ch = ee.ImageCollection('UCSB-CHG/CHIRPS/PENTAD')
    .filter(ee.Filter.date('2023-01-01', '2023-12-31'));
var mosaicCh = ch.mosaic();
var var1 = mosaicCh.select('precipitation');
var vis1 = {
  min: 0,
  max: 125,
  palette: ['LightCyan', 'LightSkyBlue', 'RoyalBlue', 'Navy'],
};

// Memotong citra variabel (1) sesuai ROI dan menampilkannya
var clipVar1 = var1.clip(roi).toFloat();
print('Clip Var1', clipVar1);
Map.addLayer(clipVar1, vis1, 'Var1: Curah Hujan',0);
```

Gambar 2. Memanggil Variabel Curah Hujan

Kecepatan Angin (*Wind Speed*). Penelitian menunjukkan bahwa kecepatan angin berpengaruh terhadap kebakaran hutan dan lahan karena dapat mempercepat penyebaran api. Angin yang kencang membawa percikan api dan bara ke area lain, sehingga kebakaran meluas dengan cepat. Selain itu, angin meningkatkan suplai oksigen ke dalam api, membuat nyala api lebih besar dan sulit dipadamkan (Pratiwi et al., 2021). Di daerah dengan kecepatan angin tinggi, kebakaran dapat menyebar ke berbagai arah secara tidak terduga, menyulitkan upaya pemadaman. Angin juga dapat mengeringkan vegetasi, sehingga lebih mudah terbakar (Bujangga Waisnawa et al., 2023). Oleh karena itu, kecepatan angin menjadi salah satu faktor utama yang mempengaruhi intensitas dan luasnya kebakaran hutan dan lahan.

Data kecepatan angin yang digunakan dalam penelitian ini merupakan data hasil reanalisis dari ERA5, yang disediakan oleh *European Centre for Medium-Range Weather Forecasts* (ECMWF) dan tersedia di *Google Earth Engine*. ERA5 adalah produk reanalisis yang menggabungkan data observasi dari berbagai sumber, seperti satelit dan stasiun cuaca, dengan model atmosfer menggunakan teknik asimilasi data untuk menghasilkan estimasi kondisi cuaca historis yang lebih akurat. Dalam akses datanya ERA5 memiliki dua komponen yang menggambarkan arah angin bergerak yaitu komponen U dan V. Untuk menghasilkan data kecepatan angin diperlukan pengolahan sebagai berikut:

$$\text{Kecepatan Angin} = \sqrt{U^2 + V^2} \quad (2.1)$$

Data ini memiliki resolusi spasial sekitar 11 km dan resolusi temporal per jam, memungkinkan analisis pola kecepatan angin dengan tingkat detail yang baik dalam

suatu periode waktu tertentu. Dalam penelitian ini, data difokuskan pada kecepatan angin musiman, dengan rentang waktu yang difilter khusus untuk mencakup satu musim. Setelah data difilter berdasarkan waktu, proses clipping dilakukan menggunakan batas wilayah kajian agar hanya data yang relevan dengan area penelitian yang diambil. Data kecepatan angin ini kemudian digunakan untuk mengidentifikasi pola angin yang berpotensi memengaruhi fenomena Karhutla di wilayah kajian. Skrip untuk memanggil data kecepatan angin dapat dilihat pada Gambar 3.

```
// =====>>>> Variabel Lingkungan (2): Kecepatan Angin <<<<=====
// Data induk: ECMWF/ERA5_LAND/HOURLY
var era5 = ee.ImageCollection('ECMWF/ERA5_LAND/HOURLY')
    .filterDate('2022-11-01', '2023-05-31')
    .select(['u_component_of_wind_10m', 'v_component_of_wind_10m'])
    .mean();

var var2 = era5.expression(
  'sqrt(pow(U, 2) + pow(V, 2))', {
    'U': era5.select('u_component_of_wind_10m'),
    'V': era5.select('v_component_of_wind_10m'),
  }
);

var vis2 = {
  min:0,
  max:50,
  palette: ["0072ff","00f3ff","fbff1b","ff920a","ff0000"],
};

// Memotong citra variabel (2) sesuai ROI dan menampilkannya
var clipVar2 = var2.clip(roi).toFloat();
print('Clip Var2', clipVar2);
Map.addLayer(clipVar2, vis2, 'Var2: Kecepatan Angin');
```

Gambar 3. Memanggil Variabel Kecepatan Angin

Suhu Permukaan (*Land Surface Temperature*). *Land Surface Temperature* (LST) telah diidentifikasi sebagai indikator penting dari tingkat keparahan kebakaran dan risiko kebakaran hutan di berbagai ekosistem. Suhu permukaan berpengaruh terhadap kebakaran hutan dan lahan karena dapat menentukan tingkat kekeringan vegetasi dan tanah. Semakin tinggi suhu permukaan, semakin cepat air dalam tanah dan tanaman menguap, sehingga vegetasi menjadi kering dan mudah terbakar (Arafah & Ramadhan, 2024), (Fitria et al., 2021). Ketika dikombinasikan dengan parameter lain seperti kelembaban, tutupan vegetasi, dan kedekatan dengan jalan dan pemukiman, LST berkontribusi pada penilaian risiko kebakaran yang komprehensif. Suhu yang lebih tinggi dan jenis tutupan lahan tertentu dikaitkan dengan peningkatan risiko kebakaran, sementara kedekatan dengan sumber air dapat menurunkan risiko. Faktor manusia, khususnya aksesibilitas, dapat memengaruhi terjadinya kebakaran bahkan di daerah dengan kelembaban tinggi (Fitria et al., 2021). Selain itu, suhu yang panas dapat mempercepat penyebaran api karena meningkatkan energi panas di sekitar area yang terbakar. Oleh karena itu, wilayah dengan suhu permukaan yang tinggi lebih rentan terhadap kebakaran hutan dan lahan, terutama saat musim kemarau.

Data suhu permukaan lahan (*land surface temperature*) dalam penelitian ini diperoleh dari koleksi data USGS Landsat 8 Collection 2 Tier 1 Raw Scenes, yang menggunakan Band 10 sebagai kanal termal utama. Band 10 dipilih karena sensornya

mampu merekam emisi termal yang digunakan untuk menghitung suhu permukaan secara tidak langsung (Mardiati, 2022). Data ini memiliki resolusi spasial sebesar $100 \times 100 \text{ m}^2$, yang kemudian direduksi menjadi $30 \times 30 \text{ m}^2$ setelah proses resampling oleh USGS, sehingga memungkinkan analisis suhu permukaan dengan tingkat ketelitian yang lebih baik. Resolusi temporal data ini adalah 16 hari. Pengambilan data dilakukan dengan memfilter koleksi citra satelit selama satu musim. Setelah data difilter berdasarkan waktu, proses lebih lanjut dilakukan untuk menyesuaikan cakupan area dengan wilayah kajian. Hal ini dilakukan melalui proses clipping, di mana batas wilayah penelitian digunakan untuk memotong data sehingga hanya mencakup piksel yang berada dalam area yang sesuai. Skrip untuk memolah data Landsat 8 yang menghasilkan data LST dapat dilihat pada Gambar 4.

```
//=====>>>> Variabel Lingkungan (3): Suhu Rerata Permukaan <<<<=====
// Data induk: Landsat 8 L1 C2 (2019)
// Satuan dalam 'derajat Celcius'
var temp = ee.ImageCollection("LANDSAT/LC08/C02/T1")
    .filterDate('2019-01-01', '2019-12-31')
    .filter(ee.Filter.lt('CLOUD_COVER',20))
    .filterBounds(roi).select("B10");

// Mengolah parameter suhu citra
var first = temp.first();
var K1 = first.get('K1_CONSTANT_BAND_10');
var K2 = first.get('K2_CONSTANT_BAND_10');
var A = first.get('RADIANCE_ADD_BAND_10');
var M = first.get('RADIANCE_MULT_BAND_10');
print('Parameter A Variabel Suhu', A);
print('Parameter M Variabel Suhu', M);
print('Parameter K1 Variabel Suhu', K1);
print('Parameter K2 Variabel Suhu', K2);

// Melakukan konversi nilai suhu
var var3 = temp.map(function(img){
var id = img.id();

// Memasukkan formula: ((K2/(log(K1/((TIR*M)+A)+1)))-273)
Return img.expression ('(( 1321.0789 / (log (774.8853 / ( (TIR*0.0003342)
+0.1)+1)))-273)',{TIR: img})
    .rename('B10').copyProperties (img, ['system:time_start']));

var vis3 = {
    min: 10,
    max: 35,
    palette: ['001137', '0aab1e', 'e7eb05', 'ff4a2d', 'e90000'],
};

// Memotong citra variabel (3) sesuai ROI dan menampilkannya
var clipVar3 = var3.mean().rename('lst').clip(roi).toFloat();
print('Clip Var3', clipVar3);
Map.addLayer(clipVar3, vis3, 'Var3: Suhu Permukaan Rerata',0);
```

Gambar 4. Memanggil Variabel Suhu Permukaan

Normalized Difference Vegetation Index. Penelitian telah menunjukkan bahwa NDVI (*Normalized Difference Vegetation Index*) dapat digunakan untuk mengidentifikasi area dengan vegetasi kering yang lebih rentan terhadap kebakaran. Nilai NDVI yang lebih rendah menunjukkan lebih sedikit tutupan vegetasi hijau, yang sering dikaitkan dengan risiko kebakaran yang lebih tinggi (Parwati et al., 2012; Punari & Ardityo Danoesobroto, 2024). Analisis NDVI berdasarkan data satelit dapat membantu

memetakan area dengan potensi kebakaran yang tinggi, terutama selama musim kemarau (Parwati et al., 2012).

Normalized Difference Vegetation Index atau NDVI diperoleh dari koleksi data Harmonized Sentinel-2 MSI: *MultiSpectral Instrument*, yang tersedia di *Google Earth Engine*, Data Sentinel-2 memiliki resolusi spasial yang bervariasi, yaitu $10 \times 10 \text{ m}^2$ untuk band merah dan inframerah dekat yang digunakan dalam perhitungan NDVI, sehingga memungkinkan analisis vegetasi dengan tingkat ketelitian yang tinggi. Resolusi temporal Sentinel-2 adalah 5 hari. NDVI dihitung menggunakan kombinasi band merah (Red) dan band inframerah-dekat (*Near-Infrared*) dari Sentinel-2, yang dirancang untuk mengukur kesehatan dan kerapatan vegetasi (Pamuji et al., 2023). Pengambilan data dilakukan dengan memfilter koleksi citra Sentinel-2 berdasarkan rentang waktu satu musim. Setelah data difilter berdasarkan waktu, wilayah kajian digunakan untuk melakukan proses clipping, sehingga hanya area yang relevan dengan lokasi penelitian yang dianalisis.

Perhitungan NDVI dilakukan secara sistematis untuk setiap piksel dalam area kajian, dengan menggunakan rumus standar (Amin Lasaiba & Wahab Saud, 2022):

$$\text{NDVI} = (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red}) \quad (2.2)$$

Nilai NDVI yang dihasilkan berkisar antara -1 hingga 1, dimana nilai mendekati 1 menunjukkan vegetasi yang sehat dan padat, sementara nilai mendekati -1 menunjukkan area tanpa vegetasi, seperti badan air atau permukaan keras. Penggunaan data NDVI dari Sentinel-2 sangat penting dalam penelitian ini karena resolusi spasial dan spektral yang tinggi memungkinkan analisis vegetasi yang lebih rinci, memberikan wawasan penting tentang dinamika vegetasi di wilayah kajian. Skrip untuk memolah data Sentinel yang menghasilkan data NDVI dapat dilihat pada Gambar 5.

```
// =====>>>> Variabel Lingkungan (4): NDVI <<<<<=====
// Data induk: Sentinel-2A
var NDVI = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
    .filterDate('2023-01-01', '2023-12-31')
    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20))
    .median()
    .clip(roi);

var NDVI_param = {
  min: -1.00,
  max: 1.00,
  palette: [
    '000000', 'a50026', 'd73027', 'f46d43', 'fdae61', 'fee08b',
    'ffffbf', 'd9ef8b', 'a6d96a', '66bd63', '1a9850', '006837'
  ]
};

// Memotong citra variabel (4) sesuai ROI dan menampilkannya
var clipVar4 = NDVI.normalizedDifference(['B8', 'B4'])
    .rename('NDVI')
    .toFloat();
print('Clip Var4', clipVar4)
Map.addLayer(clipVar4, NDVI_param, 'Var4 - NDVI')
```

Gambar 5. Memanggil Variabel NDVI

Normalized Difference Water Index. *Normalized Difference Water Index* (NDWI) merupakan indeks yang efektif untuk menilai kadar air vegetasi dan tingkat kebasahan lahan (Permata et al., 2023; Haikal, 2014). Nilai NDWI yang lebih tinggi menunjukkan peningkatan kebasahan dan kelembaban vegetasi, yang dapat dipengaruhi oleh faktor-faktor seperti curah hujan, kepadatan vegetasi, dan fenomena iklim (Permata et al., 2023). Kadar air ini sangat penting untuk ketahanan vegetasi terhadap kebakaran, karena tingkat kelembaban yang lebih rendah selama musim kemarau meningkatkan potensi kebakaran (Kusuma et al., 2021b).

Data NDWI dalam penelitian diperoleh dari koleksi data Harmonized Sentinel-2 MSI: *MultiSpectral Instrument* yang tersedia di *Google Earth Engine*. NDWI dihitung menggunakan kombinasi Band 3 (*Green*) dan Band 11 (*Shortwave Infrared, SWIR*), di mana masing-masing band memiliki peran penting dalam mendeteksi kandungan air di permukaan. Band 3 (*Green*) digunakan untuk menangkap pantulan cahaya yang berasal dari vegetasi dan permukaan air, sedangkan Band 11 (*SWIR*) sangat sensitif terhadap kandungan air pada tanah dan permukaan lainnya. Kombinasi kedua band ini menghasilkan informasi yang akurat mengenai keberadaan dan distribusi air pada area kajian.

Pengambilan data dilakukan dengan memfilter koleksi Sentinel-2 berdasarkan rentang waktu satu musim. Setelah data difilter berdasarkan waktu, wilayah kajian didefinisikan melalui proses clipping, di mana hanya data yang mencakup area penelitian yang digunakan untuk analisis. Perhitungan NDWI dilakukan menggunakan rumus standar:

$$NDWI = (Green - SWIR) / (Green + SWIR) \quad (2.3)$$

Nilai NDWI yang dihasilkan berkisar antara -1 hingga 1, dengan nilai positif yang lebih tinggi menunjukkan keberadaan air yang signifikan, sedangkan nilai yang lebih rendah menunjukkan wilayah kering atau tanpa air. Skrip untuk memolah data Sentinel yang menghasilkan NDWI dapat dilihat pada Gambar 6.

```
// Data induk: Sentinel-2A
var NDWI = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
    .filterDate('2023-01-01', '2023-12-31')
    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20))
    .mean()
    .clip(roi);

var NDWI_param = {
  min: -1.00,
  max: 1.00,
  palette: [
    'FFFFFF', 'E0FFFF', 'AFEEEE', '00FFFF', '00CED1', '008B8B',
    '1E90FF', '000080'
  ]
};

// Memotong citra variabel (4) sesuai ROI dan menampilkannya
var clipVar5 = NDWI
    .normalizedDifference(['B3','B11'])
    .rename('NDWI').toFloat();

print('Clip Var5', clipVar5);
Map.addLayer(clipVar5, NDWI_param, 'Var5 - NDWI');
```

Gambar 6. Memanggil Variabel NDWI

Kemiringan Lereng (Slope). Penelitian menunjukkan bahwa kemiringan lereng memengaruhi kebakaran hutan dan lahan. Lereng yang lebih curam mempercepat penyebaran api dibandingkan dengan penyebaran api yang menurun (Lisda et al., 2024). Namun, hubungan antara lereng dan potensi kebakaran bersifat kompleks. Sebuah penelitian yang menggunakan klasifikasi Naive Bayes mencapai akurasi 99% dalam memprediksi potensi kebakaran berdasarkan lereng (Lisda et al., 2024b). Kemiringan juga memengaruhi tingkat infiltrasi, dengan lereng yang lebih landai (0-8%) menunjukkan infiltrasi yang lebih tinggi daripada yang lebih curam (8-23%) (Kianendra et al., 2022).

Dalam penelitian ini, data kemiringan lereng (*slope*) diperoleh dari Website Tanah Air Indonesia, yang menyediakan informasi topografi *Digital Elevation Model National* (DEMNAS). DEMNAS hadir dengan resolusi spasial 0,27 detik busur (sekitar 8 meter) (Iswari & Anggraini, 2018; Julzarika & Harintaka, 2019). Data ini diunduh dan kemudian diolah menggunakan ArcGIS untuk menghasilkan peta kemiringan lereng yang merepresentasikan variasi ketinggian dan kemiringan wilayah kajian di Kabupaten Luwu Timur. Kemiringan lereng dihitung berdasarkan perubahan elevasi antar piksel dan diklasifikasikan ke dalam beberapa kategori berdasarkan tingkat kecuramannya. Kemiringan lereng diklasifikasikan menjadi lima kelas utama berdasarkan persentase kemiringan, yaitu: Datar (0–8%); Landai (8–15%); Agak Curam (15–25%); Curam (25–45%); dan Sangat Curam (>45%) (Republik Indonesia, 1980).

Setelah data slope diklasifikasikan, hasilnya diekspor dan diunggah ke *Google Earth Engine* untuk dianalisis lebih lanjut dalam konteks penelitian kebakaran hutan dan lahan. Skrip untuk memanggil data kemiringan lereng dapat dilihat pada Gambar 7.

```
var slope = ee.Image("users/arturprayudasude/Slope");

// Memotong variabel slope sesuai ROI dan menampilkannya
var clipVar6 = slope.clip(roi).toFloat();
print('Clip Var6', clipVar6);
Map.addLayer(clipVar6, {}, 'Slope');
```

Gambar 7. Memanggil Variabel Kemiringan Lereng

Jarak Sumber Air. Daerah yang lebih dekat dengan sumber air cenderung memiliki kelembaban yang lebih tinggi dan risiko kebakaran yang lebih rendah. Di Cianjur, daerah yang lebih jauh dari pegunungan dan lebih dekat ke laut mengalami lebih banyak kekeringan karena curah hujan yang lebih rendah dan pasokan air yang terbatas dari dataran tinggi (Permadi & Adiputra, 2019). Sebuah studi di Jakarta Barat menemukan bahwa 82% wilayah Kecamatan Tambora memiliki aksesibilitas yang rendah terhadap sumber air untuk pemadaman kebakaran, sebagian karena terbatasnya hidran dan bantaran sungai yang tidak dapat diakses (Tsaqila et al., 2021).

Dalam penelitian ini, data jaringan sungai dan danau (sumber air) diperoleh dari Rupa Bumi Indonesia (RBI) yang disediakan oleh Badan Informasi Geospasial (BIG) dalam format Shapefile (.shp). Data RBI mencakup informasi detail mengenai berbagai jenis badan air, seperti sungai utama, anak sungai, dan kanal, yang telah melalui proses kartografi resmi dan diverifikasi. Setelah data sungai diperoleh, proses selanjutnya adalah pengolahan menggunakan tools *Proximity* di QGIS untuk menghitung jarak setiap lokasi terhadap jaringan sungai terdekat. Analisis ini menghasilkan peta raster jarak

sungai, yang merepresentasikan jarak setiap piksel dari sungai terdekat dalam satuan meter. Data hasil analisis kemudian diekspor dalam format GeoTIFF, sehingga kompatibel untuk digunakan dalam *Google Earth Engine*.

Data raster jarak sungai yang telah diolah kemudian diunggah ke dalam GEE yang dapat dilihat pada Gambar 8. Data ini menjadi salah satu variabel yang diperhitungkan pengaruhnya terhadap kebakaran hutan dan lahan.


```
var jarak_sungai = ee.Image("users/arturprayudasude/jarak_dari_sungai");

// Memotong variabel jarak dari sungai sesuai ROI dan menampilkannya
var clipVar7 = jarak_sungai.clip(roi).rename('JS').toFloat();
print('Clip Var7', clipVar7);
Map.addLayer(clipVar7, {}, 'Jarak Sungai',0);
```

Gambar 8. Memanggil Variabel Jarak dari Sumber Air

Jarak Dari Jalan. Penelitian menunjukkan bahwa aktivitas manusia, khususnya kedekatan dengan jalan dan pemukiman, secara signifikan memengaruhi risiko kebakaran hutan dan lahan. Jarak dari jaringan jalan dan desa merupakan faktor kunci dalam model spasial kerentanan kebakaran (Novita & Vonnisa, 2021; Susilawati & Syam'ani, 2021). Aksesibilitas jalan berkontribusi besar terhadap terjadinya kebakaran, dengan frekuensi titik api meningkat drastis semakin jauh dari jalan (Susilawati & Syam'ani, 2021).

Dalam penelitian ini, data jaringan jalan diperoleh dari *OpenStreetMap* (OSM) dan Badan Informasi Geospasial (BIG), yang kemudian dikombinasikan sebagai sumber data spasial untuk infrastruktur jalan. Pengunduhan data OSM dilakukan menggunakan plugin OSM Downloader (lihat di Gambar 9) pada perangkat lunak QGIS, yang memungkinkan ekstraksi data jaringan jalan secara langsung dengan menyesuaikan batas wilayah kajian. Sementara itu, data jaringan jalan dari BIG diunduh melalui portal Ina-Geoportal (<https://tanahair.indonesia.go.id>), dengan memilih dataset yang sesuai, kemudian mengunduhnya dalam format Shapefile (.shp). Setelah semua data berhasil diunduh, dilakukan proses pengolahan dan penyelarasan untuk memastikan kesesuaian antara kedua sumber, dengan berbagai kelas jalan yang mencakup jalan utama, jalan sekunder, dan jalan lokal.



Gambar 9. Plugin OSM Downloader QGIS

Setelah data jaringan jalan diperoleh, proses selanjutnya adalah pengolahan data menggunakan tools *Proximity* di QGIS untuk menghitung jarak setiap lokasi terhadap jaringan jalan terdekat. Analisis ini menghasilkan peta raster jarak jalan, yang merepresentasikan jarak setiap piksel dari jalan terdekat dalam satuan meter. Data hasil analisis kemudian diekspor dalam format GeoTIFF agar kompatibel dengan platform GEE. Yang kemudian di input ke GEE sebagai salah satu variabel yang diperhitungkan

pengaruhnya terhadap kebakaran hutan dan lahan. Skrip untuk memanggil data jarak jalan dapat dilihat pada Gambar 10.

```
var jarak_jalan = ee.Image("users/arturprayudasude/jarak_dari_jalan");

// Memotong variabel jarak dari jalan sesuai ROI dan menampilkannya
var clipVar8 = jarak_jalan.clip(roi).toFloat();
print('Clip Var8', clipVar8);
Map.addLayer(clipVar8, {}, 'Jarak Jalan');
```

Gambar 10. Memanggil Variabel Jarak dari Jalan

2.3.4 Menjalankan Model *Maximum Entropy*

Dalam penelitian ini, pemodelan *Maximum Entropy* dijalankan menggunakan GEE untuk memprediksi distribusi probabilitas kehadiran kebakaran hutan dan lahan berbasis data lingkungan dan titik kejadian di tiap musim dari tahun 2020 sampai 2024. Setiap menjalankan model untuk satu periode akan dilakukan iterasi sebanyak sepuluh kali perulangan untuk memastikan kestabilan hasil dan mengurangi kemungkinan bias dalam prediksi. Proses ini diawali dengan menyiapkan data kehadiran (*occurrence points*) yang diklasifikasikan sebagai kelas 1, serta pembuatan titik latar belakang (*background points*) dalam jumlah lima kali lipat dari jumlah titik kehadiran yang tersebar secara acak di dalam wilayah kajian. *Background points* dalam model MaxEnt adalah titik-titik yang dipilih secara acak (lihat pada Gambar 11) dari wilayah kajian yang digunakan untuk mewakili kondisi lingkungan tempat fenomena yang dikaji bisa atau tidak bisa terjadi. Titik-titik ini berfungsi sebagai pembanding terhadap titik kehadiran (*occurrence points*) dalam proses pemodelan, sehingga memungkinkan MaxEnt untuk memperkirakan distribusi probabilitas kehadiran spesies atau fenomena berdasarkan perbedaan karakteristik lingkungan di antara keduanya. Kedua jenis titik ini kemudian digabungkan menjadi satu dataset yang digunakan sebagai sampel untuk pelatihan dan pengujian model. Adapun skrip untuk membuat titik perwakilan ketidak hadirannya dapat dilihat pada Gambar 11.

```
// MEMBUAT TITIK PEWAKIL KETIDAK HADIRAN KEJADIAN
function createBackgroundPoints(region, n) {
  return ee.FeatureCollection.randomPoints({
    region: roi,
    points: dataOccurrence.size().multiply(5),
    seed: 123
  }).map(function(feature) {
    return feature.set('class', 0);
  });
}
```

Gambar 11. Membuat Titik Perwakilan Ketidak Hadiran Kejadian

Selanjutnya, data sampel ini dibagi menjadi dua subset berdasarkan rasio 70:30, dengan 70% data digunakan untuk pelatihan dan 30% sisanya untuk pengujian model, skrip pembuatannya dapat dilihat pada Gambar 12. Untuk setiap titik sampel, nilai dari variabel lingkungan diekstrak menggunakan fungsi *sampleRegions*, sehingga menghasilkan dataset yang siap untuk diklasifikasikan dan skriptnya dapat dilihat pada Gambar 13. Model MaxEnt kemudian dilatih menggunakan fungsi *ee.Classifier.amnhMaxent()* dengan berbagai parameter, seperti *betaMultiplier*, aktivasi fitur linear hingga hinge, serta opsi untuk tidak melakukan extrapolation guna menghindari prediksi di luar domain data pelatihan. Model ini dilatih dengan dataset yang

telah dipersiapkan dan diklasifikasikan menggunakan variabel lingkungan yang tersedia yang dapat dilihat skripnya pada Gambar 14.

```
function SDM(x) {
  var seedRaw = ee.Number(x);

  // RASIO SPLIT
  var split = 0.7; // 70% training, 30% testing

  // MENYIAPKAN DATA TITIK KEJADIAN
  var occurrencePoints = dataOccurrence.map(function(feature) {
    return feature.set('class', 1);
  });

  // MENYIAPKAN TITIK PEWAKIL KETIDAK HADIRAN KEJADIAN
  var backgroundPoints = createBackgroundPoints(
    roi,
    occurrencePoints.size().multiply(3)
  );
  // MENYATUKAN TITIK UNTUK PEMODELAN
  var allPoints = occurrencePoints.merge(backgroundPoints);
```

Gambar 12. Pembuatan Data Titik untuk Training dan Testing Model

```
//PEMISAHAN ACAK UNTUK TRAINING AND TESTING
var withRandom = allPoints.randomColumn('random', seedRaw);
var training = withRandom.filter(ee.Filter.lt('random', split));
var testing = withRandom.filter(ee.Filter.gte('random', split));

// PEMBACAAN NILAI VARIABEL MENURUT SAMPEL DATA TITIK
var trainingData = stackedVars.sampleRegions({
  collection: training,
  properties: ['class'],
  scale: pixSize
});
```

Gambar 13. Pembuatan Titik untuk Training dan Testing Model dan Pembacaan Nilai Tiap Variabel Oleh *Machine Learning*

```
// MENJALANKAN MODEL MAXENT DENGAN VARIABEL YANG TELAH DISIAPKAN
var classifier = ee.Classifier.amnhMaxent({
  betaMultiplier: 0.5,
  autoFeature: true,
  linear: true,
  quadratic: true,
  product: true,
  threshold: true,
  hinge: true,
  extrapolate: false,
  doClamp: true,
  writeClampGrid: true,
  seed: seedRaw
}).setOutputMode('PROBABILITY');

var trained = classifier
  .train(trainingData, 'class', stackedVars.bandNames());
var finalPr = stackedVars.classify(trained);
var classProb = finalPr.select('probability')
```

Gambar 14. Menjalankan Model Pelatihan MaxEnt

Setelah model MaxEnt dilatih, hasil prediksi probabilitas kehadiran dihasilkan dalam bentuk peta raster yang merepresentasikan peluang keberadaan fenomena yang dikaji di setiap piksel dalam wilayah penelitian. Selain itu, analisis kontribusi variabel dilakukan untuk mengidentifikasi faktor lingkungan yang paling berpengaruh terhadap prediksi model. Evaluasi model juga dilakukan dengan menghitung nilai *Area Under the Curve - Receiver Operating Characteristic* (AUC-ROC), yang menunjukkan tingkat keakuratan model dalam membedakan antara titik kehadiran dan titik latar belakang (Gambar 15). Dengan demikian, proses ini memungkinkan pemetaan potensi distribusi fenomena yang diteliti secara lebih akurat dan berbasis data lingkungan yang komprehensif. Adapun keseluruhan skrip pemodelan dapat diakses pada Lampiran 1.

```
// Menghitung Kontribusi Variabel
var importance = trained.explain();
var variableImportance = ee.Dictionary(importance).get(
    'Contributions');

var AUCroc = ee.Dictionary(importance).get(
    'Training AUC');

var lambdas = ee.Dictionary(importance).get(
    'Lambdas');

return ee.Dictionary({
    'prediction': finalPr,
    'importance': variableImportance,
    'Nilai AUC-ROC': AUCroc,
    'Lambdas': lambdas,
    'training': training,
    'testing': testing
})
```

Gambar 15. Menghitung Nilai AUC-ROC hasil pemodelan

2.3.5 Evaluasi Model dan Analisis Hasil

Evaluasi model dalam penelitian ini dilakukan untuk mengukur kinerja MaxEnt dalam memprediksi distribusi probabilitas fenomena yang dikaji. Proses modeling akan dievaluasi dengan menggunakan *Receiver Operating Characteristic* (ROC) dan validasi hasil dengan menggunakan nilai *Area Under Curve* (AUC) (Zainal et al., 2022). Area di bawah kurva karakteristik operasi relatif AUC ROC digunakan untuk menentukan keakuratan model Maxent. AUC adalah area tertutup antara kurva ROC dan absis, dengan nilainya biasanya ditetapkan antara 0,5 hingga 1,0. Semakin besar nilainya, semakin kuat kemampuan prediksi model; AUC sebesar 0,5 setara dengan prediksi yang sepenuhnya acak, dan AUC sebesar 1 adalah prediksi yang sempurna. Nilai AUC antara 0,5 dan 0,6 berarti model gagal, dan model itu sendiri tidak memiliki daya prediksi; nilai antara 0,6 dan 0,7 menunjukkan prediksi yang buruk. Nilai AUC antara 0,7 dan 0,8 menunjukkan prediksi cukup. Nilai antara 0,8 dan 0,9 menunjukkan prediksi yang baik. Dan nilai >0,9 menunjukkan model dengan akurasi prediksi yang sangat baik (Çorbacioğlu & Aksel, 2023). Selain itu, dilakukan juga analisis *Variable Contribution & Permutation Importance* untuk menilai variabel lingkungan mana yang memiliki kontribusi paling besar terhadap prediksi model.

Selanjutnya, analisis hasil dilakukan dengan menginterpretasikan peta distribusi probabilitas yang dihasilkan oleh model MaxEnt. Dengan cara merata-ratakan nilai dari

setiap layer peta dalam 5 tahun (sepuluh peta) sehingga dapat dilakukan evaluasi pola spasial dari prediksi untuk mengidentifikasi kecenderungan distribusi di wilayah kajian, yang dapat memberikan wawasan tentang faktor lingkungan yang paling berpengaruh dalam menentukan keberadaan fenomena yang dikaji. Selain itu, hubungan antara variabel lingkungan utama dengan distribusi prediksi dianalisis untuk mengidentifikasi faktor dominan yang memengaruhi pola sebaran. Semakin tinggi probabilitas yang diprediksi oleh model, semakin besar kemungkinan fenomena tersebut terjadi di suatu wilayah. Evaluasi ini bertujuan untuk memahami keterkaitan antara kondisi lingkungan dan potensi kehadiran fenomena yang dikaji di wilayah penelitian.

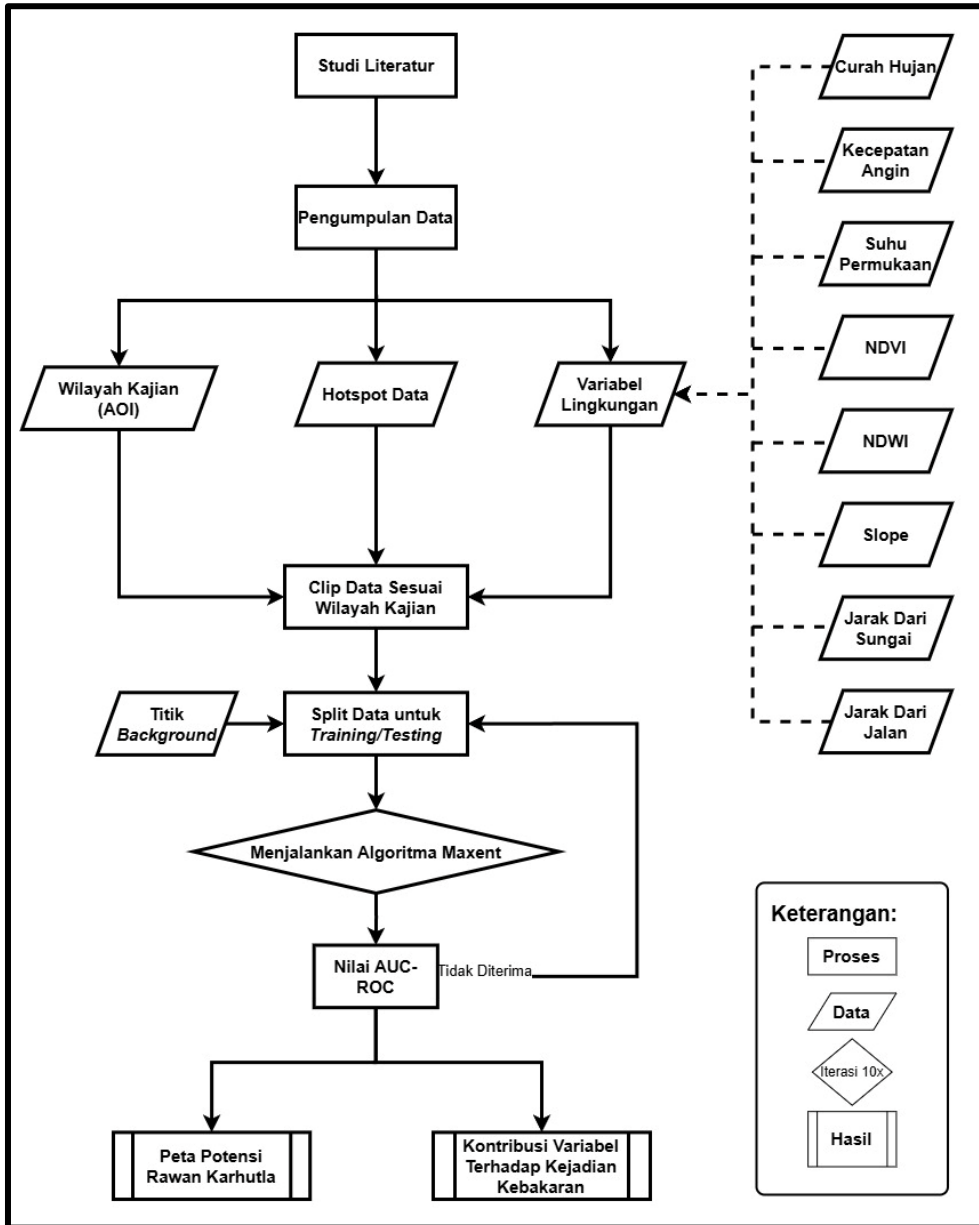
Peta kerawanan kebakaran yang dibuat menggunakan model MaxEnt menunjukkan kemungkinan terjadinya kebakaran. Semakin tinggi nilai probabilitas, semakin besar peluang kebakaran terjadi di suatu wilayah. Dalam penelitian ini, probabilitas yang terdapat pada peta hasil pemodelan MaxEnt dibagi menjadi empat kategori, dapat dilihat pada Tabel 2.

Tabel 2. Kategori Potensi

Nilai Pixel	Keterangan
> 0,6	Potensi Sangat Tinggi
0,4 - 0,6	Potensi Tinggi
0,2 - 0,4	Potensi Sedang
< 0,2	Potensi Rendah
-	Tidak Terklasifikasi

(Nurandi Rachim et al., 2024)

Klasifikasi ini digunakan untuk mengidentifikasi tingkat potensi pada suatu wilayah, di mana semakin tinggi nilai pixel, semakin besar potensi yang dimiliki. Namun dalam klasifikasi hasil di GEE terkadang terdapat lokasi yang tidak terklasifikasi dikarenakan tidak tersedianya salah satu variabel di lokasi tersebut untuk di-*overlay* sehingga dikategorikan ke dalam kelas tidak terklasifikasi. Adapun keseluruhan prosedur secara ringkas dapat dilihat pada Gambar 16.



Gambar 16. Diagram Alir Penelitian