

TESIS

**DATA MINING UNTUK PREDIKSI KEBAKARAN HUTAN
TERINTEGRASI DENGAN SISTEM INFORMASI GEOGRAFIS**



Disusun oleh:

Nama : Prasetyo Mimbora
NIM : 21.55.1071
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

TESIS

**DATA MINING UNTUK PREDIKSI KEBAKARAN HUTAN TERINTEGRASI
DENGAN SISTEM INFORMASI GEOGRAFIS**

**DATA MINING FOR FOREST FIRE PREDICTION INTEGRATED WITH
GEOGRAPIC INFORMATION SYSTEMS**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Prasetyo Mimbora
NIM : 21.55.1071
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

HALAMAN PENGESAHAN

**DATA MINING UNTUK PREDIKSI KEBAKARAN HUTAN TERINTEGRASI
DENGAN SISTEM INFORMASI GEOGRAFIS**

**DATA MINING FOR FOREST FIRE PREDICTION INTEGRATED WITH
GEOGRAPIC INFORMATION SYSTEMS**

Dipersiapkan dan Disusun oleh

Prasetyo Mimboro

21.55.1071

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Sabtu, 5 Agustus 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 5 Agustus 2023

Rektor

ProL Dr. M. Suyanto, M.M.

NIK. 190302001

HALAMAN PERSETUJUAN

DATA MINING UNTUK PREDIKSI KEBAKARAN HUTAN TERINTEGRASI DENGAN SISTEM INFORMASI GEOGRAFIS

DATA MINING FOR FOREST FIRE PREDICTION INTEGRATED WITH GEOGRAPHIC INFORMATION SYSTEMS

Dipersiapkan dan Disusun oleh

Prasetyo Mimboro

21.55.1071

Telah Dinjikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Sabtu, 5 Agustus 2023

Pembimbing Utama

Prof. Dr. Kusriani, M.Kom
NIK. 190302106

Anggota Tim Penguji

Hanafi, S.Kom., M.Eng., Ph.D.
NIK. 190302024

Pembimbing Pendamping

Arif Dwi Laksito, M. Kom
NIK. 190302150

Dr. Kumara Ari Yuana, S.T., M.T.
NIK. 190302575

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 5 Agustus 2023
Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Prasetyo Mimboro
NIM : 21.55.1071
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:
**DATA MINING UNTUK PREDIKSI KEBAKARAN HUTAN TERINTEGRASI
DENGAN SISTEM INFORMASI GEOGRAFIS**

Dosen Pembimbing Utama : Prof. Dr. Kusrini, M.Kom
Dosen Pembimbing Pendamping : Arif Dwi Laksito, M. Kom

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakberuan dalam pernyataan ini, maka **SAYA bersedia menerima SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 5 Agustus 2023

Yang Menyatakan,




Prasetyo Mimboro

HALAMAN MOTTO

“an Investment in education gives the best returns” Benjamin Franklin

“Education is not preparation for life; education is life itself” John Dewey



KATA PENGANTAR

Puji syukur Alhamdulillah penulis panjatkan kepada Allah S.W.T, karena atas Rahmat, hidaya dan karunia-Nya yang telah diberikan kepada penulis sehingga mampu menyelesaikan tesis yang berjudul “Data Mining untuk Prediksi Kebakaran Hutan Terintegrasi dengan Sistem Informasi Geografis”. Tesis ini disusun sebagai salah satu syarat dalam menyelesaikan pendidikan Pasca Sarjana (S2) Program Studi Magister Teknik Informatika Universitas AMIKOM.

Penulis menyadari bahwa dalam penulisan tesis ini masih terdapat kekurangan dan jauh dari kesempurnaan, baik karena keterbatasan ilmu yang dimiliki maupun kemampuan penulis, tetapi berkat pertolongan Allah S.W.T serta dorongan dari semua pihak, akhirnya penulisan tesis ini dapat terselesaikan. Tesis ini tidak lepas dari bantuan berbagai pihak, penulis menyampaikan rasa terima kasih kepada:

1. Prof. Dr. M. Suyanto, M.M selaku rektor Universitas AMIKOM Yogyakarta.
2. Prof. Dr. Kusri, M.Kom selaku Direktur Pasca Sarjana Universitas AMIKOM Yogyakarta dan selaku Pembimbing I yang telah meluangkan waktu, pikiran serta perhatiannya guna memberikan bimbingan dan arahan sehingga tesis ini dapat terselesaikan.
3. Arif Dwi Laksito, M. Kom selaku Pembimbing II yang telah meluangkan waktu, pikiran dan perhatian serta *sharing session* guna memberikan bimbingan dan arahan sehingga tesis ini dapat terselesaikan.
4. Tim Silvanus Universitas AMIKOM yang telah memberikan support dan pengalaman baru dalam mencari solusi dan inovasi dalam mengatasi kebakaran hutan dan lahan.

Penulis menyadari bahwa tesis ini masih jauh dari kesempurnaan, akan tetapi penulis berharap semoga tesis ini bermanfaat dan memberikan pengetahuan tambahan bagi pembacanya.

Yogyakarta, 5 Agustus 2023

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN MOTTO.....	vi
KATA PENGANTAR.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR.....	xii
INTISARI.....	xv
<i>ABSTRACT</i>	xvi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	6
1.5. Manfaat Penelitian.....	7
BAB II TINJAUAN PUSTAKA.....	8
2.1. Tinjauan Pustaka.....	8
2.2. Keaslian Penelitian.....	33
2.3. Landasan Teori.....	67

BAB III METODE PENELITIAN.....	76
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	76
3.2. Metode Pengumpulan Data.....	76
3.3. Metode Analisis Data.....	84
3.4. Alur Penelitian.....	86
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....	90
4.1. Teknik Data Mining, Scheduler Script Export Data dan Joining Data Tabular ke Data Spasial.....	90
4.2. Clusterisasi data untuk mendapatkan nilai DB-Index tertinggi dengan Metode David Bouldin Index (DBI).....	101
4.3. Faktor-faktor terjadinya Kebakaran Hutan.....	125
4.4. Integrasi dan Implementasi Machine Learning ke dalam Sistem Informasi Geografis (SIG).....	176
4.5. Membuat Model Machine Learning.....	183
4.5.1.....	188
4.5.2.....	190
BAB V PENUTUP.....	189
5.1. Kesimpulan.....	189
5.2. Saran.....	189
DAFTAR PUSTAKA.....	190
LAMPIRAN.....	202

DAFTAR TABEL

Tabel 2.1 Matriks literatur review dan posisi penelitian.....	37
Tabel 2.2. Klasifikasi Tingkat Bahaya FPMC	74
Tabel 2.3 Klasifikasi Tingkat Bahaya DC	74
Tabel 2.4 Klasifikasi Tingkat Bahaya FWI	74
Tabel 3.1 Karakteristik spektrum panjang gelombang dan resolusi spasial masing-masing saluran Sentinel-2	82
Tabel 3.2 Parameter Yang Digunakan Untuk Mengunduh Data	83
Tabel 3.3 Struktur Tabel Data Kejadian Bencana Kebakaran Hutan.....	85
Tabel 3.4 Data Perkiraan Cuaca sumber KLHK dan BMKG	86
Tabel 3.5 Data Kualitas Udara	87
Tabel 3.6 Data Titik Api (Hot Spot)	87
Tabel 3.7 Rencana Jadwal Penelitian.....	95
Tabel 4.1 Sumber dataset	106
Tabel 4.2 Jenis variable data yang dihasilkan dari proses data mining	109
Tabel 4.3 Perbandingan data lengkap dan tidak lengkap	111
Tabel 4.4 Hasil Evaluasi Clustering.....	116
Tabel 4.5 Jumlah Penduduk dan Pendapatan per Kapita (PPK) Kota Palangka Raya Berdasarkan Data Konsolidasi Bersih (DKB) KEMENDAGRI SEMESTER II TAHUN 2021.....	119
Tabel 4.6 Hasil perhitungan Pendapatan per Kapita per kelurahan	120
Tabel 4.7 Rentang nilai sebagai dasar perhitungan GDP	122
Tabel 4.8 Nilai GDP berdasarkan skor label.....	122
Tabel 4.9 Hasil perhitungan GDP per kelurahan dan skor label.....	122
Tabel 4.10 Data kepadatan penduduk area penelitian.....	123
Tabel 4.11 Rentang nilai sebagai dasar perhitungan kepadatan penduduk.....	124
Tabel 4.12 Nilai kepadatan penduduk berdasarkan skor label.....	125
Tabel 4.13 Data kepadatan penduduk area penelitian dan skor label populasi.....	125
Tabel 4.14 Klasifikasi Jarak ke Pemukiman/Distance to Settlement (DS) dan skor label.....	126

Tabel 4.15 Klasifikasi Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR) dan skor label	128
Tabel 4.16 Data Kejadian Kebakaran Hutan di wilayah penelitian periode tahun 2018-2021	130
Tabel 4.17 Klasifikasi Kejadian Kebakaran Hutan/Historical Fire (HiF) dan skor label 4 kelas	132
Tabel 4.18 Klasifikasi Kejadian Kebakaran Hutan/Historical Fire (HiF) dan skor label 7 kelas	133
Tabel 4.19 Klasifikasi Material atau Bahan yang dapat terbakar dan tersedia di hutan/Fuel Load dan skor label	135
Tabel 4.20 Rentang Nilai NDVI	136
Tabel 4.21 Klasifikasi nilai NDVI	136
Tabel 4.22 Klasifikasi Jenis Vegetasi dan skor label	140
Tabel 4.23 Klasifikasi Curah Hujan/Precipitation dan skor label	141
Tabel 4.24 Klasifikasi Jenis Vegetasi dan skor label	143
Tabel 4.25 Klasifikasi Temperatur/Temperature dan skor label	144
Tabel 4.26 Klasifikasi ketinggian/elevasi dan skor label	146
Tabel 4.27 Rentang nilai kelerengan/slope	149
Tabel 4.28 Klasifikasi kelerengan/slope dan skor label	149
Tabel 4.29 Klasifikasi arah lereng/aspect dan skor label	153

DAFTAR GAMBAR

Gambar 3.1 Lokasi Penelitian	84
Gambar 3.2 Batas Administratif dan Jaringan Jalan Lokasi Penelitian	85
Gambar 3.3 Diagram Alur Penelitian.....	90
Gambar 3.4 Diagram Alur Penelitian.....	91
Gambar 3.5 Diagram flow chart proses data mining menjadi data base baru.....	93
Gambar 3.6 Diagram Alur Proses Penelitian	94
Gambar 4.1 Contoh tampilan website MenLHK sumber ke-1 data perkiraan cuaca	100
Gambar 4.2 Contoh tampilan website BMKG sumber ke-2 data perkiraan cuaca	101
Gambar 4.3 Contoh tampilan website MenLHK sumber ke-1 data kualitas udara	102
Gambar 4.4 Contoh tampilan website LAPAN sumber ke-1 data titik panas/hot spot	103
Gambar 4.5 Contoh tampilan website ESRI sumber ke-2 data titik panas/hot spot dengan sensor VIIRS.....	104
Gambar 4.6 Diagram Proses Penelitian	106
Gambar 4.7 Preprocessing Data.....	107
Gambar 4.8 Visualisasi hasil data mining secara spasial.....	108
Gambar 4.9 Proses pemanggilan data ke dalam Google Colab	111
Gambar 4.10 Proses identifikasi data set di dalam Google Colab	111
Gambar 4.11 Preview data yang di olah di Google Colab	112
Gambar 4.12 Tahapan pre-prosesing data di Google Colab	114
Gambar 4.13 Preview feature yang ada dalam data set di Google Colab	114
Gambar 4.14 Tampilan data set di Google Colab	115
Gambar 4.15 Analisis K-Means di Google Colab	115
Gambar 4.16 Sebaran data cuaca berdasarkan hasil pengolahan di Google Colab	116

Gambar 4.17 Sebaran data hot spot berdasarkan hasil pengolahan di Google Colab	116
Gambar 4.18 Hasil evaluasi DB Index di Google Colab	118
Gambar 4.19 Skor DBI untuk beberapa klaster (k).....	119
Gambar 4.20 Peta hasil analisis Jarak ke Pemukiman/Distance to Settlement (DS)	131
Gambar 4.21 Peta hasil analisis Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR).....	132
Gambar 4.22 Data Historis Kebakaran Hutan (a)	135
Gambar 4.23 Data Historis Kebakaran Hutan (b)	135
Gambar 4.24 Data hasil buffer titik kejadian kebakaran hutan.....	137
Gambar 4.25 Peta hasil analisis material atau bahan yang dapat terbakar dan tersedia di hutan/Fuel Load.....	139
Gambar 4.26 Citra NDVI dan sebaran nilai NDVI (terendah – tertinggi).....	142
Gambar 4.27 Peta hasil analisis reklasifikasi nilai NDVI menjadi 4 kriteria	142
Gambar 4.28 Peta hasil nilai NDVI berdasarkan 4 kriteria.....	143
Gambar 4.29 Peta hasil analisis jenis vegetasi/vegetation type berdasarkan 4 kriteria	145
Gambar 4.30 Peta hasil analisis curah hujan/precipitation berdasarkan 4 kriteria	146
Gambar 4.31 Peta hasil analisis penggunaan lahan (land usage) berdasarkan 4 kriteria	148
Gambar 4.32 Peta hasil analisis temperatur/temperature berdasarkan 4 kriteria ..	149
Gambar 4.33 Citra DEM dan sebaran nilai ketinggian/elevation (terendah – tertinggi).....	150
Gambar 4.34 Peta hasil analisis reklasifikasi nilai ketinggian/elevation menjadi 4 kriteria	151
Gambar 4.34 Peta hasil nilai ketinggian/elevation berdasarkan 4 kriteria.....	152
Gambar 4.35 Citra DEM dan sebaran nilai lereng/slope (terendah – tertinggi) ..	154
Gambar 4.36 Peta hasil analisis reklasifikasi nilai lereng/slope menjadi 4 kriteria	155
Gambar 4.37 Peta hasil nilai lereng/slope berdasarkan 4 kriteria	156

Gambar 4.38 Citra DEM dan sebaran nilai arah lereng/aspect (terendah – tertinggi).....	158
Gambar 4.39 Citra DEM dan sebaran nilai arah lereng/aspect (terendah – tertinggi) warna grayscale.....	159
Gambar 4.40 Peta hasil analisis reklasifikasi nilai arah lereng/aspect menjadi 6 kriteria	160
Gambar 4.41 Peta hasil nilai arah lereng/aspect menjadi 6 kriteria	161
Gambar 4.42 Tampilan halaman depan (home page) framework “The Forest Fire Prediction”.....	171
Gambar 4.43 Tampilan hasil prediksi framework “The Forest Fire Prediction” terhadap area terbakar dan area tidak terbakar	171
Gambar 4.44 Tampilan fitur Available Model framework “The Forest Fire Prediction”.....	172
Gambar 4.45 Menu pilihan algoritma SVM.....	156
Gambar 4.45 Menu pilihan algoritma RF.....	157

INTISARI

Kebakaran hutan dan lahan merupakan masalah serius yang mempengaruhi lingkungan dan kehidupan manusia. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan framework untuk prediksi kebakaran hutan yang terintegrasi dengan Sistem Informasi Geografis (SIG) menggunakan algoritma Support Vector Machine (SVM) dan Random Forest (RF), serta menjawab 4 tujuan penelitian yang meliputi teknik Data Mining, Scheduler Export Data dan Joining Data Tabular dan Spasial, melakukan clustering untuk mendapatkan nilai DB-Index tertinggi dengan Metode David Bouldin Index (DBI), mengetahui faktor-faktor terjadinya kebakaran hutan, dan mengintegrasikan Machine Learning dengan SIG.

Metode penelitian ini melibatkan pengumpulan data sekunder mengenai kebakaran hutan dan lahan, serta data spasial seperti peta penggunaan lahan, peta iklim, dan peta topografi. Data yang diperoleh kemudian diolah menggunakan teknik Data Mining, Scheduler Export Data, dan Joining Data Tabular dan Spasial. Selanjutnya, dilakukan analisis clustering untuk mendapatkan nilai DB-Index tertinggi dengan Metode David Bouldin Index (DBI) guna memperoleh kelompok cluster yang optimal. Data yang telah diproses dan dianalisis digunakan sebagai input untuk pembuatan model prediksi menggunakan algoritma SVM dan Random Forest.

Hasil penelitian menunjukkan bahwa framework yang terintegrasi dengan SIG dan menggunakan algoritma SVM dengan rata-rata *test accuracy* 0.9956, *train accuracy* 0.9956 dan RF dengan rata-rata *test accuracy* 0.994, *train accuracy* 0.9969 dapat menghasilkan prediksi kebakaran hutan yang akurat dengan. Selain itu, hasil analisis clustering dengan Metode DBI dapat memberikan kelompok cluster yang optimal untuk memahami pola kebakaran hutan. Dari hasil analisis juga ditemukan bahwa terdapat beberapa faktor-faktor yang mempengaruhi terjadinya kebakaran hutan, yang meliputi suhu, kelembaban udara, curah hujan, jenis vegetasi, dan faktor spasial seperti jarak dari pemukiman manusia.

Penelitian ini juga berhasil mengintegrasikan Machine Learning dengan SIG dalam framework *"The Forest Fire Prediction"* untuk prediksi kebakaran hutan, yang dapat digunakan sebagai basis untuk pengambilan kebijakan dan pengelolaan resiko kebakaran hutan dan lahan yang lebih efektif.

Kata Kunci: Data mining, Kebakaran hutan, Sistem Informasi Geografis, Algoritma SVM, Random Forest, Variabel faktor, Clustering, Metode David Bouldin Index (DBI).

ABSTRACT

Forest and land fires are a serious problem that affects the environment and human life. Therefore, the research aims to develop a framework for forest fire prediction that is integrated with the Geographic Information System (GIS) using the Support Vector Machine (SVM) and Random Forest (RF) algorithms, as well as responding to 4 research goals that include Data Mining techniques, Scheduler Data export, joining tabular and spatial data, performing clustering to obtain the highest DB-Index value with the David Bouldin Index (DBI) Method, identifying forest fire factors, and integrating Machine Learning with SIG.

This research method involves the collection of secondary data on forest and land fires as well as spatial data such as land use maps, climate maps, and topographic maps. The data obtained is then processed using Data Mining techniques, Scheduler Export Data, and Joining Tabular and Spatial Data. Next, clustering analysis is performed to obtain the highest DB-Index value using the David Bouldin Index Method (DBI) to get the optimum cluster group. The data that has been processed and analyzed is used as input to make predictive models using SVM and Random Forest algorithms.

The results of the research showed that frameworks integrated with SIG and using SVM algorithms with an average test accuracy of 0.9956, a train accuracy of 0.9966, and RF with an average test accuracy of 0.994, a train accuracy of 0.9969, could produce accurate forest fire predictions. In addition, the results of clustering analysis with the DBI Method can provide the optimum cluster group to understand forest fire patterns. The analysis also found that there are several factors that influence the occurrence of forest fires, which include temperature, humidity, rainfall, type of vegetation, and spatial factors such as distances from human settlements.

The research also successfully integrated Machine Learning with SIG in the framework "Forest Fire Prediction" for forest fire prediction, which can be used as a basis for policymaking and management of forest and land fire risk more effectively.

Keywords: Data mining, Forest fires, Geographic Information Systems, SVM algorithms, Random forests, Factor variables, Clustering, David Bouldin Method Index (DBI).

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Hutan merupakan suatu kesatuan ekosistem berupa hamparan lahan berisi sumber daya alam hayati yang didominasi pepohonan dalam persekutuan alam lingkungannya, yang satu dengan lainnya tidak dapat dipisahkan (Cheng & Wang, 2005). Kebakaran hutan yaitu kebakaran yang terjadi di dalam kawasan hutan, dimana kebakaran hutan sendiri terjadi akibat dari faktor disengaja maupun tidak disengaja.

Kebakaran hutan adalah salah satu bencana yang mengintai wilayah Indonesia. Resiko bencana ini menjadi semakin meningkat dengan semakin banyaknya peralihan fungsi lahan yang meningkatkan resiko kebakaran hutan. Dalam penelitian ini digunakan beberapa data historical yang berpengaruh terhadap tingkat resiko kebakaran hutan, seperti data Cuaca, Kualitas Udara, Suhu, Kelembaban, Angin dan Titik Api. Data historical tersebut akan digunakan untuk membuat model / training yang dapat digunakan untuk melakukan prediksi kebakaran hutan pada situasi kondisi tertentu yang sesuai dengan tujuan penelitian ini, yaitu memperoleh model prediksi kebakaran hutan.

Penelitian tentang prediksi kebakaran hutan menggunakan data mining dan sistem informasi geografis telah banyak dilakukan sebelumnya. Misalnya, penelitian oleh Taravat et al. (2018) yang menggunakan algoritma random forest untuk memprediksi risiko kebakaran hutan di Iran berdasarkan faktor topografi, iklim, dan parameter kebakaran sebelumnya. Hasil penelitian menunjukkan bahwa model prediksi yang dikembangkan dapat memberikan tingkat akurasi yang baik.

Selain itu, penelitian oleh Sujarwo et al. (2019) juga mengembangkan model prediksi kebakaran hutan menggunakan data mining dan sistem informasi geografis di Indonesia. Model ini didasarkan pada faktor seperti curah hujan, suhu udara, kelembaban relatif, dan elevasi. Hasil penelitian menunjukkan bahwa model ini dapat memberikan prediksi risiko kebakaran hutan yang akurat.

Secara umum, kelebihan dari penelitian tersebut dapat mencakup penggunaan teknik data mining untuk memprediksi kebakaran hutan, yang dapat membantu mengidentifikasi pola dan faktor yang berkontribusi pada terjadinya kebakaran hutan. Selain itu, integrasi dengan sistem informasi geografis juga memungkinkan analisis spasial yang lebih baik.

Namun, kelemahan atau keterbatasan dari penelitian tersebut dapat terkait dengan kualitas data yang digunakan, termasuk data spasial dan non spasial, serta keakuratan dan kecukupan data yang digunakan dalam model prediksi. Selain itu, penggunaan data mining dan model prediksi dapat terbatas oleh kemampuan dan pengalaman analis dalam memilih dan mengevaluasi model yang tepat untuk masalah yang diteliti.

"A Comparison of Machine Learning Algorithms for Forest Fire Prediction in Turkey" oleh Ozcelik et al. (2021) menggunakan data citra satelit dan sistem informasi geografis untuk memprediksi kebakaran hutan di Turki menggunakan berbagai algoritma machine learning. Hasil penelitian menunjukkan bahwa algoritma XGBoost memberikan hasil terbaik dalam memprediksi kebakaran hutan.

"Forest Fire Risk Prediction using Machine Learning Techniques and Climate Change Projections" oleh Ashraf et al. (2021) menggunakan data cuaca dan citra satelit untuk memprediksi risiko kebakaran hutan di Pakistan dengan menggunakan algoritma Random Forest dan Support Vector Machine. Hasil penelitian menunjukkan bahwa algoritma Random Forest memberikan hasil yang lebih baik dalam memprediksi risiko kebakaran hutan.

"Forest Fire Risk Prediction using Deep Learning Techniques and Meteorological Data" oleh Liu et al. (2021) menggunakan data meteorologi dan citra satelit untuk memprediksi risiko kebakaran hutan di Cina dengan menggunakan algoritma Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM). Hasil penelitian menunjukkan bahwa kedua algoritma dapat memberikan hasil yang akurat dalam memprediksi risiko kebakaran hutan.

"A Data Mining Approach to Forest Fire Prediction" oleh Pandey dan Tiwari (2021) menggunakan data meteorologi dan citra satelit untuk memprediksi

kebakaran hutan di India dengan menggunakan algoritma Random Forest dan Decision Tree. Hasil penelitian menunjukkan bahwa algoritma Random Forest memberikan hasil yang lebih baik dalam memprediksi kebakaran hutan.

Kelebihan/Keunggulan penelitian tersebut adalah:

- Penelitian ini menggunakan metode Data Mining yang merupakan salah satu teknik analisis yang efektif dalam memproses data besar dan kompleks, sehingga dapat menghasilkan pola atau tren yang tersembunyi dan sulit ditemukan.
- Integrasi Sistem Informasi Geografis (SIG) dalam penelitian ini memungkinkan untuk menganalisis data spasial, yang memungkinkan untuk mengetahui lokasi yang berpotensi terjadi kebakaran hutan.
- Penelitian ini memperhitungkan faktor-faktor seperti curah hujan, temperatur udara, dan kelembaban udara, yang mempengaruhi kebakaran hutan, sehingga dapat memberikan prediksi yang lebih akurat.

Kekurangan/Kelemahan Penelitian tersebut adalah:

- Data yang digunakan dalam penelitian ini hanya berasal dari satu sumber, yaitu citra satelit, sehingga penggunaan data tambahan seperti data kelembaban tanah dan data cuaca harian dapat meningkatkan keakuratan prediksi.
- Variabel yang digunakan dalam penelitian ini terbatas pada curah hujan, temperatur udara, kelembaban udara, dan arah lereng, sehingga beberapa faktor lain yang dapat mempengaruhi kebakaran hutan seperti vegetasi dan topografi mungkin tidak terakomodasi dengan baik.
- Dalam penelitian ini, tidak dilakukan validasi dengan data pengamatan lapangan untuk mengevaluasi sejauh mana hasil prediksi yang dihasilkan sesuai dengan kondisi lapangan. Validasi dengan data pengamatan lapangan dapat meningkatkan kepercayaan pada hasil prediksi.

Untuk menyempurnakan penelitian sebelumnya, penelitian ini memiliki beberapa keunggulan dan keunikan dibandingkan dengan penelitian sebelumnya, di antaranya:

- Integrasi antara data mining dan sistem informasi geografis (SIG) secara langsung untuk memprediksi kebakaran hutan. Penelitian sebelumnya

cenderung memisahkan pengolahan data SIG dan data mining, sehingga tidak terintegrasi secara langsung.

- b. Penggunaan algoritma Support Vector Machine (SVM) dan Random Forest (RF) yang dapat membantu mengidentifikasi faktor-faktor utama yang mempengaruhi terjadinya kebakaran hutan. Hal ini dapat membantu pemerintah dan masyarakat dalam melakukan tindakan pencegahan dan penanggulangan kebakaran hutan dengan lebih efektif.
- c. Penggunaan data citra satelit dan Digital Elevation Model (DEM) sebagai salah satu input data, yang dapat memberikan informasi spasial yang lebih detail dan akurat. Hal ini dapat membantu meningkatkan akurasi model prediksi kebakaran hutan.
- d. Penelitian ini dilakukan di wilayah tertentu yaitu Taman Nasional Sebangau (TNS) Paduran Sebangau, Sebangau Kuala, Paduran Sebangau, Kec. Sebangau Kuala, Palangka Raya, Kalimantan Tengah, sehingga dapat memberikan informasi yang lebih spesifik dan relevan dengan kondisi wilayah tersebut.

Saat ini di Indonesia terdapat beberapa sumber website pemerintah yang menyediakan data iklim dan sebaran titik api (hot spot) dalam bentuk data tabular dan data spasial, yang mendukung pemerintah dalam melakukan monitoring pengawasan kebakaran hutan. Akan tetapi, masing-masing website tersebut tidak terintegrasi, sehingga dibutuhkan suatu teknik Data Mining dalam menyatukan data dari berbagai sumber tersebut dan menggabungkan ke dalam 1 sumber data yang utuh serta mampu diintegrasikan dengan aplikasi/platform lainnya.

Informasi persebaran titik api dapat divisualisasikan dalam bentuk peta menggunakan SIG. Pengembangan aplikasi SIG sudah banyak dilakukan. Namun, pada aplikasi tersebut hanya menampilkan lokasi kebakaran hutan dan belum terdapat modul klasifikasi titik api. Modul klasifikasi titik api sangat penting untuk menentukan lokasi rawan kebakaran berdasarkan karakteristik lokasi terjadinya titik api.

Dengan adanya *framework* Data Mining dan Integrasi tersebut, data dapat dimanfaatkan lebih maksimal lagi dalam melakukan monitoring kebakaran hutan dan membuat sistem informasi geografis yang mampu menampilkan data secara

near real time untuk *Early Warning Systems* (EWS) dan Penanganan kebakaran hutan.

1.2. Rumusan Masalah

Berdasarkan uraian permasalahan tersebut, maka dalam penelitian ini akan dilakukan beberapa hal sebagai berikut:

- a. Bagaimana melakukan Data Mining dari berbagai website penyedia data dan melakukan join data tabular dengan data spasial?
- b. Parameter apa yang menghasilkan cluster terbaik?
- c. Apakah ada pengaruh perubahan penggunaan lahan, kepadatan penduduk dan sebaran hot spot terhadap potensi kebakaran hutan?
- d. Bagaimana mengintegrasikan semua data hasil Data Mining ke dalam Sistem Informasi Geografis (SIG) untuk membangun *Early Warning Systems* (EWS) kebakaran hutan?

1.3. Batasan Masalah

Merujuk pada referensi paper *Wildfire Risk Assessment of Transmission-Line Corridors Based on Naïve Bayes Network and Remote Sensing Data* (W. Chen et al., 2021) yang berlokasi di negara China. Ruang lingkup penelitian ini adalah:

- a. Data yang digunakan dalam penelitian ini berupa hasil dari proses Data Mining yang bersumber dari beberapa website penyedia data iklim dan sebaran *hot spot* (titik api) yaitu Badan Meteorologi, Klimatologi, dan Geofisika (BMKG); Kementerian Lingkungan Hidup dan Kehutanan (KLHK) dan Lembaga Penerbangan, Antariksa Nasional (LAPAN) secara berkala mulai Agustus – November 2022 dan website BNPB untuk data kejadian kebakaran hutan periode tahun 2018-2022.
- b. Proses data mining dilakukan dengan tools scrapping:
 - i. Script worker dibuat dengan nodejs.
 - ii. Visual studio sebagai text editor script nodejs.
 - iii. Data base menggunakan postgres-sql versi 10
- c. Melakukan joining data sehingga diperoleh sumber data baru

- d. Melakukan clusterisasi data
- e. Lokasi Penelitian berada di rentang koordinat:

1. $113^{\circ} 32' 46,592''$ E	$1^{\circ} 49' 33,294''$ S
2. $114^{\circ} 7' 36,710''$ E	$1^{\circ} 49' 37,577''$ S
3. $114^{\circ} 7' 32,287''$ E	$2^{\circ} 25' 36,241''$ S
4. $113^{\circ} 32' 42,168''$ E	$2^{\circ} 25' 31,958''$ S

Secara batas administrasi, lokasi penelitian berada di Provinsi Kalimantan Timur: Kelurahan Bukit Tunggul, Kelurahan Kereng Bangkirai, Kelurahan Langkai, Kelurahan Menteng, Kelurahan Pahandut, Kelurahan Pahandut Seberang, Kelurahan Palangka, Kelurahan Panarung, Kelurahan Petuk Katimpun, Kelurahan Tumbang Rungan.

- f. Citra satelit yang digunakan adalah citra satelit Sentinel-2 rentang waktu tahun 2018 – 2022 dengan tutupan awan kurang dari 10%
- g. Data kejadian kebakaran hutan tahun 2018 – 2022 berdasarkan website <https://dibi.bnpb.go.id/>.
- h. Integrasi Machine Learning ke platform Sistem Informasi Geografis (SIG)

1.4. Tujuan Penelitian

Berdasarkan latar belakang dan rumusan masalah, tujuan penelitian ini adalah:

- a. Teknik Data Mining, Scheduler Export Data dan Joining Data Tabular dan Spasial.
- b. Melakukan clustering untuk mendapatkan nilai DB-Index tertinggi dengan Metode David Bouldin Index (DBI).
- c. Mengetahui faktor-faktor terjadinya kebakaran hutan
- d. Mengintegrasikan Machine Learning dengan Sistem Informasi Geografis (SIG).

1.5. Manfaat Penelitian

Manfaat dari penelitian ini adalah:

- a. Memberikan solusi teknik data mining dari beberapa sumber website penyedia data iklim/cuaca dan hot spot.
- b. Melakukan teknik join data tabular dengan data spasial sehingga diperoleh clusterisasi data yang paling efektif.
- c. Melakukan analisa faktor-faktor yang mempengaruhi terjadinya kebakaran hutan.
- d. Integrasi antara dengan Sistem Informasi Geografis (SIG) dengan Machine Learning sebagai *Early Warning Systemx* (EWS) Kebakaran Hutan.



BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

2.1.1 Data Mining

Penelitian atau penerapan Data Science untuk kebakaran hutan sudah sangat banyak, mulai dari data akuisisi atau data mining, klasifikasi hingga prediksi. Penelitian pertama yang menjadi rujukan adalah penelitian oleh (Ramesh & Dinesh, 2018) yang berjudul *Prediction and Data Mining of Burned Areas of Forest Fires: Optimized data matching and mining algorithm provides valuable insight*. Dimana tujuan penelitian tersebut adalah untuk melakukan data mining dengan dataset dari tahun 2000 hingga 2003 dan melakukan prediksi melalui analisis data untuk mendapatkan nilai mean absolute error (MAE) dan root mean square error (RMSE) sebagai informasi akurasi algoritma machine learning. Penelitian selanjutnya adalah penelitian oleh (Wood, 2021) yang berjudul *Parallel SVM Model for Forest Fire Prediction*, dimana penelitian ini bertujuan untuk implementasi algoritma Parallel Support Vector Machine untuk memprediksi Kebakaran Hutan. Adapun algoritma SVM yang digunakan ada enam algoritma yaitu CNN, MPNN, PNN, RBF, Linear dan Parallel SVM, dimana akurasi tertinggi adalah pada algoritma Parallel SVM.

Penelitian yang berjudul *Forest Fires Detection Using Machine Learning Techniques* dilakukan oleh (Butar-Butar et al., 2021) dengan tujuan untuk membandingkan penggunaan tiga teknik regresi pada machine learning untuk melakukan prediksi daerah rawan kebakaran hutan. Yang menarik dari penelitian ini selain membandingkan tiga teknik regresi linear (Linear, Ridge, Regression) juga dilakukan perbandingan terhadap komposisi variabel yang digunakan antara dataset dengan menggunakan variabel lengkap dan juga dataset dengan variabel tidak lengkap. Skor akurasi dihitung pada data set pelatihan dan pengujian, pada data set pelatihan masing-masing adalah 1, 0,98 dan 0,88 pada regresi linier, regresi ridge, dan regresi laso, pada data set pengujian adalah 1, 0,95 dan 0,81 pada linear regresi, regresi punggung, dan regresi laso, masing-masing. Hasil

eksperimen menunjukkan bahwa algoritma regresi linier memberikan hasil terbaik.

Penelitian (R. Chen et al., 2013) dengan judul *A Novel Forest Fire Prediction Tool Utilizing Fire Weather And Machine Learning Methods* oleh Leo Deng, dkk (2016) dengan tujuan untuk membantu badan-badan manajemen ini dalam perencanaan dan strategi untuk mengelola kebakaran hutan secara efisien dan bersiap untuk mengatasi kebakaran yang berbahaya dan tidak diinginkan. Dalam penelitian ini, alat baru untuk meramalkan kebakaran hutan dikembangkan, memberikan tingkat intensitas tertentu untuk kebakaran tertentu berdasarkan jumlah lahan yang akan terbakar. Peramalan tingkat intensitas kebakaran hutan bergantung pada keakuratan prakiraan atribut cuaca. Hasil dari penelitian ini mendapatkan akurasi dari setiap atribut menggunakan SVM, dimana akurasi paling tinggi adalah pada Rain Duration - 79% dan yang paling rendah adalah Rain Ammount (jumlah hujan) 33%. Selain itu juga dihasilkan bahwa akurasi metode machine learning tertinggi adalah metode DNF yaitu > 95% dan yang paling rendah adalah Naive Bayes 73%.

2.2.2 Penggunaan Teknik Data Mining dalam Data Kebakaran Hutan

Data kebakaran hutan umumnya berupa data spasial. Data spasial memiliki karakteristik spasial dan non-spasial. Atribut spasial digunakan untuk mendefinisikan lokasi objek. Sedangkan atribut non-spasial menjelaskan karakteristik objek seperti nama dan jumlah populasi untuk area tertentu. Teknik-teknik data mining telah digunakan dalam mencari pola menarik dari data spasial berukuran besar. Proses tersebut dinyatakan sebagai spatial data mining dimana algoritme data mining spasial dan non-spasial diimplementasikan pada data spasial. Penerapan teknik data mining dalam data spasial lebih kompleks dari penggunaan teknik tersebut pada data non-spasial, karena algoritme-algoritme data mining spasial harus memperhitungkan objek tetangga dari objek studi untuk mendapatkan pola yang menarik. Dalam data mining spasial, atribut-atribut dari tetangga sebuah objek dapat memberikan pengaruh yang signifikan kepada objek studi

Teknik-teknik *data mining* telah banyak diterapkan dalam menganalisis data spasial untuk kebakaran hutan. Prasad dan Ramakrishna [6] menggunakan algoritme *clustering* yaitu K-means dan logika fuzzy dalam penentuan lokasi yang memiliki resiko terjadinya kebakaran hutan. Studi tersebut mengajukan sebuah sistem untuk mengidentifikasi kebakaran hutan dari citra satelit (KUKUK & KILIMCI, 2021). Stojanova et. al. (Prihandoko & Bertalya, 2017) telah membangun model prediktif berdasarkan data dari satelit meteorologi ALADIN dan MODIS. Teknik *data mining* yang digunakan adalah regresi logistik, pohon keputusan, *random forests*, *bagging* dan *boosting*, untuk memperoleh model prediktif untuk kemunculan kebakaran.

Dalam studi oleh Cortez dan Morais (Kalantar et al., 2020), teknik lainnya dalam *data mining* yaitu Support Vector Machines dan *Random Forests* diterapkan untuk memprediksi area yang terbakar karena kebakaran hutan berdasarkan factor meteorologi di area timur laut di Portugal, yaitu temperature, kelembaban relative, curah hujan dan kecepatan angin. Angayarkkani dan Radhakrishnan (2009); (Ferreira et al., 2020) menentukan area yang rawan terjadinya kebakaran hutan dengan menggunakan teknik *data mining* spasial dan logika fuzzy. Teknik *data mining* lain yang digunakan dalam analisis data kebakaran hutan adalah algoritme Apriori untuk mencari aturan asosiasi (Khairani & Sutoyo, 2020a). Algoritme tersebut digunakan untuk menentukan peluang dan intensitas kebakaran hutan berdasarkan data cuaca.

2.2.3 Faktor-faktor yang mempengaruhi terjadinya kebakaran hutan

Jurnal "Wildfire Risk Assessment of Transmission-Line Corridors Based on Naïve Bayes Network and Remote Sensing Data" (W. Chen et al., 2021), membahas tentang penilaian risiko kebakaran hutan di koridor jalur transmisi dengan menggunakan Naïve Bayes Network (NBN) dan data penginderaan jauh (*remote sensing*). Penilaian risiko kebakaran hutan sangat penting dalam melindungi lingkungan dan infrastruktur, seperti jalur transmisi listrik.

Metode yang digunakan dalam penelitian ini adalah pengumpulan data penginderaan jauh dan analisis statistik. Data yang digunakan mencakup peta

tutupan lahan, ketinggian permukaan, dan kepadatan vegetasi. Kemudian, data tersebut diolah menggunakan teknik NBN untuk membangun model prediksi risiko kebakaran hutan.

Hasil penelitian menunjukkan bahwa model prediksi yang dibangun memiliki akurasi yang baik dalam memprediksi risiko kebakaran hutan di koridor jalur transmisi. Penelitian ini memberikan wawasan baru tentang penggunaan data penginderaan jauh dan analisis statistik dalam penilaian risiko kebakaran hutan dan dapat digunakan sebagai referensi untuk penelitian lebih lanjut tentang penilaian risiko kebakaran hutan.

Pemanfaatan machine learning berdasarkan data Human Related Factors (HRF) dan Physical-Environmental Factors Calculation telah banyak dilakukan dalam prediksi kebakaran hutan dan lahan. Beberapa hasil penelitian yang menunjukkan pemanfaatan machine learning berdasarkan kedua faktor tersebut adalah sebagai berikut:

- a. Pemanfaatan Random Forest untuk menganalisis pengaruh faktor HRF dan Physical-Environmental terhadap risiko kebakaran hutan dan lahan di wilayah Asia Tenggara (Chong et al., 2021).
- b. Pemanfaatan model Deep Belief Network untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di Cina (Wei et al., 2019).
- c. Pemanfaatan algoritma Decision Tree dan Logistic Regression untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di daerah Mediterranean (Lanorte et al., 2020).
- d. Pemanfaatan algoritma Support Vector Machine (SVM) untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di wilayah Australia (Yang et al., 2021).
- e. Pemanfaatan model Artificial Neural Network (ANN) untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di wilayah Amerika Selatan (Rojas et al., 2020).

- f. Pemanfaatan algoritma Gradient Boosting Decision Tree (GBDT) untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di daerah Mediteranea (Bajwa et al., 2021).
- g. Pemanfaatan algoritma Naive Bayes untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di wilayah Amerika Utara (Kamal et al., 2019).
- h. Pemanfaatan model Random Forest untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di daerah Himalaya (Pandey et al., 2019).
- i. Pemanfaatan model Gradient Boosting untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di wilayah Eropa (Papakostas et al., 2019).
- j. Pemanfaatan algoritma K-Nearest Neighbor (KNN) untuk menganalisis faktor HRF dan Physical-Environmental dalam prediksi kebakaran hutan dan lahan di wilayah Amerika Selatan (Caro-Castro et al., 2021).

2.2.3.1 A. Human Related Factors (HRF)

Human Related Factors (HRF) adalah faktor yang berkaitan dengan perilaku manusia yang dapat mempengaruhi terjadinya kebakaran hutan dan lahan. HRF terdiri dari berbagai faktor seperti aktivitas pembukaan lahan, pembakaran sampah, pembukaan jalan, dan kegiatan perburuan.

Penelitian sebelumnya telah menunjukkan bahwa HRF memiliki kontribusi yang signifikan terhadap terjadinya kebakaran hutan dan lahan. Penelitian oleh Andela et al. (2017) menggunakan data penginderaan jauh dan analisis statistik untuk mengevaluasi faktor-faktor yang mempengaruhi terjadinya kebakaran hutan di seluruh dunia. Hasil penelitian menunjukkan bahwa aktivitas manusia seperti deforestasi dan pembukaan lahan merupakan faktor utama yang mempengaruhi terjadinya kebakaran hutan.

Penelitian lain yang dilakukan oleh Ribeiro et al. (2018) di Brasil menemukan bahwa aktivitas manusia seperti pembukaan jalan dan perburuan dapat memicu terjadinya kebakaran hutan dan lahan di wilayah tersebut.

Penelitian ini menekankan pentingnya pengelolaan lahan yang baik dan edukasi masyarakat untuk mengurangi risiko terjadinya kebakaran hutan dan lahan.

Dengan demikian, pemahaman terhadap faktor-faktor HRF sangat penting dalam mengelola dan mencegah terjadinya kebakaran hutan dan lahan. Penerapan teknologi seperti penginderaan jauh dan analisis statistik dapat membantu dalam pengidentifikasian dan pemantauan faktor-faktor HRF tersebut.

2.2.3.1.1 A.1. Pendapatan per Kapita (GDP)

Gross Domestic Product (GDP) / Produk Domestik Bruto (PDB) adalah perhitungan yang digunakan oleh suatu negara sebagai ukuran utama bagi aktivitas perekonomian nasionalnya, tetapi pada dasarnya GDP/PDB mengukur seluruh volume produksi dari suatu wilayah (negara) secara geografis. Pengaruh GDP (Gross Domestic Product) atau Produk Domestik Bruto terhadap faktor kebakaran hutan dan lahan dapat dilihat dari dua sudut pandang, yaitu positif dan negatif.

Dari sudut pandang positif, peningkatan GDP dapat membantu meningkatkan kesadaran masyarakat akan pentingnya menjaga dan melestarikan lingkungan. Peningkatan GDP juga dapat menghasilkan sumber daya yang lebih besar untuk investasi dalam pengelolaan dan pencegahan kebakaran hutan dan lahan, seperti pendidikan dan pelatihan masyarakat serta peningkatan akses ke teknologi yang lebih canggih.

Namun, dari sudut pandang negatif, peningkatan GDP juga dapat berdampak negatif pada kebakaran hutan dan lahan. Peningkatan aktivitas ekonomi seperti perluasan lahan pertanian dan industri, pembangunan infrastruktur, dan urbanisasi dapat meningkatkan risiko terjadinya kebakaran hutan dan lahan. Selain itu, peningkatan konsumsi energi dan produksi industri juga dapat meningkatkan emisi gas rumah kaca yang dapat memperburuk dampak dari kebakaran hutan dan lahan.

Beberapa penelitian sebelumnya telah menunjukkan adanya hubungan antara GDP dan terjadinya kebakaran hutan dan lahan. Sebagai contoh, penelitian

oleh Zahabu et al. (2019) di Tanzania menunjukkan bahwa adanya hubungan yang signifikan antara pertumbuhan ekonomi dan peningkatan risiko kebakaran hutan dan lahan. Penelitian lain oleh [18] Qian et al. (2018) di China menemukan bahwa pertumbuhan ekonomi dan perubahan penggunaan lahan telah menyebabkan peningkatan risiko kebakaran hutan dan lahan di wilayah tersebut.

Dengan demikian, sementara peningkatan GDP dapat membawa dampak positif pada pengelolaan dan pencegahan kebakaran hutan dan lahan, namun juga dapat meningkatkan risiko terjadinya kebakaran jika tidak dikelola dengan baik. Oleh karena itu, pengelolaan lingkungan yang baik dan kebijakan yang berkelanjutan perlu diterapkan untuk memastikan bahwa pertumbuhan ekonomi tidak merusak lingkungan.

2.2.3.1.2 A.2 Population Density (PD)

Kepadatan adalah hasil bagi jumlah objek terhadap luas daerah. Dengan demikian satuan yang digunakan adalah satuan/luas daerah, misalnya: buah/m². rumus kepadatan penduduk sebagai berikut:

$$P = \frac{\text{Jumlah Penduduk (Orang)}}{\text{Luas Wilayah (km}^2\text{)}} \quad (1)$$

Population Density (PD) atau kepadatan penduduk juga dapat berdampak pada faktor kebakaran hutan dan lahan. Peningkatan PD dapat meningkatkan risiko terjadinya kebakaran hutan dan lahan karena adanya peningkatan aktivitas manusia seperti pembukaan lahan pertanian, pembangunan infrastruktur, dan urbanisasi yang dapat meningkatkan risiko terjadinya kebakaran. Selain itu, PD juga dapat memengaruhi kemampuan untuk mendeteksi dan merespons kebakaran secara cepat dan efektif.

Namun, peningkatan PD juga dapat membawa dampak positif pada pencegahan kebakaran hutan dan lahan. Dengan adanya lebih banyak penduduk, dapat meningkatkan kesadaran masyarakat akan pentingnya menjaga dan melestarikan lingkungan serta membantu meningkatkan kapasitas untuk melakukan tindakan pencegahan dan penanggulangan kebakaran.

Beberapa penelitian sebelumnya juga telah menunjukkan adanya hubungan antara PD dan risiko kebakaran hutan dan lahan. Sebagai contoh, penelitian oleh Daud et al. (2017) di Malaysia menemukan bahwa PD memiliki pengaruh positif pada risiko terjadinya kebakaran hutan dan lahan. Penelitian lain oleh Chen et al. (2018) di Provinsi Hubei, China menemukan bahwa peningkatan PD juga dapat memperburuk dampak kebakaran hutan dan lahan.

Dalam hal ini, peran masyarakat dalam pencegahan dan penanggulangan kebakaran hutan dan lahan menjadi sangat penting. Dengan meningkatkan kesadaran masyarakat akan pentingnya menjaga lingkungan dan pencegahan kebakaran, serta meningkatkan kemampuan masyarakat untuk mendeteksi dan merespons kebakaran secara cepat dan efektif, maka dapat membantu mengurangi risiko terjadinya kebakaran.

Semakin besar angkanya maka semakin padat kependudukannya. Data Kepadatan Penduduk/ Population Density (PD) diperoleh dari website Badan Pusat Statistik Provinsi Kalimantan Timur dengan perolehan data sebagai berikut:

2.2.3.1.3 A.3 Distance to Settlement (DS)

Distance to Settlement (DS) atau jarak ke pemukiman juga dapat memengaruhi faktor kebakaran hutan dan lahan. Penurunan jarak antara lahan hutan dan lahan pemukiman dapat meningkatkan risiko terjadinya kebakaran karena adanya aktivitas manusia seperti pembukaan lahan pertanian, pembangunan infrastruktur, dan urbanisasi yang dapat meningkatkan risiko terjadinya kebakaran. Selain itu, semakin dekat lahan hutan dengan pemukiman juga dapat memperburuk dampak kebakaran karena risiko kehilangan nyawa dan properti yang lebih besar.

Beberapa penelitian sebelumnya juga telah menunjukkan adanya hubungan antara DS dan risiko kebakaran hutan dan lahan. Sebagai contoh, penelitian oleh Pham et al. (2020) di Vietnam menemukan bahwa DS memiliki pengaruh positif pada risiko terjadinya kebakaran hutan dan lahan. Penelitian lain oleh Yulianto et al. (2020) di Indonesia menunjukkan bahwa semakin dekat jarak

lahan hutan dengan permukiman, maka semakin tinggi risiko terjadinya kebakaran.

Dalam hal ini, peran pengelolaan tata ruang dan penempatan pemukiman juga menjadi sangat penting untuk mengurangi risiko terjadinya kebakaran hutan dan lahan. Dengan menempatkan pemukiman pada jarak yang aman dari lahan hutan dan menerapkan tata ruang yang baik, maka dapat membantu mengurangi risiko terjadinya kebakaran.

2.2.3.1.4 A,4 Distance to Road (DR)

Distance to Road (DR) atau jarak ke jalan raya juga dapat memengaruhi faktor kebakaran hutan dan lahan. Adanya jalan raya yang berdekatan dengan lahan hutan dapat memudahkan akses manusia untuk melakukan aktivitas di sekitar lahan hutan, seperti pembukaan lahan pertanian atau penambangan, yang dapat meningkatkan risiko terjadinya kebakaran. Selain itu, jalan raya juga dapat memfasilitasi perpindahan api dari satu area ke area lain yang berdekatan, sehingga memperbesar risiko terjadinya kebakaran hutan dan lahan.

Beberapa penelitian sebelumnya telah menunjukkan adanya hubungan antara DR dan risiko kebakaran hutan dan lahan. Sebagai contoh, penelitian oleh Naik et al. (2018) di India menemukan bahwa semakin dekat jarak lahan hutan dengan jalan raya, maka semakin tinggi risiko terjadinya kebakaran. Penelitian lain oleh Mardiatno et al. (2021) di Indonesia juga menunjukkan adanya hubungan yang signifikan antara DR dengan kejadian kebakaran hutan dan lahan.

Dalam hal ini, pengelolaan tata ruang dan pembangunan infrastruktur harus mempertimbangkan faktor risiko kebakaran hutan dan lahan. Penempatan jalan raya yang jauh dari lahan hutan dan penerapan regulasi yang ketat terhadap aktivitas manusia di sekitar lahan hutan dapat membantu mengurangi risiko terjadinya kebakaran.

2.2.3.1.5 A.5 Historical Fire (HiF)

Historical Fire (HiF) atau riwayat kebakaran sebelumnya juga dapat memengaruhi faktor kebakaran hutan dan lahan. Jika suatu wilayah pernah mengalami kebakaran sebelumnya, maka kemungkinan besar akan terjadi lagi di masa depan. Hal ini terkait dengan adanya sumber api yang belum padam sepenuhnya atau adanya bahan bakar yang masih tersisa dan dapat mudah terbakar lagi.

Beberapa penelitian telah menunjukkan adanya hubungan antara HiF dan risiko kebakaran hutan dan lahan. Sebagai contoh, penelitian oleh Zhu et al. (2019) di California, Amerika Serikat menunjukkan bahwa area yang pernah mengalami kebakaran hutan dalam 10 tahun terakhir memiliki risiko lebih tinggi untuk terjadi kebakaran lagi di masa depan. Hal ini disebabkan oleh adanya tumbuhan baru yang tumbuh di wilayah yang terbakar sebelumnya yang memiliki kandungan bahan bakar yang lebih mudah terbakar.

Dalam hal ini, pengelolaan lahan hutan dan lahan harus mempertimbangkan riwayat kebakaran sebelumnya untuk mengurangi risiko terjadinya kebakaran. Pengawasan dan pemantauan secara terus menerus serta pencegahan tindakan manusia yang dapat memicu kebakaran dapat dilakukan di area yang pernah mengalami kebakaran sebelumnya.

2.2.3.2 B. Physical-Environmental Factors Calculation

Physical-Environmental Factors (PEF) atau faktor fisik lingkungan juga dapat memengaruhi faktor kebakaran hutan dan lahan. Faktor-faktor ini meliputi topografi, iklim, dan jenis vegetasi yang ada di wilayah tersebut. Topografi yang curam dan terjal, serta kondisi yang kering dan panas, dapat meningkatkan risiko kebakaran hutan dan lahan. Selain itu, jenis vegetasi yang mudah terbakar dan memiliki kandungan air yang rendah juga dapat memicu terjadinya kebakaran.

Beberapa penelitian telah menunjukkan adanya hubungan antara PEF dan risiko kebakaran hutan dan lahan. Sebagai contoh, penelitian oleh Singh et al. (2018) di India menunjukkan bahwa topografi curam dan kondisi cuaca yang

kering dapat meningkatkan risiko kebakaran hutan dan lahan. Penelitian tersebut juga menunjukkan bahwa jenis vegetasi yang ada di wilayah tersebut, seperti semak belukar dan rumput, memiliki kandungan air yang rendah sehingga mudah terbakar.

Dalam hal ini, pengelolaan lahan hutan dan lahan harus mempertimbangkan faktor-faktor fisik lingkungan tersebut untuk mengurangi risiko terjadinya kebakaran. Pencegahan tindakan manusia yang dapat memicu kebakaran juga harus dilakukan secara ketat.

2.2.3.2.1 B.1 Fuel

Fuel atau bahan bakar seperti material organik yang terdapat di hutan dan lahan juga dapat memengaruhi faktor kebakaran hutan dan lahan. Bahan bakar yang banyak dan mudah terbakar dapat memicu terjadinya kebakaran. Beberapa faktor yang mempengaruhi ketersediaan bahan bakar termasuk jenis vegetasi, kepadatan vegetasi, dan kondisi vegetasi yang kering.

Sejumlah penelitian telah menunjukkan adanya hubungan antara faktor bahan bakar dengan risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Zhao et al. (2018) di China menunjukkan bahwa jenis vegetasi dan kepadatan vegetasi memiliki hubungan yang kuat dengan risiko kebakaran hutan dan lahan. Penelitian tersebut menunjukkan bahwa vegetasi seperti semak belukar dan hutan yang lebat dapat memberikan bahan bakar yang banyak dan mudah terbakar, sehingga meningkatkan risiko kebakaran.

Pengelolaan bahan bakar juga dapat membantu mengurangi risiko kebakaran. Misalnya, tindakan pembersihan lahan dari material organik seperti daun kering dan ranting, atau melakukan pembakaran terkontrol pada musim yang tepat dapat mengurangi jumlah bahan bakar yang tersedia dan mengurangi risiko kebakaran.

2.2.3.2.2 B.2 *Normalized Difference Vegetation Index (NDVI)*

Normalized Difference Vegetation Index (NDVI) adalah salah satu parameter yang digunakan dalam memantau kondisi vegetasi dan dapat memberikan informasi tentang risiko kebakaran hutan dan lahan. NDVI mengukur kandungan klorofil dan aktivitas fotosintesis pada vegetasi. Area yang memiliki nilai NDVI tinggi cenderung memiliki vegetasi yang sehat dan subur, sedangkan area dengan nilai NDVI rendah cenderung memiliki vegetasi yang kurang sehat dan mungkin mengalami kekeringan atau bahkan mati.

Beberapa penelitian telah menunjukkan bahwa analisis NDVI dapat memberikan informasi yang berguna dalam memprediksi risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Fuentes et al. (2019) di Chile menunjukkan bahwa nilai NDVI yang rendah dapat dijadikan indikator untuk mengidentifikasi area yang rentan terhadap kebakaran hutan dan lahan. Penelitian tersebut menunjukkan bahwa area yang memiliki nilai NDVI rendah cenderung memiliki vegetasi yang kurang subur dan rentan terhadap kekeringan, sehingga meningkatkan risiko kebakaran.

Selain itu, analisis NDVI juga dapat digunakan untuk memetakan area yang rentan terhadap kebakaran hutan dan lahan. Misalnya, penelitian oleh Karyadi et al. (2019) di Indonesia menunjukkan bahwa peta risiko kebakaran hutan dan lahan dapat dibuat dengan memanfaatkan data NDVI dari citra satelit. Peta risiko tersebut dapat membantu pihak terkait dalam merencanakan tindakan pencegahan dan penanggulangan kebakaran hutan dan lahan.

2.2.3.2.3 B.3 *Vegetation Type*

Jenis vegetasi di suatu area dapat mempengaruhi risiko terjadinya kebakaran hutan dan lahan. Vegetasi yang memiliki tingkat kandungan air yang rendah, tumbuhan yang mudah terbakar, dan lahan yang terbuka cenderung lebih rentan terhadap kebakaran. Oleh karena itu, pengetahuan tentang jenis vegetasi yang ada di suatu area dapat membantu dalam memprediksi risiko kebakaran.

Beberapa penelitian telah menunjukkan pengaruh vegetation type terhadap risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Lan et al. (2019) di China menunjukkan bahwa jenis vegetasi yang ada di suatu area dapat mempengaruhi risiko kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa area yang ditumbuhi oleh jenis pohon yang memiliki daun kecil cenderung lebih rentan terhadap kebakaran karena memiliki tingkat kekeringan yang lebih tinggi dibandingkan dengan jenis pohon lainnya.

Selain itu, penelitian oleh Tripathi et al. (2018) di India juga menunjukkan bahwa jenis vegetasi dapat mempengaruhi risiko kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa lahan yang ditumbuhi oleh jenis rumput yang mudah terbakar cenderung lebih rentan terhadap kebakaran.

2.2.3.2.4 B.4 Precipitation

Curah hujan (precipitation) dapat mempengaruhi risiko kebakaran hutan dan lahan. Jumlah curah hujan yang rendah dapat membuat tanah menjadi kering, dan jika disertai dengan cuaca panas dan angin kencang, dapat meningkatkan risiko kebakaran hutan dan lahan. Sebaliknya, curah hujan yang tinggi dapat mengurangi risiko kebakaran hutan dan lahan karena membuat tanah menjadi lebih lembab.

Beberapa penelitian telah menunjukkan pengaruh curah hujan terhadap risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Sivakumar dan Das (2016) di India menunjukkan bahwa curah hujan memiliki korelasi negatif dengan risiko kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa ketika curah hujan meningkat, risiko kebakaran hutan dan lahan cenderung menurun.

Selain itu, penelitian oleh Pausas et al. (2019) di Spanyol menunjukkan bahwa curah hujan dapat mempengaruhi pola kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa kebakaran hutan dan lahan di daerah dengan curah hujan yang tinggi cenderung terjadi pada periode waktu yang lebih lama dibandingkan dengan daerah dengan curah hujan yang rendah.

2.2.3.2.5 B.5 Land Usage/Perubahan Lahan

Perubahan penggunaan lahan atau land use dapat mempengaruhi risiko kebakaran hutan dan lahan. Misalnya, jika lahan hutan atau vegetasi alami diganti dengan lahan pertanian atau pemukiman, maka dapat meningkatkan risiko kebakaran hutan dan lahan karena terjadi perubahan pada ketersediaan bahan bakar atau material yang mudah terbakar.

Beberapa penelitian telah menunjukkan pengaruh perubahan penggunaan lahan terhadap risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Bui et al. (2020) di Vietnam menunjukkan bahwa perubahan penggunaan lahan dari hutan menjadi lahan pertanian dapat meningkatkan risiko kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa daerah yang mengalami perubahan penggunaan lahan memiliki risiko kebakaran hutan dan lahan yang lebih tinggi dibandingkan dengan daerah yang masih berupa hutan.

Selain itu, penelitian oleh Alcasena et al. (2019) di Argentina menunjukkan bahwa perubahan penggunaan lahan dapat mempengaruhi pola kebakaran hutan dan lahan. Penelitian tersebut menemukan bahwa kebakaran hutan dan lahan lebih sering terjadi di daerah yang mengalami perubahan penggunaan lahan dari hutan menjadi lahan pertanian atau padang rumput.

2.2.3.2.6 B.6 Temperature

Suhu atau temperature merupakan salah satu faktor lingkungan yang berpengaruh terhadap risiko kebakaran hutan dan lahan. Semakin tinggi suhu udara, semakin mudah bahan bakar atau material yang ada di hutan atau lahan untuk terbakar. Kondisi suhu yang tinggi juga dapat meningkatkan potensi terjadinya api dari sumber-sumber lain, seperti sambaran petir atau aktivitas manusia yang dapat memicu kebakaran.

Beberapa penelitian telah menunjukkan bahwa suhu memiliki pengaruh yang signifikan terhadap risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Huang et al. (2019) di Cina menunjukkan bahwa suhu yang tinggi berkontribusi terhadap peningkatan risiko kebakaran hutan dan lahan. Penelitian

tersebut menemukan bahwa terdapat korelasi positif yang signifikan antara suhu dan kejadian kebakaran hutan dan lahan.

Penelitian lain oleh Chen et al. (2017) di Taiwan juga menunjukkan hasil yang serupa. Penelitian tersebut menemukan bahwa suhu merupakan salah satu faktor lingkungan yang paling berpengaruh terhadap risiko kebakaran hutan dan lahan di daerah pegunungan Taiwan.

2.2.3.2.7 B.7 Elevation

Elevasi atau ketinggian tempat juga merupakan faktor lingkungan yang berpengaruh terhadap risiko kebakaran hutan dan lahan. Elevasi dapat mempengaruhi iklim lokal, termasuk suhu, kelembaban, dan curah hujan, yang semuanya dapat mempengaruhi risiko kebakaran.

Beberapa penelitian telah menunjukkan bahwa elevasi memiliki pengaruh yang signifikan terhadap risiko kebakaran hutan dan lahan. Misalnya, penelitian oleh Koutsias et al. (2013) di Yunani menunjukkan bahwa elevasi yang lebih tinggi dapat menurunkan risiko kebakaran hutan dan lahan. Hal ini disebabkan oleh kondisi iklim yang lebih dingin dan lebih basah di daerah yang lebih tinggi, yang dapat mengurangi kekeringan dan potensi kebakaran.

Namun, penelitian lain oleh Ribeiro et al. (2018) di Brazil menunjukkan hasil yang berbeda. Penelitian tersebut menemukan bahwa elevasi tidak memiliki pengaruh yang signifikan terhadap risiko kebakaran hutan dan lahan di wilayah studi mereka. Hal ini mungkin disebabkan oleh kondisi iklim yang berbeda dan faktor lingkungan lain yang lebih mempengaruhi risiko kebakaran di wilayah tersebut.

2.2.3.2.8 B.8 Slope

Slope atau kemiringan topografi dapat memengaruhi kebakaran hutan dan lahan. Kemiringan yang curam dapat mempercepat penyebaran api dan meningkatkan risiko kebakaran. Pada kemiringan yang lebih datar, kebakaran

dapat lebih mudah dikendalikan. Oleh karena itu, slope dapat menjadi faktor yang penting dalam memprediksi risiko kebakaran hutan dan lahan.

Beberapa penelitian telah mengidentifikasi pengaruh slope terhadap faktor kebakaran hutan dan lahan. Misalnya, penelitian yang dilakukan di Provinsi Aceh, Indonesia, menunjukkan bahwa kemiringan topografi berpengaruh signifikan terhadap kebakaran hutan dan lahan. Hasil penelitian menunjukkan bahwa wilayah dengan slope yang lebih curam memiliki risiko kebakaran yang lebih tinggi daripada wilayah dengan slope yang lebih datar (Rahmawati et al., 2019).

Penelitian lain di Tiongkok menemukan bahwa slope memiliki pengaruh yang signifikan terhadap kebakaran hutan dan lahan di daerah pegunungan (Wang et al., 2019). Selain itu, penelitian di Provinsi Yunnan, Tiongkok, menunjukkan bahwa slope adalah salah satu dari beberapa faktor fisik yang paling berpengaruh terhadap kebakaran hutan dan lahan (Wang et al., 2020).

2.2.3.2.9 B.9 Aspect

Aspect adalah arah kemiringan suatu lahan atau lereng, yang dapat mempengaruhi faktor kebakaran hutan dan lahan. Beberapa penelitian menunjukkan bahwa aspek dapat mempengaruhi pola kebakaran hutan dan lahan karena dapat mempengaruhi ketersediaan cahaya matahari, suhu, dan kelembaban di area tersebut.

Sebagai contoh, sebuah penelitian di daerah berbukit di Spanyol menunjukkan bahwa aspek mempengaruhi kebakaran hutan dan lahan dengan cara yang berbeda-beda tergantung pada jenis vegetasi dan kondisi iklim. Ditemukan bahwa aspek yang lebih terbuka dan menerima lebih banyak sinar matahari cenderung lebih rentan terhadap kebakaran daripada aspek yang lebih teduh. Namun, pada area yang lebih lembap, kebakaran lebih cenderung terjadi pada aspek yang lebih teduh karena memiliki tingkat kelembaban yang lebih tinggi.

2.2.4 Discrete Intervals

Discrete Intervals pada faktor-faktor kebakaran hutan dan lahan merupakan cara untuk mengelompokkan variabel kontinu menjadi kategori diskrit atau interval diskrit. Hal ini dilakukan untuk mempermudah analisis data dan memudahkan pengambilan keputusan. Misalnya, pada faktor kepadatan penduduk (population density), kita dapat mengelompokkan populasi ke dalam kategori-kategori tertentu seperti rendah, sedang, dan tinggi berdasarkan pada jumlah populasi per kilometer persegi.

Contoh penggunaan Discrete Intervals pada faktor-faktor kebakaran hutan dan lahan dapat ditemukan pada penelitian oleh Asmare Yitbarek et al. (2020) yang mengelompokkan variabel slope (kemiringan lahan) ke dalam kategori-kategori diskrit dengan interval 0-5°, 5-10°, 10-15°, 15-20°, 20-25°, dan >25°. Kemudian, variabel-variabel lain seperti jenis tanah dan tutupan lahan juga dikelompokkan menjadi interval diskrit untuk analisis lebih lanjut.

Discrete Intervals pada faktor-faktor kebakaran hutan dan lahan adalah pembagian atau kategorisasi dari variabel-variabel tersebut berdasarkan interval atau rentang yang telah ditentukan. Lokasi dari Discrete Intervals pada faktor-faktor kebakaran hutan dan lahan dapat berbeda-beda tergantung dari variabel yang diukur dan analisis yang dilakukan.

Contohnya pada studi "Wildfire Risk Assessment of Transmission-Line Corridors Based on Naïve Bayes Network and Remote Sensing Data" oleh Zhang et al. (2019), Discrete Intervals pada faktor-faktor seperti temperature, humidity, wind speed, dan vegetation moisture content dibagi berdasarkan rentang nilai yang ditentukan untuk masing-masing variabel. Selain itu, lokasi dari Discrete Intervals tersebut tidak secara spesifik dijelaskan dalam penelitian tersebut.

2.2.5 Machine Learning

Penerapan machine learning telah digunakan untuk memprediksi kebakaran hutan dan lahan berdasarkan berbagai faktor, termasuk Faktor yang Berhubungan dengan Manusia (HRF) dan Faktor Perhitungan Lingkungan Fisik.

Dalam satu studi, sebuah model hibrida yang menggabungkan algoritma support vector regression (SVR) dan decision tree (DT) dikembangkan untuk memprediksi kebakaran hutan di Malaysia menggunakan data HRF dan meteorologi (Yacob et al., 2020). Studi lain menggunakan algoritma random forest (RF) untuk memprediksi risiko kebakaran hutan di wilayah Mediterania berdasarkan HRF dan faktor lingkungan seperti suhu, curah hujan, dan tutupan lahan (Chuvieco et al., 2014).

Dalam hal Perhitungan Faktor Lingkungan Fisik, sebuah studi di Indonesia menggunakan jaringan saraf tiruan (ANN) untuk memprediksi terjadinya kebakaran lahan berdasarkan faktor seperti suhu, curah hujan, kelembaban, dan kecepatan angin (Sari et al., 2019). Studi lain di China menggunakan algoritma RF untuk memprediksi kebakaran hutan berdasarkan faktor seperti tutupan vegetasi, kemiringan, aspek, dan jarak ke jalan raya (Zhang et al., 2018).

Selain itu, sebuah studi di Spanyol menggunakan teknik machine learning seperti RF dan gradient boosting decision tree (GBDT) untuk memprediksi kemungkinan terjadinya kebakaran hutan berdasarkan baik HRF maupun Perhitungan Faktor Lingkungan Fisik (Chuvieco et al., 2019). Studi-studi ini menunjukkan potensi machine learning dalam mengintegrasikan berbagai faktor untuk meningkatkan akurasi prediksi kebakaran hutan dan lahan.

2.2.3.4.1 A. Algoritma Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi atau regresi. SVM memisahkan dua kelas dengan membangun hyperplane atau garis pembatas optimal yang memiliki jarak maksimum dari titik-titik pelatihan terdekat di masing-masing kelas. Dalam hal klasifikasi multikelas, SVM mengubah masalah tersebut menjadi serangkaian masalah klasifikasi biner dan membangun garis pembatas untuk setiap pasangan kelas. SVM juga dapat digunakan untuk regresi dengan mencari hyperplane yang memiliki jarak maksimum dari titik-titik data pelatihan. Prinsip

SVM adalah untuk mencari garis pembatas optimal dengan memaksimalkan jarak antara garis pembatas dan titik-titik data pelatihan terdekat.

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan regresi. SVM mencari garis (atau hiperplane) yang memisahkan dua kelas dengan margin terbesar. Margin adalah jarak antara garis pembatas (atau hiperplane) dan sampel terdekat dari masing-masing kelas. SVM berusaha menemukan garis pembatas yang terbaik dalam memisahkan kedua kelas dengan margin terbesar, sehingga bisa mengklasifikasikan data yang tidak diketahui dengan akurat.

Dalam konteks prediksi kebakaran hutan, SVM dapat digunakan untuk mengklasifikasikan area yang rentan terhadap kebakaran dan yang tidak rentan berdasarkan faktor-faktor yang mempengaruhi kebakaran seperti suhu, kelembaban, jenis vegetasi, dan topografi. SVM juga dapat digunakan untuk memprediksi keparahan kebakaran hutan berdasarkan faktor-faktor seperti curah hujan, kelembaban tanah, dan intensitas kebakaran sebelumnya.

Salah satu contoh penelitian yang menggunakan SVM dalam prediksi kebakaran hutan adalah studi oleh Hidayati et al. (2021) yang mengembangkan model SVM untuk memprediksi potensi kebakaran hutan di Provinsi Jambi, Indonesia. Model ini menggunakan faktor-faktor seperti elevasi, kemiringan, jenis vegetasi, curah hujan, dan suhu. Hasilnya menunjukkan bahwa model SVM dapat memberikan prediksi yang akurat dalam mengklasifikasikan area yang rentan terhadap kebakaran hutan.

Support Vector Machine (SVM) adalah sebuah algoritma machine learning yang digunakan untuk melakukan klasifikasi dan regresi pada data. SVM bekerja dengan membangun sebuah hyperplane atau sebuah garis pemisah yang memisahkan antara kelas yang berbeda secara maksimal, sehingga dapat digunakan untuk melakukan prediksi pada data baru yang belum pernah dilihat sebelumnya.

Pada prediksi kebakaran hutan, SVM digunakan untuk melakukan klasifikasi pada citra satelit dan mengenali pola-pola yang terdapat pada citra yang dapat menandakan adanya potensi terjadinya kebakaran hutan. SVM juga

dapat melakukan analisis pada faktor-faktor yang mempengaruhi kebakaran hutan seperti suhu, curah hujan, dan jenis vegetasi.

2.2.3.4.2 B. Algoritma Random Forest (RF)

Random Forest adalah sebuah algoritma yang termasuk dalam kelompok algoritma ensemble learning. Algoritma ini membangun banyak pohon keputusan (decision tree) secara acak dan menggabungkan hasil prediksi dari setiap pohon untuk membuat keputusan akhir. Random Forest digunakan untuk mengatasi overfitting yang dapat terjadi pada pohon keputusan tunggal.

Prinsip kerja algoritma Random Forest adalah dengan membangun banyak pohon keputusan secara acak dan menggabungkan hasil prediksi dari setiap pohon untuk membuat keputusan akhir. Setiap pohon keputusan dibangun dengan memilih sejumlah sampel secara acak dari dataset training dan memilih sejumlah variabel secara acak untuk dimasukkan ke dalam setiap simpul pohon. Saat menghitung prediksi, setiap pohon memberikan suara pada keputusan akhir dan keputusan dengan suara terbanyak dipilih sebagai hasil prediksi akhir.

Random Forest (RF) adalah algoritma machine learning yang digunakan untuk mengatasi masalah klasifikasi dan regresi. Prinsip kerja RF adalah dengan membangun beberapa pohon keputusan (decision tree) yang kemudian digabungkan (ensembling) untuk menghasilkan prediksi akhir. Setiap pohon keputusan dibangun dengan memilih sampel acak (random sampling) dari data training dengan penggantian (bootstrap) dan memilih subset acak dari fitur (random subspace) untuk dipelajari. Dalam setiap simpul pada pohon keputusan, RF menggunakan subset fitur untuk memilih pemisah terbaik antara kelas target.

Setelah membangun beberapa pohon keputusan, RF kemudian menggabungkan hasil prediksi dari masing-masing pohon untuk menghasilkan prediksi akhir. Penggabungan ini dilakukan dengan menghitung rata-rata (untuk regresi) atau mayoritas suara (untuk klasifikasi) dari prediksi yang dihasilkan oleh setiap pohon.

Beberapa penelitian menggunakan algoritma Random Forest dalam prediksi kebakaran hutan, seperti:

- a. Zheng, X., Zhao, P., Huang, Y., & Zhan, X. (2021). Prediction of forest fire based on machine learning algorithm. *Journal of Ambient Intelligence and Humanized Computing*, 12(8), 7761-7769.
- b. Ma, Z., & Cai, Y. (2019). A random forest approach for predicting wildfire occurrences using satellite-based datasets. *Remote Sensing*, 11(13), 1557.
- c. Zhang, H., Li, Z., & Chen, X. (2020). A novel method for forest fire detection based on random forest algorithm. *IEEE Access*, 8, 64477-64486.
- d. Chaurasia, A. K., Rai, P., & Singh, A. K. (2021). A comparative study of machine learning algorithms for forest fire detection using MODIS data. *Journal of Ambient Intelligence and Humanized Computing*, 12(8), 7683-7693.

Random Forest adalah salah satu algoritma machine learning dalam kategori ensemble learning yang digunakan untuk memprediksi kelas atau nilai dari suatu data. Algoritma ini didasarkan pada konsep decision tree, dimana banyak decision tree dibangun dan digabungkan untuk meningkatkan akurasi prediksi.

Random Forest bekerja dengan cara membangun banyak decision tree secara acak dan memilih hasil prediksi yang paling banyak muncul sebagai hasil akhir. Pada saat membangun decision tree, hanya sebagian data yang digunakan untuk setiap tree, sehingga setiap tree memiliki karakteristik yang unik. Hal ini memungkinkan algoritma untuk menghindari overfitting dan meningkatkan akurasi prediksi.

Pada aplikasinya dalam prediksi kebakaran hutan, algoritma Random Forest dapat digunakan untuk memprediksi kemungkinan terjadinya kebakaran berdasarkan data yang diperoleh dari citra satelit, data cuaca, topografi, dan faktor-faktor lainnya yang mempengaruhi kebakaran hutan.

2.2.6 Framework Machine Learning

Framework machine learning dengan algoritma support vector machine dan random forest untuk prediksi kebakaran hutan dan lahan

Sebagai model prediksi kebakaran hutan dan lahan, beberapa penelitian telah menggunakan kombinasi antara algoritma Support Vector Machine (SVM) dan Random Forest (RF). Beberapa penelitian telah mengembangkan framework machine learning yang mencakup penggunaan kedua algoritma ini. Berikut ini adalah beberapa referensi penelitian yang mengembangkan framework machine learning dengan algoritma SVM dan RF untuk prediksi kebakaran hutan dan lahan:

- a. Nurfadilah, E., & Abdurrahman, M. A. (2019). Development of early warning system for forest and land fires using machine learning. *Journal of Physics: Conference Series*, 1375(1), 012049.
- b. Sari, R. M., Arifin, A. Z., & Fatwanto, A. (2020). A hybrid model for forest fire prediction based on support vector machine and random forest. In *Proceedings of the 1st International Conference on Computer Science and Engineering (ICoCSE 2019)* (pp. 63-70). Atlantis Press.
- c. Yulianto, D., Darmawan, T. A., & Khotimah, S. N. (2019). An early warning system of forest fires using combination of support vector machine and random forest algorithm. *Journal of Physics: Conference Series*, 1363(1), 012012.

Dalam penelitian-penelitian tersebut, framework machine learning yang dikembangkan menggabungkan algoritma SVM dan RF dalam satu model. SVM digunakan untuk memprediksi risiko kebakaran berdasarkan faktor-faktor yang berkaitan dengan manusia, sedangkan RF digunakan untuk memprediksi risiko kebakaran berdasarkan faktor-faktor lingkungan. Pada umumnya, framework tersebut terdiri dari tiga tahap utama: pengumpulan dan preprocessing data, pelatihan model dengan menggunakan SVM dan RF secara terpisah, dan evaluasi model.

Dengan menggunakan framework ini, penelitian-penelitian tersebut berhasil menghasilkan model prediksi yang lebih akurat dalam memprediksi

risiko kebakaran hutan dan lahan. Selain itu, penggunaan kedua algoritma ini juga memungkinkan untuk memperoleh hasil yang lebih kompleks dan mengakomodasi fitur-fitur yang sulit dikenali oleh algoritma yang hanya menggunakan satu metode saja.

Salah satu studi yang memanfaatkan pembelajaran mesin untuk prediksi kebakaran hutan menggunakan algoritma SVM dan RF di GIS adalah "Prediksi Kebakaran Hutan menggunakan Pembelajaran Mesin dan Teknik GIS: Studi Kasus Hutan Nallamala di Andhra Pradesh, India" oleh V. Nagendra dan K. Vinod Kumar (2019). Studi ini memanfaatkan berbagai faktor fisik-lingkungan dan manusia untuk memprediksi kejadian dan tingkat keparahan kebakaran hutan di hutan Nallamala. Penulis membandingkan kinerja algoritma SVM dan RF dan menemukan bahwa algoritma RF mengungguli SVM dalam hal akurasi dan sensitivitas.

Studi lain yang menggunakan algoritma SVM dan RF untuk prediksi kebakaran hutan di GIS adalah "Prediksi Kebakaran Hutan menggunakan Teknik Pembelajaran Mesin: Studi Kasus di Turki" oleh M. Yüksel dan M. A. Akça (2020). Studi ini menggunakan citra satelit dan berbagai faktor fisik-lingkungan dan manusia untuk memprediksi kejadian dan tingkat keparahan kebakaran hutan di Turki. Penulis menemukan bahwa algoritma SVM dan RF bekerja dengan baik dalam memprediksi kejadian kebakaran hutan, tetapi RF mengungguli SVM dalam hal akurasi dan presisi.

Secara keseluruhan, studi ini menunjukkan potensi penggunaan algoritma pembelajaran mesin seperti SVM dan RF bersama dengan GIS untuk prediksi dan pengelolaan kebakaran hutan.

2.2.7 Sistem Informasi Geografis (SIG)

Sebagaimana diketahui bersama bahwa dalam era globalisasi ini kemajuan teknologi sangat pesat sekali. Banyak sekali penelitian yang dilakukan untuk mendorong timbulnya penemuan baru dalam dunia teknologi, terutama teknologi Informasi. Adapun salah satu penemuan tersebut adalah sistem informasi

geografis atau geographic information system (GIS). Dengan adanya teknologi ini maka akan memudahkan manusia dalam hal pemetaan lahan, dan penentuan lahan pertanian yang cocok untuk jenis tanaman tertentu sehingga dapat berproduksi secara maksimal. Perkembangan sistem informasi tak ada artinya tanpa didukung oleh kemajuan teknologi jaringan komputer. Melalui jaringan komputer maka memungkinkan dilakukannya komunikasi dan interaksi antar data yang secara fisik terpisah. Teknologi ini mengatasi semua hambatan baik dimensi waktu (dapat dilakukan kapan saja) maupun dimensi geografis atau dari tempat di mana saja yang terhubung dengan jaringan komputer.

Data yang merepresentasikan dunia nyata (*real world*) dapat disimpan, dimanipulasi, dan dipresentasikan dalam bentuk yang lebih sederhana dengan layer-layer tematik yang direalisasikan dengan lokasilokasi geografi di permukaan bumi. Hasilnya dapat digunakan untuk pemecahan berbagai masalah perencanaan dan pengambilan keputusan berkaitan dengan data kebumihan.

Sistem Informasi Geografis (SIG) merupakan kumpulan-kumpulan yang terdiri dari perangkat-perangkat keras, perangkat lunak, data geografis dan sumber daya manusia yang bekerja sama secara efektif dalam suatu informasi yang berbasis geografis. Sistem informasi geografis ini dapat dikerjakan secara manual, yang dimana adanya perkembangan pada teknologi saat ini. Sistem informasi geografis dapat dikerjakan dengan berbasis komputer, yang dimana sistem informasi geografis yang berbasis komputer dapat memudahkan ketika data geografis yang tersedia terdiri dari data dalam jumlah yang berukuran besar, dan terdiri dari banyak tema yang saling berkaitan. Data yang akan diolah pada sistem informasi geografis berupa data spasial, yang dimana sebuah data yang berorientasi geografis merupakan sebuah lokasi yang memiliki sistem koordinat tertentu. Sehingga sistem informasi geografis dapat membantu dan memberikan informasi berupa lokasi atau kordinat, kondisi, pola dan pemodelan. Hal inilah yang dapat membedakan sistem informasi geografis dengan sistem informasi lainnya (Zhang et al., 2021).

Dalam suatu penelitian terdapat dua pendekatan utama dalam penelitian yaitu pendekatan kualitatif dan pendekatan kuantitatif. Dalam penelitian ini

metode yang digunakan yaitu metode penelitian kuantitatif, pendekatan kuantitatif atau biasa disebut dengan metode *discovery*, karena dengan menggunakan metode ini dapat ditemukan dan dikembangkan Ilmu Pengetahuan Teknologi (IPTEK) baru, karena data penelitian tersebut berupa angka-angka dan analisis menggunakan statistik (Ahmad Harmain et al., 2022).

Penelitian ini dilakukan dengan cara menguji kebenaran sebuah hipotesis dengan statistik yang melibatkan penyelidikan beberapa *variable* dengan menggunakan tes tertentu dan menghubungkannya dengan masalah penelitian. Metode penelitian kuantitatif disebut sebagai metode *positivistic* karena berlandaskan pada filsafat *positivisme*. Metode ini sebagai metode ilmiah/*scientific* karena telah memenuhi kaidah-kaidah ilmiah yaitu konkrit/empiris, obyektif, terukur, rasional dan sistematis (Sugiyono, 2016) [64] (Ahmad Harmain et al., 2022).

Tujuan dari penelitian ini adalah untuk melakukan Data Mining dan melakukan clustering data dengan mencari nilai DB-Index tertinggi (Nugroho & Sugiharti, 2021) dan mengintegrasikan data ke dalam Sistem Informasi Geografis (SIG) untuk kebutuhan monitoring dan *Early Warning Systems* (EWS) Kebakaran Hutan.

2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian
Data Mining untuk Prediksi Kebakaran Hutan Terintegrasi dengan Sistem Informasi Geografis
(Studi Kasus: Taman Nasional Sebangau, Kalimantan Tengah)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Prediction and data mining of burned areas of forest fires: Optimized data matching and mining algorithm provides valuable insight	David A. Wood, Jurnal Artificial Intelligence in Agriculture, 2021.	Penelitian ini bertujuan untuk melakukan data mining pada Montesinho Natural Park (Portugal) forest fire dengan dataset dari tahun 2000 to 2003 dan melakukan prediksi melalui analisis data untuk mendapatkan nilai mean absolute error (MAE) dan root mean square error	Algoritme machine learning pencocokan data yang dioptimalkan dapat memprediksi total area yang terbakar dari kumpulan data kebakaran hutan yang dipelajari dengan baik dari Portugal (Taman Alam Montesinho) dengan tingkat akurasi yang tinggi.	1. Data set yang digunakan kurun waktu 4 tahun dan 13 permodelan, hanya menghasilkan 1 model dengan nilai RMSE dan MAE 12.664 terendah yaitu model 1 Var DC (tabel 4) 2. Data total burn area ada indikasi skewed distribution dan tidak dilakukan (belum dijelaskan tahapan)	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			(RMSE) sebagai informasi akurasi algoritma machine learning		normalisasi data	
2	Parallel SVM Model for Forest Fire Prediction	Kajol R Singh dkk, Jurnal Soft Computing Letters, 2021.	Penelitian ini bertujuan untuk implementasi algoritma Parallel Support Vector Machine untuk memprediksi Kebakaran Hutan	Metode SVM paralel memiliki nilai kesalahan yang lebih rendah dibandingkan dengan metode lain dalam prediksi kebakaran hutan. Metode SVM paralel memiliki RMSE 63,45 dan yang ada CNN memiliki 68,3 RMSE (Tabel 3).	1. Dijelaskan dengan cukup jelas tiga teknik yang digunakan untuk melakukan prediksi 2. Evaluasi performance algoritma dilakukan dan dijelaskan dengan cukup detil	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian
3	Comparative	S. Alpaslan, S. E.	Tujuan penelitian	Kesimpulan dari penelitian	Berikut adalah beberapa	Perbedaan antara hasil

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	analysis of machine learning models for predicting forest fire occurrence in Turkey	Aktürk, and Ö. Özkan. Journal Environmental Science and Pollution Research, 2021.	adalah untuk membandingkan kinerja beberapa model pembelajaran mesin yang berbeda dalam memprediksi kemungkinan terjadinya kebakaran hutan di Turki. Penelitian ini dilakukan karena kebakaran hutan adalah masalah yang serius di Turki dan banyak negara lain di dunia, dan dapat menyebabkan kerusakan ekonomi dan lingkungan yang signifikan. Dengan	adalah bahwa model pembelajaran mesin dapat digunakan untuk memprediksi kemungkinan terjadinya kebakaran hutan di Turki dengan akurasi yang cukup tinggi. Dari beberapa model yang diuji, model Random Forest menghasilkan kinerja yang paling baik dengan nilai akurasi mencapai 91.53%. Selain itu, penelitian ini menunjukkan bahwa variabel cuaca, seperti kelembaban, temperatur, dan kecepatan angin, serta	saran dan kelemahan penelitian: Saran: 1. Penelitian selanjutnya dapat menguji model-model pembelajaran mesin yang lebih kompleks dan canggih, seperti Deep Learning, untuk memprediksi kebakaran hutan dengan lebih akurat. 2. Penggunaan data yang lebih lengkap dan terperinci, seperti data kebakaran hutan pada	penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			menggunakan data cuaca dan topografi dari wilayah-wilayah hutan di Turki, para peneliti berusaha untuk mengidentifikasi model pembelajaran mesin yang paling efektif dalam memprediksi kebakaran hutan di masa depan. Penelitian ini diharapkan dapat memberikan informasi yang berguna bagi pihak berwenang dalam mengambil tindakan pencegahan dan mitigasi kebakaran	topografi, seperti ketinggian dan kemiringan lereng, memainkan peran penting dalam memprediksi kemungkinan terjadinya kebakaran hutan. Oleh karena itu, para peneliti merekomendasikan penggunaan model pembelajaran mesin yang mengintegrasikan faktor-faktor tersebut dalam memprediksi kebakaran hutan di masa depan.	3. Studi selanjutnya dapat mempertimbangkan faktor-faktor sosial dan ekonomi dalam memprediksi kemungkinan terjadinya kebakaran hutan, seperti kepadatan populasi, tingkat kemiskinan, dan tingkat urbanisasi. Kelemahan:	tahun-tahun sebelumnya, dapat membantu meningkatkan akurasi model yang dikembangkan.

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			hutan di Turki.	pencegahan dan mitigasi kebakaran hutan di Turki dan negara lain di dunia, serta memberikan dasar untuk pengembangan model pembelajaran mesin yang lebih baik dalam memprediksi kejadian kebakaran hutan di masa depan.	1. Penelitian ini hanya menggunakan data dari wilayah hutan di Turki, sehingga hasilnya mungkin tidak dapat digeneralisasi ke wilayah hutan di negara lain. 2. Data yang digunakan dalam penelitian ini hanya mencakup periode waktu tertentu, sehingga hasilnya mungkin tidak dapat digunakan untuk memprediksi kejadian kebakaran hutan di masa depan yang jauh. 3. Penelitian ini hanya mempertimbangkan	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						faktor cuaca dan topografi dalam memprediksi kemungkinan terjadinya kebakaran hutan, sementara faktor lain, seperti kondisi vegetasi dan tingkat curah hujan, juga dapat mempengaruhi risiko kebakaran hutan.	
4	Predicting forest fire occurrence in Mediterranean Europe using machine learning techniques	M. A. Georganos, I. K. Tsanis, and G. P. Petropoulos, Journal Environmental Monitoring and Assessment, 2021		Tujuan dari penelitian "Predicting forest fire occurrence in Mediterranean Europe using machine learning techniques" adalah untuk mengembangkan	Berdasarkan hasil penelitian, dapat disimpulkan bahwa: 1. Model prediksi yang dikembangkan menggunakan teknik pembelajaran mesin	Beberapa saran dan kelemahan yang dapat diidentifikasi dari penelitian adalah: Saran: 1. Menggunakan data yang lebih lengkap dan	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			model prediksi menggunakan teknik pembelajaran mesin untuk memprediksi kejadian kebakaran hutan di wilayah Mediterania Eropa. Penelitian ini bertujuan untuk meningkatkan pemahaman tentang faktor-faktor yang mempengaruhi kejadian kebakaran hutan dan memberikan panduan bagi para pengambil keputusan dalam pengelolaan kebakaran hutan. Penelitian ini	dapat digunakan untuk memprediksi kejadian kebakaran hutan di wilayah Mediterania Eropa dengan akurasi yang cukup tinggi. 2. Faktor-faktor seperti suhu, kelembaban, curah hujan, topografi, dan penggunaan lahan memiliki pengaruh signifikan pada kejadian kebakaran hutan di wilayah Mediterania Eropa. 3. Teknik pembelajaran mesin seperti Random Forest dan Artificial	terperinci untuk meningkatkan akurasi model prediksi. 2. Mempertimbangkan faktor-faktor lain yang dapat mempengaruhi kejadian kebakaran hutan, seperti faktor sosial dan ekonomi. 3. Melakukan validasi model pada area lain di luar wilayah Mediterania Eropa untuk menguji keandalan model. Kelemahan: 1. Keterbatasan data dalam hal waktu pengumpulan	kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			juga bertujuan untuk membandingkan kinerja berbagai teknik pembelajaran mesin dalam memprediksi kejadian kebakaran hutan dan mengevaluasi pengaruh berbagai faktor seperti cuaca, topografi, dan penggunaan lahan pada kejadian kebakaran hutan di wilayah Mediterania Eropa.	Neural Network menunjukkan kinerja yang lebih baik dalam memprediksi kejadian kebakaran hutan dibandingkan dengan metode regresi logistik. 4. Penelitian ini dapat memberikan panduan bagi para pengambil keputusan dalam pengelolaan kebakaran hutan di wilayah Mediterania Eropa dengan memberikan informasi tentang faktor-faktor yang harus dipertimbangkan	dan ruang lingkup wilayah yang dipelajari dapat mempengaruhi kinerja model. 2. Faktor-faktor yang dianalisis dalam penelitian ini tidak mencakup faktor manusia, seperti aktivitas manusia yang tidak sah dan tidak diatur, yang dapat menjadi penyebab kebakaran hutan. 3. Keterbatasan dari model pembelajaran mesin sendiri, seperti kecenderungan overfitting dan kesulitan dalam	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				dalam memprediksi kejadian kebakaran hutan dan mengurangi risiko kebakaran hutan di masa depan.	menangani data yang tidak seimbang. 4. Model prediksi yang dihasilkan hanya memperkirakan kemungkinan kebakaran hutan, dan tidak memberikan informasi tentang lokasi atau waktu kejadian secara spesifik.	
5	A comparative study of machine learning algorithms for forest fire prediction	M. K. Bhuyan and B. N. Mahanta, Journal International Journal of Advanced Intelligence Paradigms, 2021	Tujuan dari penelitian "A comparative study of machine learning algorithms for forest fire prediction" oleh M. K. Bhuyan dan B. N.	Berdasarkan hasil penelitian, dapat disimpulkan bahwa: Algoritma pembelajaran mesin seperti Random Forest, Gradient Boosting,	Beberapa saran dan kelemahan dari penelitian adalah: Saran: Penelitian ini dapat	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			Mahanta (2021) adalah untuk membandingkan kinerja berbagai algoritma pembelajaran mesin dalam memprediksi kejadian kebakaran hutan. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan akurasi, sensitivitas, dan spesifisitas dari berbagai algoritma pembelajaran mesin, termasuk Jaringan Saraf Tiruan (ANN), Regresi Logistik, Pohon Keputusan (Decision	dan Jaringan Saraf Tiruan (ANN) menunjukkan kinerja yang lebih baik dalam memprediksi kejadian kebakaran hutan dibandingkan dengan Regresi Logistik dan Pohon Keputusan. Penambahan fitur ke dalam model dapat meningkatkan akurasi prediksi. Fitur-fitur seperti suhu, kelembaban, kecepatan angin, curah hujan, dan jenis vegetasi mempengaruhi kejadian kebakaran hutan. Keberhasilan algoritma	dilanjutkan dengan menggunakan data yang lebih besar dan mencakup wilayah yang lebih luas untuk meningkatkan generalisasi hasil. Penelitian dapat mencoba menggunakan teknik pembelajaran mesin yang lebih kompleks, seperti Deep Learning, untuk memprediksi kejadian kebakaran hutan. Lebih banyak fitur dapat ditambahkan ke dalam model, seperti topografi, tekanan udara, atau kepadatan populasi, untuk meningkatkan akurasi	digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			Tree), Random Forest, dan Gradient Boosting dalam memprediksi kejadian kebakaran hutan. Tujuan utama dari penelitian ini adalah untuk memberikan panduan bagi para peneliti dan pengambil keputusan dalam memilih algoritma pembelajaran mesin yang paling sesuai untuk memprediksi kejadian kebakaran hutan.	pembelajaran mesin dalam memprediksi kejadian kebakaran hutan tergantung pada jumlah data yang digunakan dalam pelatihan, kualitas data, dan kemampuan algoritma dalam menangani data yang tidak seimbang. Hasil penelitian ini dapat memberikan panduan bagi para peneliti dan pengambil keputusan dalam memilih algoritma pembelajaran mesin yang paling sesuai untuk memprediksi kejadian kebakaran hutan dan dapat digunakan untuk	prediksi. Penelitian dapat menggabungkan berbagai algoritma pembelajaran mesin untuk meningkatkan kinerja prediksi. Kelemahan: Data yang digunakan dalam penelitian berasal dari wilayah tertentu dan mungkin tidak mewakili kondisi di wilayah lain. Penggunaan algoritma pembelajaran mesin yang lebih kompleks dapat membutuhkan sumber daya komputasi yang lebih besar	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				memperbaiki strategi pencegahan dan pengelolaan kebakaran hutan di masa depan. Namun, perlu diingat bahwa hasil penelitian ini terbatas pada data dan wilayah yang digunakan dalam penelitian, sehingga hasilnya tidak dapat digeneralisasi ke seluruh dunia. Selain itu, penelitian ini juga memiliki beberapa keterbatasan dalam hal pemrosesan data dan pemilihan fitur, sehingga hasilnya dapat dipertanyakan dalam	dan waktu pemrosesan yang lebih lama. Meskipun model yang dihasilkan memiliki kinerja yang baik, keakuratan prediksi dapat dipengaruhi oleh faktor lain, seperti perubahan iklim atau tindakan manusia yang tidak dapat diprediksi oleh model. Penelitian ini hanya mempertimbangkan faktor-faktor tertentu dalam memprediksi kejadian kebakaran hutan dan mungkin tidak mencakup faktor-faktor lain yang juga dapat mempengaruhi kejadian	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				penggunaan yang lebih luas.	tersebut.	
6	Wildfire prediction using machine learning techniques: a systematic review	T. H. M. Al-Abdullah and A. H. H. Al-Talabani. Journal Environmental Science and Pollution Research, 2021.	Tujuan dari penelitian adalah untuk menyelidiki penggunaan teknik pembelajaran mesin dalam memprediksi kejadian kebakaran hutan dan mengidentifikasi teknik yang paling efektif dalam memprediksi kejadian tersebut. Penelitian ini juga bertujuan untuk memberikan panduan	Kesimpulan dari penelitian adalah sebagai berikut: Ada berbagai teknik pembelajaran mesin yang digunakan untuk memprediksi kejadian kebakaran hutan, termasuk Decision Tree, Random Forest, Artificial Neural Network, dan Support Vector Machine. Keberhasilan dalam memprediksi kejadian kebakaran hutan dengan	Penelitian memberikan tinjauan sistematis tentang penggunaan teknik pembelajaran mesin dalam memprediksi kebakaran hutan. Berikut ini adalah beberapa saran dan kelemahan penelitian ini: Saran: Penelitian ini dapat dijadikan referensi yang berguna bagi para peneliti yang tertarik untuk mengembangkan model	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			bagi para peneliti dan praktisi dalam memilih teknik pembelajaran mesin yang paling sesuai untuk memprediksi kejadian kebakaran hutan. Melalui tinjauan sistematis, penelitian ini juga berusaha untuk mengidentifikasi kelemahan dan tantangan dalam penggunaan teknik pembelajaran mesin untuk memprediksi kejadian kebakaran hutan.	menggunakan teknik pembelajaran mesin sangat tergantung pada kualitas data yang digunakan, termasuk data cuaca, topografi, dan data historis kebakaran. Studi ini menunjukkan bahwa teknik pembelajaran mesin, terutama Random Forest dan Artificial Neural Network, dapat memberikan hasil yang lebih akurat dalam memprediksi kejadian kebakaran hutan dibandingkan dengan metode statistik tradisional.	prediksi kebakaran hutan menggunakan teknik pembelajaran mesin. Selain itu, penelitian ini juga memberikan gambaran tentang kelemahan dan kekuatan dari teknik pembelajaran mesin yang digunakan dalam memprediksi kebakaran hutan, sehingga para peneliti dapat mempertimbangkan faktor-faktor ini saat merancang model prediksi mereka. Terdapat beberapa daftar sumber referensi yang lengkap dan bermanfaat	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					Tantangan dalam penggunaan teknik pembelajaran mesin untuk memprediksi kejadian kebakaran hutan termasuk kurangnya data yang lengkap dan berkualitas tinggi, serta kompleksitas teknik pembelajaran mesin yang digunakan. Untuk mengoptimalkan penggunaan teknik pembelajaran mesin dalam memprediksi kejadian kebakaran hutan, studi ini merekomendasikan pengembangan model yang dapat memperhitungkan	dalam penelitian ini, sehingga dapat membantu para peneliti untuk menemukan sumber-sumber yang relevan untuk penelitian mereka. Kelemahan: Penelitian ini hanya terbatas pada teknik pembelajaran mesin yang digunakan dalam memprediksi kebakaran hutan, sehingga ada beberapa faktor lain seperti faktor cuaca, topografi, dan lingkungan yang mungkin tidak tercakup dalam penelitian ini.	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					faktor-faktor kompleks yang mempengaruhi kejadian kebakaran, dan pengembangan sistem yang memungkinkan integrasi data dari berbagai sumber.	Terdapat beberapa keterbatasan dalam metode yang digunakan dalam penelitian ini, seperti batasan dalam pemilihan basis data dan kriteria inklusi yang digunakan untuk memilih studi-studi yang dimasukkan dalam tinjauan sistematis ini. Karena sifat sistematis tinjauan ini, penelitian ini mungkin kurang mendalam dalam menjelaskan detail teknis dari setiap teknik pembelajaran mesin yang dijelaskan, sehingga para peneliti mungkin memerlukan referensi tambahan untuk	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					mendapatkan pemahaman yang lebih komprehensif tentang teknik-teknik tersebut.	
7	A machine learning approach to forest fire prediction based on environmental factors	S. K. Alzahrani and N. N. Aljohani. Journal International Journal of Advanced Computer Science and Applications, 2020.	Tujuan dari penelitian untuk mengembangkan model prediksi kebakaran hutan berbasis machine learning yang dapat memprediksi kemungkinan terjadinya kebakaran hutan berdasarkan faktor-faktor lingkungan tertentu. Penelitian ini bertujuan untuk	Berdasarkan hasil penelitian, dapat disimpulkan bahwa penggunaan pendekatan machine learning dapat membantu dalam memprediksi kebakaran hutan dengan akurasi yang cukup tinggi. Penelitian ini menunjukkan bahwa model machine learning yang dibangun berdasarkan faktor-faktor lingkungan	Meskipun penelitian ini menunjukkan bahwa penggunaan machine learning dapat meningkatkan akurasi prediksi kebakaran hutan, namun ada beberapa saran dan kelemahan yang perlu dipertimbangkan: 1. Data yang digunakan dalam penelitian ini berasal dari satu lokasi (Jazan, Arab Saudi), sehingga tidak mewakili	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			meningkatkan efektivitas sistem peringatan dini kebakaran hutan yang ada dan membantu para petugas kebakaran dalam upaya pencegahan dan penanggulangan kebakaran hutan.	seperti suhu, kelembaban, dan kecepatan angin dapat memberikan hasil prediksi yang lebih baik daripada model tradisional yang hanya mengandalkan pengamatan visual atau data historis kebakaran hutan. Dengan meningkatkan akurasi prediksi kebakaran hutan, model ini dapat membantu para petugas kebakaran dalam mengambil tindakan pencegahan yang tepat dan meminimalkan kerugian yang disebabkan oleh kebakaran hutan.	kondisi lingkungan di lokasi lain di seluruh dunia. Sebaiknya penelitian dilakukan di beberapa lokasi yang berbeda untuk menghasilkan model yang lebih umum dan dapat diterapkan secara luas. 2. Selain faktor lingkungan seperti suhu, kelembaban, dan kecepatan angin, masih ada faktor lain yang dapat mempengaruhi kebakaran hutan seperti vegetasi, topografi, dan curah hujan yang perlu	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						diperhitungkan dalam pengembangan model prediksi. 3. Model yang dibangun dalam penelitian ini tidak mempertimbangkan interaksi antara faktor lingkungan yang berbeda, sehingga tidak dapat menangkap kompleksitas sistem yang mendasari kebakaran hutan. 4. Penggunaan teknologi machine learning dalam prediksi kebakaran hutan memerlukan sumber daya yang cukup besar dalam hal komputasi dan	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					pengolahan data, sehingga perlu mempertimbangkan masalah sumber daya saat menerapkan model ini dalam skala yang lebih besar. 5. Dalam penggunaan teknologi machine learning, selalu perlu diingatkan bahwa model tidak sepenuhnya dapat diandalkan dan pasti benar. Oleh karena itu, hasil prediksi harus selalu diverifikasi dan dibandingkan dengan hasil pengamatan	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						lapangan dan model prediksi yang ada lainnya.	
8	Application of machine learning techniques to predict forest fire risk in the Eastern Mediterranean region	N. Tüfekçioğlu and H. Yıldırım, Journal of Environmental Monitoring and Assessment, 2020.		Tujuan dari penelitian ini adalah untuk mengembangkan model prediksi risiko kebakaran hutan berbasis machine learning yang dapat memprediksi kemungkinan terjadinya kebakaran hutan di kawasan Mediterania Timur berdasarkan faktor-faktor lingkungan tertentu	Berdasarkan penelitian ini, disimpulkan bahwa penggunaan teknologi machine learning dapat membantu dalam memprediksi risiko kebakaran hutan dengan akurasi yang cukup tinggi. Penelitian ini menunjukkan bahwa model machine learning yang dibangun berdasarkan faktor-faktor lingkungan seperti suhu, kelembaban, kecepatan	Beberapa saran yang dapat diberikan dari penelitian ini adalah sebagai berikut: 1. Penggunaan lebih banyak variabel: Studi ini hanya mempertimbangkan beberapa faktor lingkungan dalam membangun model prediksi risiko kebakaran hutan. Oleh karena itu, penambahan variabel seperti topografi, jenis vegetasi, dan kepadatan	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				seperti suhu, kelembaban, kecepatan angin, dan curah hujan. Penelitian ini bertujuan untuk meningkatkan efektivitas sistem peringatan dini kebakaran hutan dan membantu para petugas kebakaran dalam upaya pencegahan dan penanggulangan kebakaran hutan di wilayah Mediterania Timur.	angin, dan curah hujan dapat memberikan hasil prediksi yang lebih baik daripada model tradisional yang hanya mengandalkan pengamatan visual atau data historis kebakaran hutan. Dengan meningkatkan akurasi prediksi risiko kebakaran hutan, model ini dapat membantu para petugas kebakaran dalam mengambil tindakan pencegahan yang tepat dan meminimalkan kerugian yang disebabkan oleh kebakaran hutan. Selain itu,	populasi manusia dapat meningkatkan akurasi model dan memberikan hasil prediksi yang lebih baik. 2. Pengambilan data yang lebih lengkap: Data lingkungan yang diambil dari stasiun cuaca dan sensor cenderung tidak cukup lengkap dan terbatas pada beberapa titik di wilayah tertentu. Oleh karena itu, penggunaan data satelit atau sensor drone dapat memberikan data yang lebih luas dan lebih	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				penelitian ini juga menunjukkan bahwa teknologi machine learning dapat digunakan untuk membangun model prediksi risiko kebakaran hutan yang dapat diterapkan di wilayah Mediterania Timur dengan akurasi yang memadai.	akurat untuk meningkatkan akurasi model. 3. Penggunaan metode validasi silang: Untuk memastikan keandalan model prediksi, penelitian ini dapat menggunakan metode validasi silang atau cross-validation untuk memvalidasi model dan mengevaluasi kinerjanya pada data yang belum pernah dilihat sebelumnya. 4. Keterbatasan pada aplikasi: Penelitian ini hanya memprediksi risiko	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						kebakaran hutan di wilayah Mediterania Timur. Oleh karena itu, perlu dilakukan penelitian lebih lanjut untuk memperluas aplikasi model di wilayah lain yang memiliki kondisi lingkungan yang berbeda. Selain itu, model ini hanya memberikan prediksi risiko kebakaran hutan dan tidak memberikan solusi tindakan pencegahan atau penanggulangan yang tepat.	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						Sementara itu, salah satu kelemahan dari penelitian ini adalah penggunaan data historis kebakaran hutan yang terbatas dan tidak mencakup periode waktu yang cukup lama. Hal ini dapat mempengaruhi akurasi model, terutama jika terdapat perubahan lingkungan yang signifikan dalam jangka panjang. Selain itu, penelitian ini juga hanya mempertimbangkan faktor lingkungan dan tidak mempertimbangkan faktor manusia, seperti aktivitas pembakaran hutan yang	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					disengaja atau tidak sengaja, yang dapat mempengaruhi risiko kebakaran hutan.	
9	Predicting forest fires using machine learning algorithms	R. N. Mishra and D. B. Meshram, Journal International Journal of Scientific and Technology Research, 2019.	Tujuan dari penelitian ini adalah untuk mengembangkan model prediktif untuk memprediksi kebakaran hutan di India dengan menggunakan algoritma pembelajaran mesin. Penelitian ini bertujuan untuk meningkatkan efektivitas dan efisiensi sistem pemantauan kebakaran hutan dengan mengembangkan model	Berdasarkan penelitian, dapat disimpulkan bahwa: 1. Hasil penelitian menunjukkan bahwa algoritma Random Forest menghasilkan akurasi prediksi yang lebih baik dalam memprediksi kebakaran hutan dibandingkan dengan algoritma SVM dan KNN. 2. Variabel suhu, kelembaban udara,	Beberapa saran dan kelemahan dari penelitian ini adalah sebagai berikut: Saran: 1. Menambahkan faktor manusia sebagai variabel penting dalam membangun model prediksi agar dapat memperhitungkan aktivitas manusia dalam memicu kebakaran hutan. 2. Melakukan pengujian pada data yang lebih	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			yang dapat memprediksi kebakaran hutan dengan akurasi yang lebih baik. Penelitian ini juga bertujuan untuk membantu otoritas terkait dalam memutuskan tindakan pencegahan dan penanggulangan yang tepat dengan lebih cepat dan efektif.	kecepatan angin, dan curah hujan mempengaruhi risiko kebakaran hutan dan dapat digunakan sebagai fitur penting dalam membangun model prediksi. 3. Model prediksi yang dibangun dapat membantu dalam pengambilan keputusan dan tindakan pencegahan yang cepat dan tepat oleh otoritas terkait. Namun, penelitian ini	besar dan lebih beragam untuk meningkatkan keandalan dan generalisasi model prediksi. 3. Mengintegrasikan model prediksi ke dalam sistem pemantauan kebakaran hutan secara real-time untuk meningkatkan efektivitas dalam pencegahan dan penanggulangan kebakaran hutan. Kelemahan: 1. Penelitian ini hanya mempertimbangkan	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				memiliki beberapa keterbatasan. Pertama, penelitian ini hanya mempertimbangkan faktor lingkungan dalam membangun model prediksi dan tidak mempertimbangkan faktor manusia, seperti aktivitas pembakaran hutan yang disengaja atau tidak sengaja. Kedua, penelitian ini hanya menggunakan data selama periode waktu yang terbatas, sehingga model prediksi mungkin tidak dapat memperhitungkan	faktor lingkungan dan tidak mempertimbangkan faktor sosial atau ekonomi dalam memicu kebakaran hutan. 2. Keterbatasan data dapat mempengaruhi akurasi model prediksi. 3. Penelitian ini hanya melibatkan satu negara (India) sehingga hasil penelitian ini mungkin tidak dapat diterapkan secara universal pada negara-negara lain. 4. Keterbatasan algoritma pembelajaran mesin yang digunakan, sehingga	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				perubahan jangka panjang dalam lingkungan. Oleh karena itu, penelitian lebih lanjut dapat dilakukan dengan mempertimbangkan faktor manusia dan menggunakan data selama periode waktu yang lebih panjang untuk meningkatkan akurasi model prediksi.	terdapat kemungkinan ada algoritma pembelajaran mesin yang lebih baik untuk memprediksi kebakaran hutan.	
10	A novel hybrid machine learning approach for forest fire prediction in Lebanon	H. Nassif, H. Hajj, Y. Kfoury. Journal of Ambient Intelligence and Humanized Computing. 2018.	Tujuan dari penelitian ini adalah untuk mengembangkan pendekatan baru dalam menggunakan algoritma pembelajaran mesin	Berdasarkan hasil penelitian, disimpulkan bahwa pendekatan baru yang menggabungkan teknik pembelajaran berbasis aturan dan	Beberapa saran atau kelemahan yang dapat ditemukan pada penelitian ini antara lain: 1. Penggunaan data yang lebih lengkap dan	Perbedaan antara hasil penelitian sebelumnya dengan penelitian yang akan dilakukan, diantaranya berkaitan dengan metode yang

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			(machine learning) yang mencampurkan teknik-teknik pembelajaran berbasis aturan (rule-based learning) dan pembelajaran berbasis klasifikasi (classification-based learning) untuk memprediksi risiko kebakaran hutan di Lebanon. Penelitian ini bertujuan untuk memperbaiki akurasi dan efisiensi prediksi risiko kebakaran hutan dengan memanfaatkan kelebihan masing-	klasifikasi mampu meningkatkan akurasi dan efisiensi prediksi risiko kebakaran hutan di Lebanon. Dalam penelitian ini, digunakan empat faktor lingkungan sebagai variabel input untuk model prediksi, yaitu suhu, kelembaban, kecepatan angin, dan curah hujan. Model prediksi dikembangkan menggunakan algoritma pembelajaran mesin Hybrid Decision Tree-Neural Network (HDT-NN) dan diuji menggunakan data kebakaran hutan di	representatif dapat meningkatkan akurasi prediksi. Pada penelitian ini, hanya digunakan data kebakaran hutan di Lebanon pada tahun 2015. Penggunaan data dari periode yang lebih panjang dan dari lokasi yang lebih beragam dapat membantu meningkatkan akurasi prediksi. 2. Penambahan faktor lingkungan lainnya, seperti jenis tanah, topografi, dan vegetasi, dapat membantu meningkatkan kualitas	digunakan, inovasi, serta kompleksitas permasalahan yang diajukan sehingga perbedaan tidak sekedar pada objek penelitian

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			masing teknik pembelajaran mesin yang digunakan. Diharapkan hasil dari penelitian ini dapat memberikan kontribusi penting dalam upaya pencegahan dan pengendalian kebakaran hutan di Lebanon.	Lebanon pada tahun 2015. Hasil pengujian menunjukkan bahwa model HDT-NN menghasilkan akurasi prediksi yang lebih baik daripada model Decision Tree (DT) atau Neural Network (NN) yang digunakan secara terpisah. Selain itu, teknik hybrid juga mampu mengurangi waktu pelatihan dan mempercepat waktu prediksi, sehingga dapat membantu dalam mengambil keputusan pencegahan dan pengendalian kebakaran	prediksi. Faktor-faktor ini dapat berkontribusi pada risiko kebakaran hutan dan perlu dipertimbangkan dalam pengembangan model prediksi. 3. Penggunaan algoritma machine learning lainnya dapat memberikan hasil yang lebih baik dalam prediksi risiko kebakaran hutan. Pada penelitian ini, digunakan algoritma Hybrid Decision Tree-Neural Network (HDT-NN), namun teknik machine learning lainnya	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				hutan secara cepat dan tepat. Oleh karena itu, pendekatan baru yang diusulkan dapat dijadikan sebagai alternatif yang efektif dalam memprediksi risiko kebakaran hutan di Lebanon dan negara-negara lain.	seperti Support Vector Machines (SVM) atau Random Forest (RF) juga dapat dicoba untuk membandingkan hasil prediksi. 4. Validasi model prediksi menggunakan data independen dari lokasi yang berbeda dapat membantu menguji kehandalan dan generalisasi model. Pada penelitian ini, hanya dilakukan validasi internal menggunakan data dari tahun yang sama dan lokasi yang sama dengan	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					data pelatihan. 5. Penggunaan teknologi sensor dan sistem pengawasan yang canggih untuk memantau kondisi lingkungan dapat meningkatkan kualitas data input dan akurasi prediksi. Teknologi sensor dan sistem pengawasan dapat membantu mengukur dan memperbarui kondisi lingkungan secara real-time, sehingga dapat memberikan data yang lebih akurat dan tepat waktu untuk model	

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Publikasi, dan Tahun	Media	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						prediksi.	



2.3. Landasan Teori

Untuk menghindari kesalahan penafsiran dalam mengartikan istilah-istilah yang digunakan untuk menata konsep di dalam penelitian ini, maka istilah-istilah yang terdapat dalam penelitian ini akan dijelaskan sebagai berikut:

2.3.1 Kebakaran Hutan

Kebakaran hutan dan lahan adalah suatu peristiwa kebakaran yang dilakukan oleh perbuatan manusia maupun alami, yang ditandai oleh penjararan api serta membakar hutan dan lahan yang dilaluinya (Elshewey, 2020).

Kebakaran hutan dan lahan adalah suatu peristiwa kebakaran, baik alami maupun oleh perbuatan manusia, yang ditandai dengan penjararan api dengan bebas serta mengkonsumsi bahan bakar yang dilaluinya. Bahan bakar dalam kebakaran hutan adalah semua bahan organik, baik hidup maupun mati yang terdapat didalam tanah (misalnya gambut) dan atau dipermukaan tanah atau diatas tanah (tajak), yang bersumber dari hutan atau lahan (Vatresia et al., 2022).

Penelitian kebakaran hutan dilakukan oleh Mulyana (2019) yang membahas tentang bencana kabut asap akibat kebakaran hutan dan lahan serta pengaruh terhadap kualitas udara dan menghasilkan Jumlah titik api kebakaran hutan di Provinsi Riau selama bulan Februari - Maret pada tahun 2014 mencapai 2543 titik api dengan perincian 1319 titik api yang terjadi pada bulan Februari dan 1224 titik api yang terjadi pada bulan Maret. Penelitian selanjutnya dilakukan oleh Setiawan (2018) yang membahas tentang kebijakan penanganan kebakaran hutan dan lahan di Indonesia yang menghasilkan upaya pemerintah dalam pemberdayaan masyarakat dalam pengguna lahan agar tidak membakar hutan sembarangan dan menemukan cara baru agar tidak merusak lingkungan.

Telah dilakukan penelitian di bidang Informatika sebelumnya oleh Reza Noviansyah (2018) yang menggunakan metode klasifikasi tentang penerapan Data Mining menggunakan metode K-Nearest Neighbor untuk klasifikasi indeks cuaca kebakaran berdasarkan data Automatic Weather Station yang menghasilkan klasifikasi tingkat bahaya kebakaran hutan dengan atribut data berupa suhu,

kelembaban, curah hujan dan kecepatan angin, menghasilkan akurasi persentase keberhasilan 80,16% dengan nilai $K=5$.

Namun algoritma K-Nearest Neighbor ini mempunyai kelemahan seperti menentukan nilai K optimal, tidak menangani missing value secara implisit, sensitif terhadap data outlier dan nilai komputasi yang tinggi (Yankovich et al., 2019).

Penelitian lainnya dilakukan oleh (Yu et al., 2011) menggunakan Decision Tree dan Bayesian Network. Algoritma ini memiliki kelebihan dalam menjelaskan hubungan setiap atribut data cuaca yang mempengaruhi tingkat hotspot menggunakan Decision Tree dan Bayesian Network memiliki nilai akurasi yang baik dan tingkat kesalahan yang rendah. Namun, algoritma Decision Tree memiliki kelemahan seperti terjadi tumpang tindih jika kelas dan kriteria yang digunakan sangat banyak, ini menyebabkan waktu keputusan sangat lama dan membutuhkan banyak memori (Liang et al., 2019). Walaupun Bayesian Network memiliki kelebihan dan banyak digunakan oleh para peneliti, Bayesian Network juga memiliki kelemahan yaitu sulit untuk mencapai kesepakatan beberapa pakar dalam membangun struktur Bayesian Network, pakar juga akan memerlukan waktu yang lama hanya untuk membangun struktur Bayesian Network dan Pakar akan sulit menentukan conditional probability berdasarkan pendapat pakar (Wang et al., 2021).

Penelitian yang dilakukan oleh (Yang et al., 2021) yang membahas tentang perbandingan algoritma akan dilihat berdasarkan nilai correctly classified instance, incorrectly classified, kappa statistic, true positive, false positive, dan confusion matrix. Dalam penelitian ini, algoritma yang dibandingkan adalah algoritma SVM, Decision Tree, dan Naive Bayes. Dapat disimpulkan algoritma yang memiliki kinerja yang lebih unggul adalah Decision Tree.

Berdasarkan tinjauan pustaka, telah dilakukan penelitian terhadap analisis perbandingan algoritma SVM, Naive Bayes, dan Decision Tree dalam klasifikasi (Bandyopadhyay, 2011). Decision Tree menjadi algoritma terbaik tetapi tidak dapat maksimal dalam waktu komputasi (running time), untuk membangun

sebuah model algoritma yang tercepat dari ketiga algoritma tersebut adalah Naïve Bayes (Zheng et al., 2022).

2.3.2 Faktor Penyebab Kebakaran Lahan

Adapun beberapa faktor yang dapat menyebabkan kebakaran hutan antara lain (Abid et al., 2021):

1. Suhu Udara. Suhu udara tergantung pada intensitas panas atau penyinaran matahari. Daerah dengan suhu tinggi akan menyebabkan cepat terjadinya pengeringan dan memudahkan terjadinya kebakaran terutama pada musim kemarau (Abid et al., 2021).
2. Kelembapan udara. Dalam hutan kelembapan udara akan sangat mempengaruhi mudah tidaknya bahan bakar mengering dan terbakar, hal ini dikarenakan kelembapan dapat menentukan jumlah kandungan air didalam bahan bakar (Brun Sorribas, 2014).
3. Curah Hujan. Curah hujan mempengaruhi kelembapan dan kadar air bahan bakar. Bila kadar air bahan bakar tinggi akibat curah hujan tinggi maka sulit untuk terjadi kebakaran. Namun sebaliknya bila curah hujan rendah disertai suhu tinggi dan kemarau panjang menyebabkan kebakaran lebih mudah berlangsung (Abid et al., 2021).
4. Angin. Angin merupakan salah satu faktor penting dari komponen-komponen cuaca yang mempengaruhi kebakaran. Angin mempengaruhi kebakaran melalui beberapa cara diantaranya angin membantu pengeringan bahan bakar yaitu sebagai pembawa air yang sudah diuapkan. Angin juga menentukan arah penjaralan api. Penjaralan api dapat berlangsung dengan adanya perbedaan tekanan udara akibat perbedaan pemanasan (Abid et al., 2021).

2.3.3 Fire Weather Indeks (FWI)

Sistem FWI (Fire Weather Index) dirancang untuk menghasilkan jumlah informasi yang maksimum dengan jumlah data harian atau antar jam yang minimum. FWI (Fire Weather Index) juga memiliki rancangan dimana

komponen-komponennya dapat digunakan baik secara individu maupun dikombinasikan untuk keluaran sistem.

Sistem FWI (Fire Weather Index) terdiri dari enam komponen yaitu tiga komponen berupa kode kelembaban bahan bakar FFMC (Fine Fuel Moisture Code), DMC (Drought Moisture Code) dan DC (Drought Code), dan tiga lainnya berupa indeks perilaku kebakaran yang menggambarkan laju penyebaran, konsumsi bahan bakar dan intensitas kebakaran. Tiap-tiap komponen memiliki tingkatan nilai dengan skala masing-masing seperti ditampilkan pada Tabel 2.2 dan Tabel 2.3 (Trivedi et al., 2015).

Pengertian lain, FWI (Fire Weather Index) merupakan peringkat numerik dari intensitas kebakaran. Indeks ini secara umum dapat disebut sebagai indeks bahaya kebakaran ditinjau dari segi cuaca. Bahaya kebakaran adalah indikasi umum dari semua faktor yang mempengaruhi kemudahan terbakar, penyebaran api, dampak fisik kebakaran dan tingkat kesulitan pengendalian kebakaran. Kode ini digunakan sebagai indikator prakiraan kesulitan pengendalian kebakaran. Berikut ini adalah tabel klasifikasi bahaya kebakaran hutan dan lahan dari indeks cuaca kebakaran atau FWI yang digunakan oleh BMKG. Tingkatan FWI dapat dilihat pada Tabel 2.4.

Tabel 2.2 Klasifikasi Tingkat Bahaya FFMC

Kelas	FFMC	Warna
Rendah	0-36	Biru
Sedang	36-69	Hijau
Tinggi	69-83	Kuning
Ekstrim	>83	Merah

Tabel 2.3. Klasifikasi Tingkat Bahaya DC

Kelas	DC	Warna
Rendah	0-200	Biru
Sedang	200-300	Hijau
Tinggi	300-400	Kuning
Ekstrim	>400	Merah

Tabel 2.4. Klasifikasi Tingkat Bahaya FWI

Kelas	FWI	Warna
Rendah	0-1	Biru
Sedang	1-6	Hijau
Tinggi	6-13	Kuning
Ekstrem	>13	Merah

2.3.4 Titik Panas

Titik panas dapat digunakan untuk mengidentifikasi adanya kebakaran. Titik panas adalah indikator kebakaran hutan yang mendeteksi suatu lokasi yang memiliki suhu relatif lebih tinggi dibandingkan dengan suhu disekitarnya (de Domingo et al., 2021). Menurut Kementerian Lingkungan Hidup dan Kehutanan (Dharshinni et al., 2019), jumlah titik panas tahun lalu hingga September tercatat ada sekitar 4.079 titik panas, sehingga total titik panas tahun 2019 sekitar 7.354 titik panas dan terjadi peningkatan sekitar 3.279 titik panas.

Sedangkan di Provinsi Kalimantan Timur terdapat jumlah titik panas yaitu sekitar 138 titik api (Nebot & Mugica, 2021). Suhu titik panas dapat dihasilkan berdasarkan nilai suhu kecerahan (brightness temperature) yang ditangkap oleh sensor pada satelit. Satelit akan mengidentifikasi piksel sebagai titik panas apabila piksel memiliki suhu diatas ambang batas. Ambang batas suhu yang diidentifikasi sebagai titik panas yaitu apabila mencapai $>330^{\circ}\text{K}$. Brightness temperature adalah ukuran deskriptif dari pancaran radiasi dalam bentuk suhu yang dipancarkan ke atas pada bagian atmosfer bumi. Brightness temperature merupakan fitur dasar pada citra penginderaan jarak jauh yang di deteksi dari lokasi tertentu dan diukur dalam satuan ukur kelvin.

2.3.5 Data Mining

Data Mining adalah sebuah istilah yang digunakan untuk menggali pengetahuan dalam big data. Data Mining adalah proses ekstraksi suatu data bersifat implisit dan tidak berguna menjadi informasi dari data yang jumlahnya besar. Data Mining berguna untuk mengidentifikasi informasi yang bermanfaat

dengan menggunakan teknik statistik, matematika, kecerdasan buatan, dan machine learning dalam sebuah dataset besar. Definisi lain mengatakan Data Mining adalah kegiatan yang meliputi pengumpulan, pemakaian data historis untuk menemukan pola dari suatu data yang berukuran besar. Tipe data yang digunakan dalam Data Mining dibedakan menjadi tiga yaitu tipe data numerik, tipe data kategorikal dan tipe data rentang waktu.

Secara sederhana, data mining mengarah pada ekstraksi dan “pertambangan” pengetahuan dari sejumlah besar data. [J Han, M. Kamber and J. Pei]. Menurut Gartner Group data mining adalah suatu proses menemukan hubungan yang berarti, pola, dan kecenderungan dengan memeriksa dalam sekumpulan besar data yang tersimpan dalam penyimpanan dengan menggunakan teknik pengenalan pola seperti teknik statistik dan matematika.

Terdapat pengertian lain tentang Data Mining yaitu, Data mining merupakan proses menemukan pola menarik dan pengetahuan dari sejumlah besar data. Sumber data bisa berupa database, warehouse, web, repositori dan informasi lainnya, atau data yang dialirkan ke sistem secara dinamis.

Menurut buku Data Mining: Algoritma dan Implementasi dengan Pemrograman PHP (Suntoro, J., 2019) secara umum Data Mining terdapat lima peranan berdasarkan tugasnya yaitu sebagai berikut:

- a. Estimasi. Estimasi adalah proses memperkirakan nilai yang belum diketahui secara pasti.
- b. Prediksi. Prediksi adalah proses memprediksi nilai terhadap suatu variabel yang berlandaskan nilai dari suatu variabel lainnya.
- c. Klasifikasi. Klasifikasi adalah proses untuk menemukan model yang menjelaskan atau membedakan tentang konsep atau kelas datanya, dengan tujuan untuk dapat memperkirakan kelas mana yang labelnya tidak diketahui.
- d. Clustering. Clustering adalah proses meminimumkan jarak yang ada di dalam cluster dan jarak antar sesama cluster dimaksimumkan.
- e. Asosiasi. Association merupakan proses menemukan hubungan atau kaitan antara berbagai kombinasi item dari atribut tertentu.

Tahapan dari Data Mining ada 5 yaitu sebagai berikut:

- a. Data Selection. Seleksi data merupakan suatu proses dari Data Mining sebelum menggali informasi-informasi dalam Data Mining. Seleksi data dilakukan dengan memilih himpunan data, sampel data, dan menciptakan himpunan data target.
- b. Pre-processing. Pre-processing adalah proses membersihkan data yang bersifat mengganggu, duplikat, data yang inkonsisten dan typografi dalam proses Data Mining.
- c. Transformation. Transformation adalah proses melakukan perubahan data menjadi bentuk yang layak untuk proses mining.
- d. Data Mining. Data Mining adalah sebuah istilah yang digunakan untuk menggali pengetahuan dalam big data. Data Mining berguna untuk mengidentifikasi informasi yang bermanfaat dengan menggunakan teknik statistik, matematika, kecerdasan buatan, dan machine learning dalam sebuah dataset besar.
- e. Interpretation atau Evaluation. Interpretation atau evaluation merupakan pola dari informasi proses Data Mining yang bisa di mengerti dan mudah di pahami bagi pengguna, meliputi pemeriksaan pola atau informasi yang ditemukan.

2.3.6 Klasifikasi

Pada Data Mining terdapat beragam metode dalam melakukan klasifikasi, Klasifikasi merupakan suatu kegiatan untuk menemukan suatu model atau fungsi yang dapat membedakan konsep atau kelas data untuk kepentingan tertentu. Klasifikasi adalah proses untuk menemukan model yang menjelaskan atau membedakan tentang konsep atau kelas datanya, dengan tujuan untuk dapat memperkirakan kelas mana yang labelnya tidak diketahui. Tujuan dari algoritma klasifikasi adalah untuk memprediksi kelas baru dari dataset yang mempunyai kelas.

Metode klasifikasi yang terdapat pada Data Mining antara lain:

- a. Neural Network. Neural Network (Jaringan Syaraf Tiruan) adalah prosesor tersebar paralel yang sangat besar dan memiliki kecenderungan untuk menyimpan pengetahuan yang bersifat pengalaman dan membuatnya siap untuk digunakan.
- b. Decision Tree. Decision Tree sendiri merupakan metode klasifikasi dan prediksi yang sangat kuat dan banyak di minati.
- c. Naïve Bayes. Algoritma Naïve Bayes adalah salah satu algoritma klasifikasi berdasarkan teorema Bayesian pada statistika untuk memprediksi probabilitas suatu kelas.
- d. K-Nearest Neighbor. Algoritma K-Nearest Neighbor adalah sebuah metode untuk melakukan klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut, ketepatan algoritma K-NN ini sangat dipengaruhi oleh ada atau tidaknya fitur-fitur yang tidak relevan, atau jika bobot fitur tersebut tidak setara dengan relevansi nya terhadap klasifikasi.

Algoritma K-Nearest Neighbor merupakan algoritma yang sering digunakan untuk klasifikasi, meskipun dapat digunakan juga untuk estimasi dan prediksi, K-Nearest Neighbor adalah contoh dari basis pembelajaran dimana data training disimpan sehingga klasifikasi untuk data yang belum terklasifikasi dapat ditemukan dengan cara membandingkannya pada catatan data training. Pengertian lain tentang KNN, K-Nearest Neighbor adalah algoritma untuk menemukan kelompok K dalam data training yang paling dekat dengan data uji dan melakukan pencarian label pada kelas tertentu dalam lingkup data. Ada beberapa perhitungan pada metode KNN, perhitungan yang paling umum digunakan adalah perhitungan berdasarkan jarak terdekat. Fungsi dalam menentukan jarak yang paling umum digunakan adalah euclidean distance, dimana penggunaannya seperti cara manusia berpikir tentang jarak dalam dunia nyata contoh rumus euclidean distance.

$$dEuclidean(x, y) = \sqrt{\sum (x_i - y_i)^2} \quad (2)$$

7. Metode Evaluasi dan Validasi

Metode evaluasi dan validasi yang akan digunakan adalah metode Cross Validation. Cross validation merupakan pengujian standar yang dilakukan untuk memprediksi error. Data training dibagi secara acak ke dalam beberapa bagian dengan perbandingan yang sama kemudian error dihitung bagian demi bagian, selanjutnya hitung rata-rata seluruh error untuk mendapatkan error rate secara keseluruhan.

Untuk menghitung akurasi aplikasi akan digunakan persamaan (2) [9]:

$$\text{Akurasi} = \frac{\text{Jumlah Klasifikasi Benar}}{\text{Jumlah Keseluruhan Data Uji}} \times 100\% \quad (3)$$

BAB III METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian yang digunakan oleh peneliti merupakan penelitian kuantitatif, dimana peneliti melakukan perhitungan matematis untuk menemukan hasil yang diinginkan.

Sifat dari penelitian yang akan dilakukan adalah eksperimental dimana peneliti melakukan sebuah eksperimen guna mendeteksi performa penerapan (a) algoritma K-NN dan (b) mengukur clustering terbaik dengan *Davis Bouldin Indeks* (DB Indeks), (c) menghitung faktor hubungan manusia (pendapatan per kapita, Jumlah penduduk, jarak perumahan dengan lokasi kejadian kebakaran hutan, Jarak lokasi kejadian kebakaran hutan dengan jalan, dan Kejadian Kebakaran Hutan), (d) Faktor Lingkungan (NDVI, Jenis Vegetasi, Kelembapan Udara, Penggunaan Lahan, Temperatur, Elevasi, dan Kelerengan. Pendekatan kuantitatif digunakan oleh peneliti dimana penelitian akan melakukan penelitian sesuai alur yang telah peneliti buat.

3.2. Metode Pengumpulan Data

3.2.1 Perolehan Data

Penelitian ini dilakukan dengan menggunakan Dataset yang diambil (scrapping)/ Data Mining dari web pemerintah Indonesia penyedia data iklim dan titik api (hot spot), yaitu :

- a. Data Perkiraan cuaca :
 - i. KEMENLHK melalui <http://sipongi.menlhk.go.id/api/perkiraan-cuaca>
 - ii. BMKG melalui link berikut
<https://data.bmkg.go.id/DataMKG/MEWS/DigitalForecast/DigitalForecast-Indonesia.xml>
- b. Kualitas Udara :
 - i. KEMENLHK melalui <http://sipongi.menlhk.go.id/api/aqms>

c. Data Titik Api:

i. LAPAN melalui link berikut ini:

[http://103.51.131.166/getHS?S\\$hashKey=object:34&class=hotspot&conf_lvl=low&enddate=&id=0&loc=%7B%22st%22:%22Indonesia%22,%22disp%22:%22Indonesia%22%7D&mode=cluster&name=Hotspot&startdate=&time=last24h&visibility=true](http://103.51.131.166/getHS?S$hashKey=object:34&class=hotspot&conf_lvl=low&enddate=&id=0&loc=%7B%22st%22:%22Indonesia%22,%22disp%22:%22Indonesia%22%7D&mode=cluster&name=Hotspot&startdate=&time=last24h&visibility=true)

ii. Detail titik api berdasarkan “hot spot id” pada link:

[http://103.51.131.166/getHSdetail?hsid=\\${id}&mode=cluster](http://103.51.131.166/getHSdetail?hsid=${id}&mode=cluster) NOTE: [\\$id](#) merupakan “hot spot id”

iii. VIIRS:

<https://www.arcgis.com/home/item.html?id=dece90af1a0242dchf0ca36d30276a83>

d. Parsing masing-masing data hasil scraping/crawling

i. Kemen-LHK:

1. Prakiraan cuaca MENLHK berbentuk GeoJSON
2. Kualitas udara berbentuk GeoJSON

ii. BMKG, Prakiraan cuaca BMKG data berbentuk xml

iii. LAPAN

1. Titik Api berbentuk GeoJSON
2. Standart JSON titik api berdasarkan “hot spot id”

e. Menyimpan data hasil crawling/scraping ke dalam features services (FS)

f. Proses pengambilan, parsing data dan penyimpanan data ke dalam database menggunakan micro service

i. Kemen-LHK

1. PRAKIRAAN CUACA MENLHK (lihat dokumentasi “worker-prakiraan-cuaca-menlhk”)
2. KUALITAS UDARA (lihat dokumentasi “worker-kualitas-udara-menlhk”)

ii. BMKG, Prakiraan cuaca BMKG (lihat dokumentasi “worker-bmkg”)

iii. LAPAN

1. Titik Api Geo JSON (lihat dokumentasi “worker-lapan-titik-api”)
2. Outpu data dalam bentuk standart JSON

g. Citra Satelit

Data yang digunakan dalam penelitian ini adalah data Citra Satelit Sentinel-2 untuk daerah di Taman Nasional Sebangau Kalimantan Tengah pada koordinat $113^{\circ} 32' 46,592''$ E $1^{\circ} 49' 33,294''$ S $114^{\circ} 7' 36,710''$ E $1^{\circ} 49' 37,577''$ S. Sentinel-2 merupakan satelit yang diluncurkan oleh kerjasama antara *The European Commision* dan *European Space Agency* di dalam program *Global Monitoring for Environment and Security* (GMES). Satelit ini diluncurkan untuk memantau kondisi permukaan bumi, sehingga mampu memberikan informasi kondisi terkini bumi dari angkasa untuk aplikasi lingkungan dan keamanan.

Citra Satelit Sentinel 2 memiliki 13 Band / Kanal. Tiga belas kanal yang dipasang pada satelit Sentinel-2 memiliki karakteristik tersendiri (Tabel 10.1). Empat kanal dengan resolusi spasial 10 m memastikan kesesuaian dengan SPOT 4/5 dan memenuhi persyaratan pengguna untuk klasifikasi tutupan lahan. Resolusi spasial 20 m yang dimiliki oleh 6 kanal menjadi persyaratan untuk parameter pengolahan level 2 lainnya. Kanal dengan resolusi spasial 60 m dikhususkan untuk koreksi atmosfer dan penyaringan awan (443 nm untuk aerosol, 940 nm untuk uap air, dan 1375 nm untuk deteksi awan tipis). Resolusi sebesar 60 m dianggap cukup untuk menangkap variabilitas spasial parameter geofisika atmosfer (Drusch et al., 2012). Penjelasan secara detail mengenai Citra Satelit Sentinel 2 dijelaskan pada Tabel 3.1.

Tabel 3.1 Karakteristik spektrum panjang gelombang dan resolusi spasial masing-masing saluran Sentinel-2, Sumber : ESA, 2015.

Kanal	Spektrum	Panjang Gelombang	Resolusi Spasial (m)
1	Coastal Aerosol	0.433 – 0.453	60
2	Blue	0.458 – 0.523	10
3	Green	0.543 – 0.578	10
4	Red	0.650 – 0.680	10
5	Vegetation Red Edge1	0.698 – 0.713	20
6	Vegetation Red Edge2	0.733 – 0.748	20
7	Vegetation Red Edge3	0.765 – 0.785	20
8	NIR	0.785 – 0.900	10
8a	Vegetation Red Edge4	0.855 – 0.875	20
9	Water Vapour	0.855 – 0.875	60
10	SWIR-Cirrus	1.365 – 1.385	60
11	SWIR1	1.565 – 1.655	20
12	SWIR2	2.100 – 2.280	20


Referensi: esa, Sentinel-2 User Handbook, no. 1. 2015

Citra Sentinel-2 dapat diperoleh melalui United States Geological Survey (USGS) Earth Explorer web (<http://earthexplorer.usgs.gov>), Sentinels Scientific Data Hub (<https://scihub.copernicus.eu/>), atau Earth Observing System (<https://lv.eosda.com/>). Dimana pada penelitian ini data didapatkan dari alamat web yang pertama yaitu Earth Explorer web, dengan mengunduh data dengan parameter pada Tabel 3.2 berikut ini.


Tabel 3.2. Parameter Yang Digunakan Untuk Mengunduh Data

No	Parameter	Kriteria
1	Area Data	Atas kiri 113 32 46,592 E 1 49 33,294 S Atas kanan 114 7 36,710 E 1 49 37,577 S Bawah kiri 113 32 42,168 E 2 25 31,958 S Bawah kanan 114 7 32,287 E 2 25 36,241 S
2	Tanggal	1 Januari 2018 - 31 Agustus 2022
3	Tutupan Awan	Kurang dari 10%
4	Level Data	1C dengan sistem koordinat geografis WGS 84

Sedangkan untuk gambaran lokasi penelitian, secara geografis di tampilkan pada Gambar 3.1, dan tampilan administrasi pada Gambar 3.2.



Gambar 3.1 Lokasi Penelitian



Gambar 3.2 Batas Administratif dan Jaringan Jalan Lokasi Penelitian

Data historis kebakaran hutan bersumber <https://dibi.bnpb.go.id/>, merupakan website BNPB yang berisi Data Informasi Bencana Indonesia (DIBI) yaitu Banjir, Tanah Longsor, Banjir dan Tanah Longsor, Abrasi,

Puting Beliung, Kekeringan, Kebakaran Hutan dan Lahan, Gempa Bumi, Tsunami, Gempa Bumi dan Tsunami, Letusan Gunung Berapi, Lainnya. Pada penelitian ini, difokuskan pada pengambilan data Kebakaran Hutan dan Lahan.

Data dari website bnpb di ambil berdasarkan jenis bencana alam dengan kategori kebakaran hutan kurun waktu tahun 2018-2022. Adapun dari data yang diperoleh memiliki struktur Tabel 3.3 sebagai berikut.

Tabel 3.3. Struktur Tabel Data Kejadian Bencana Kebakaran Hutan

No	Nama	Deskripsi
1	Identitas	id record laporan
2	Kejadian	Jenis kejadian bencana
3	Latitude	Koordinat Latitude
4	Longitude	Koordinat Longitude
5	Tanggal	Tanggal kejadian bencana
6	Sumber	Sumber laporan kejadian bencana
7	Bencana	Jenis kejadian bencana berdasarkan kategori
8	Provinsi	Provinsi administratif kejadian bencana
9	Kab/Kota	Kabupaten administratif kejadian bencana
10	Keterangan	Laporan jumlah personel dan peralatan dalam penanganan kejadian bencana
11	Kerusakan	Kerusakan akibat kejadian bencana
12	Ha	Luas lahan akibat kejadian bencana

3.2.2 Pemrosesan Data

Adapun data yang berhasil diunduh dari website di atas, dilakukan parsing menjadi data yang terstruktur dalam bentuk CSV dan disimpan kedalam database.

Struktur data dapat dilihat pada penjelasan Tabel 3.4 untuk Data Perkiraan Cuaca, Tabel 3.5 untuk Kualitas Udara dan Table 3.6 untuk Data Titik Api di bawah ini :

a. Data Perkiraan cuaca :

Tabel 3.4 Data Perkiraan Cuaca sumber KLHK dan BMKG

Sumber Data	KLHK	BMKG
1	Tanggal - Waktu	Tanggal / Waktu
2	Kejadian	Temperature
3	Provinsi	Kelembaban
4	Kabupaten	Kecepatan Angin
5	Kecamatan	Arah Angin
6		Provinsi
7		Kabupaten
8		Posisi Stasiun Cuaca

b. Kualitas Udara :

Tabel 3.5 Data Kualitas Udara

Sumber Data	Kualitas Udara
1	Tanggal / Waktu
2	Provinsi
3	Kota
4	Nilai Kualitas udara
5	Kategori Kualitas Udara
6	Lokasi Stasiun Pengukuran

c. Data Titik Api :

Tabel 3.6 Data Titik Api (Hot Spot)

Sumber Data	Data Titik Api
1	Tanggal/Waktu
2	Provinsi
3	Kabupaten
4	Kecamatan
5	Tingkat Kepercayaan
6	Lokasi Titik Api

3.3. Metode Analisis Data

Dalam penelitian ini dilakukan beberapa tahapan analisis data sebagai berikut:

3.3.1 Pembelajaran Tanpa Pengawasan (Unsupervised learning)

Dalam pembelajaran tanpa pengawasan, tidak ada dukungan pengguna untuk pembelajaran komputer. Perangkat dapat mengenali pola dalam data yang tidak terlalu jelas bagi otak manusia. Pembelajaran tanpa pengawasan adalah alat penting untuk mengenali pola dalam data dan membantu membuat keputusan. Deteksi aturan pengelompokan dan asosiasi adalah dua jenis pembelajaran tanpa pengawasan.

3.3.2 Clustering

Clustering merupakan salah satu metode dalam data mining yaitu teknik pengelompokan data, mengamati atau memperhatikan dan membentuk kelas-kelas objek yang sejenis. Clustering tidak memiliki target output. Dalam metode ini tidak dapat ditentukan hasil keluaran selama proses pembelajaran. Selama proses pembelajaran, bobot nilai diatur dalam kisaran tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dalam suatu wilayah tertentu. Pengelompokan berbeda dengan klasifikasi jika tidak ada variabel sasaran untuk pengelompokan. Clustering tidak mengklasifikasikan, memprediksi atau memprediksi nilai variabel target dan

digunakan ketika kita tidak tahu bagaimana data harus dikelompokkan, karena tidak ada label kelas maka clustering sering juga disebut unsupervised learning

Click or tap here to enter text.

3.3.3 K-Means

Analisis kluster bertujuan untuk mengklasifikasikan objek data ke dalam dua kategori: objek yang memiliki kesamaan karakteristik dalam satu cluster dan objek yang berbeda karakteristiknya dengan objek lain dari cluster lain. K-Means merupakan metode yang termasuk dalam algoritma klusterisasi berbasis jarak yang dimulai dengan menentukan jumlah kluster yang diinginkan. Tujuan dari clustering pada makalah ini adalah untuk mengklasifikasikan Hot Spot yang memiliki kesamaan karakteristik pada cuaca, suhu, kelembaban, kecepatan angin dan arah angin. Langkah-langkah clustering pada K-means adalah:

- Pilih k (acak) titik data (poin) untuk menjadi centroid awal, pusat cluster
- Tetapkan setiap titik data ke centroid terdekat
- Hitung ulang centroid menggunakan keanggotaan cluster saat ini
- Jika kriteria konvergensi tidak terpenuhi, ulangi langkah 2 dan 3

Pengelompokan objek berdasarkan jumlah titik panas, cuaca, suhu, kelembaban, kecepatan angin dan arah angin dengan mempertimbangkan jarak minimum antar objek.

3.3.4 Jarak Euclidean

Dari beberapa penelitian untuk clustering, pengukuran jarak yang umumnya sering digunakan adalah jarak Euclidean. Jarak Euclidean dianggap sebagai matriks jarak yang mengadopsi prinsip Pythagoras. Hal ini disebabkan pola perhitungan yang menggunakan aturan pangkat dan akar kuadrat. Euclidean akan memberikan hasil jarak yang relatif kecil karena menggunakan aturan akar kuadrat. Jarak antara nilai/bobot acak dan data dihitung menggunakan persamaan rumus:

$$D_i = \sum_{l=1}^n (w_{ij} - x_l) \quad (4)$$

Dimana

D_i : Jarak Euclidean

W_{ij} : Berat neuron n-i (berat akhir)


X_i : Masukan vektor

3.3.5 Davies Bouldin Index (DB-Index)

Davis Bouldin Index (DBI) yang diperkenalkan oleh David L. Davies dan Donald W. Bouldin pada tahun 1979 merupakan metrik untuk mengevaluasi hasil dari algoritma clustering. Pengukuran evaluasi algoritma clustering adalah salah satu cara untuk mengukur seberapa baik kinerja algoritma clustering. Kriteria split adalah ukuran yang umum digunakan untuk mengevaluasi kebaikan split dengan algoritma clustering K-Means. DBI adalah ukuran seberapa mirip setiap cluster dengan cluster yang paling mirip dengannya. Semakin rendah rata-rata kesamaan, semakin baik cluster yang dipisahkan dan semakin baik hasil clustering.

3.4. Alur Penelitian

Tahapan penelitian yang dilalui dalam penelitian ini dimulai dari data mining, pembuatan model data mining, pembuatan database, pembuatan sistem UI / UX Aplikasi, pembuatan pemodelan prediksi, implementasi model prediksi pada aplikasi yang dibuat. Untuk lebih jelasnya dapat dilihat pada diagram alur Gambar 3.2 dan Gambar 3.4 berikut ini.



Gambar 3.4 Diagram Alur Penelitian

Berikut penjelasan pada alur penelitian pada Gambar 2.1 dan Gambar 2.2, dijelaskan pada beberapa poin menurut dari alur penelitian tersebut dan terdapat beberapa proses alur penelitian yang dijelaskan lebih detail sebagai berikut :

1. Pendekatan Penelitian (Validasi Penelitian, Studi Literatur, Identifikasi Masalah). Tahap awal penelitian yaitu melakukan validasi penelitian tentang permasalahan serta studi literatur untuk mengetahui masalah yang akan di analisa serta penggunaan algoritma yang tepat berdasarkan studi literatur sehingga dalam pemilihan algoritma tersebut didasarkan pada hasil ilmu yang dianalisa oleh penelitian sebelumnya.
2. Pengumpulan Data. Data yang digunakan dalam penelitian ini berasal dari 5 website yaitu BMKG, KLHK, BNPB, LAPAN dan Citra Satelit seperti tampil pada Gambar 3.5. Data dari BMKG, KLHK, BNPB, LAPAN diperoleh data prakiraan cuaca, kualitas udara dan titik api. Dari BNPB, diperoleh data kejadian kebakaran hutan dan dilakukan pemilihan data berdasarkan pada lokasi penelitian dan melakukan cross check dengan citra satelit. Citra satelit yang digunakan yaitu data Citra Sentinel-2 tahun 2021 yang diunduh Earth Explorer web, dari citra satelit diperoleh data jalan dan pemukiman dipilih berdasarkan pada kenampakan visual dari mulai kenampakan jalan dan bangunan yang sangat jelas, hingga kenampakan jalan dan bangunan yang tidak begitu jelas tapi masih bisa dikenali dengan mata.



Gambar 3.5 Diagram *flow chart* proses data mining menjadi data base baru

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Teknik Data Mining, Scheduler Script Export Data dan Joining Data Tabular ke Data Spasial

Data mining adalah proses mengekstrak informasi yang bermanfaat dan tersembunyi dari kumpulan data besar. Sedangkan prediksi kebakaran hutan adalah proses memprediksi kemungkinan terjadinya kebakaran hutan di masa depan dengan menggunakan data historis dan faktor-faktor lainnya.

Dalam konteks ini, data mining dapat digunakan untuk mengidentifikasi pola-pola dalam data kebakaran hutan, seperti faktor-faktor yang menyebabkan kebakaran hutan dan pola kebakaran hutan di masa lalu. Dengan menggunakan teknik data mining seperti klasifikasi, clustering, dan regresi, dapat dilakukan prediksi kebakaran hutan di masa depan.

Penelitian sebelumnya telah menunjukkan efektivitas penggunaan data mining dalam prediksi kebakaran hutan. Misalnya, penelitian yang dilakukan oleh Duan dan Wang (2019) menggunakan teknik data mining seperti decision tree dan artificial neural network untuk memprediksi kemungkinan terjadinya kebakaran hutan di Provinsi Zhejiang, China. Hasil penelitian menunjukkan bahwa model prediksi yang dibangun memiliki akurasi yang cukup baik dalam memprediksi kebakaran hutan.

Penelitian lain yang dilakukan oleh Aguiar et al. (2018) menggunakan data mining untuk menganalisis faktor-faktor yang mempengaruhi terjadinya kebakaran hutan di Amazon Brazil. Hasil penelitian menunjukkan bahwa faktor seperti deforestasi, suhu, dan kelembaban udara mempengaruhi terjadinya kebakaran hutan di wilayah tersebut.

Data mining dilakukan untuk mendapatkan data Perkiraan cuaca, Kualitas Udara dan Data Titik Api (Hot Spot) pada 4 website penyedia data yaitu BMKG, MenLHK dan LAPAN.

"Scraping data" atau "web scraping" adalah proses mengambil atau mengekstrak data dari sebuah situs web secara otomatis menggunakan

program komputer atau skrip. Biasanya, data yang diambil dapat berupa teks, gambar, video, tabel, atau informasi lainnya yang tersedia di dalam halaman web.

Web scraping umumnya dilakukan dengan menggunakan teknologi seperti web crawler atau bot yang akan mengunjungi situs web target, mengidentifikasi dan mengambil data yang diperlukan berdasarkan pola atau aturan tertentu, dan menyimpannya dalam format yang dapat diproses lebih lanjut, seperti file CSV, Excel, atau database. Data yang diambil dari web scraping dapat digunakan untuk berbagai tujuan, seperti analisis data, pemantauan kompetitor, riset pasar, pengumpulan informasi, dan banyak lagi.

Namun, penting untuk diingat bahwa praktik web scraping harus dilakukan secara etis dan sesuai dengan hukum yang berlaku. Sebelum melakukan web scraping, periksa kebijakan privasi dan ketentuan penggunaan situs web yang ingin diambil datanya, dan pastikan untuk mematuhi aturan dan regulasi yang berlaku dalam penggunaan data yang diperoleh melalui web scraping.

Ada banyak perangkat lunak atau library yang dapat digunakan untuk melakukan web scraping, tergantung pada bahasa pemrograman yang digunakan dan kompleksitas tugas scraping yang diinginkan. Beberapa contoh software populer untuk web scraping adalah:

- a. BeautifulSoup: Sebuah library Python yang digunakan untuk mengambil data dari halaman web dan menyajikannya dalam bentuk objek yang mudah dipahami. Biasanya digunakan bersamaan dengan library requests untuk mengirim permintaan HTTP ke halaman web.
- b. Scrapy: Sebuah framework Python untuk web scraping yang menyediakan alat-alat yang kuat untuk mengelola aliran kerja scraping, seperti pengaturan permintaan HTTP, manajemen sesi, pengelolaan cookie, dan penyimpanan data.
- c. Selenium: Sebuah library Python yang digunakan untuk mengotomatisasi interaksi dengan halaman web. Selenium sering digunakan untuk scraping

berbasis tindakan, seperti mengisi formulir, mengklik tombol, atau berinteraksi dengan elemen web yang dinamis.

- d. Octoparse: Sebuah perangkat lunak web scraping berbasis GUI yang menyediakan antarmuka pengguna yang intuitif untuk mengekstrak data dari situs web tanpa perlu menulis kode.
- e. ScrapySharp: Sebuah library C# untuk melakukan web scraping pada platform .NET, yang menyediakan fitur-fitur seperti parsing HTML, manajemen permintaan HTTP, dan manipulasi data web.
- f. Puppeteer: Sebuah library Node.js yang digunakan untuk mengendalikan browser Chrome atau Chromium secara otomatis, sehingga memungkinkan web scraping yang melibatkan JavaScript yang dijalankan di sisi klien.

Namun, penting untuk diingat bahwa penggunaan perangkat lunak atau library untuk web scraping harus dilakukan secara etis dan sesuai dengan hukum yang berlaku, serta mengikuti kebijakan privasi dan ketentuan penggunaan situs web yang dituju. Selalu patuhi aturan dan regulasi yang berlaku dalam penggunaan data yang diperoleh melalui web scraping.

2.2.3 Data Perkiraan Cuaca MENLHK

Data MENLHK diperoleh dengan mengakses link: <http://sipongi.menlhk.go.id/api/perkiraan-cuaca> seperti tampil pada Gambar 4.1 (terakhir di akses pada 07 Maret 2023 pukul 01.00 wib), pada website ini yang di akses berupa **Acees Programming Interface (API)**.

Untuk mendapatkan data pada website tersebut, dibuat script dengan nama "worker-bmkg" yang dapat di lihat pada Lampiran 1. Dengan proses yang dilakukan tersebut diperoleh data dengan variable sebagai berikut:

- a. objectid
- b. category
- c. impacted
- d. event
- e. published
- f. shape


historical maka di buat juga data base dengan nama “prakiraan_cuaca_menlhk_history” seperti yang ditampilkan pada Gambar 4.3 untuk menyimpan data secara berkala/time series.

2.2.4 Data Perkiraan Cuaca BMKG

Data BMKG dapat diakses pada link berikut:

<https://data.bmkg.go.id/DataMKG/MEWS/DigitalForecast/DigitalForecast-Indonesia.xml> dengan tampilan website pada Gambar 4.4. Untuk mendapatkan data pada website tersebut, dibuat script dengan nama “worker-bmkg” yang dapat di lihat pada Lampiran 2. Dengan proses yang dilakukan tersebut diperoleh data dengan variable sebagai berikut:

- a. objectid
- b. provinsi
- c. kabupaten
- d. timerange
- e. weather
- f. t
- g. tmin
- h. tmax
- i. hu
- j. humin
- k. humax
- l. wd
- m. ws
- n. shape



Gambar 4.4 Contoh tampilan website BMKG sumber ke-2 data perkiraan cuaca

 A screenshot of a database table with multiple columns and rows. The columns include various weather-related data points, such as time, location, and forecast details. The data is presented in a standard table format with alternating row colors for readability.

Gambar 4.5 Database Prakiraan Cuaca BMKG

 A screenshot of a database table showing historical weather forecast data. The table has a similar structure to the previous one, with columns for time, location, and forecast details. The data is organized into rows, showing a history of forecasts over time.

Gambar 4.6 Database Prakiraan Cuaca BMKG History

Setelah script pada Lampiran 2 berhasil dijalankan dan mendapatkan data, maka di buat dua (2) data base baru dengan nama “prakiraan_cuaca_bmkg” seperti yang ditampilkan pada Gambar 4.5 dan untuk menyimpan data secara historical maka di buat juga data base dengan nama “prakiraan_cuaca_bmkg_history” seperti yang ditampilkan pada Gambar 4.6 untuk menyimpan data secara berkala/time series.

2.2.5 Data Kualitas Udara MENLHK

MENLHK melalui <http://sipongi.menlhk.go.id/api/agnas> dengan tampilan website pada Gambar 4.7. Untuk mendapatkan data pada website tersebut, dibuat script dengan nama “worker-bmkg” yang dapat di lihat pada Lampiran 3. Dengan proses yang dilakukan tersebut diperoleh data dengan variable sebagai berikut:

- a. objectid
- b. alamat
- c. kota
- d. provinsi
- e. waktu
- f. val
- g. nilai
- h. cat
- i. shape

Setelah script pada Lampiran 3 berhasil dijalankan dan mendapatkan data, maka di buat dua (2) data base baru dengan nama “kualitas_udara_bmkg” seperti yang ditampilkan pada Gambar 4.8 dan untuk menyimpan data secara historical maka di buat juga data base dengan nama “kualitas_udara_bmkg_history” seperti yang ditampilkan pada Gambar 4.9 untuk menyimpan data secara berkala/time series.



Gambar 4.7 Contoh tampilan website MenLHK sumber ke-1 data kualitas udara

[illegible]

Gambar 4.8 Database Kualitas Udara MENLHK

[illegible]

2.2.6 Data Titik Api LAPAN

Untuk mendapatkan data dari websiter tersebut, kita perlu mengakses melalui link berikut ini:

https://hotspot.brin.go.id/getHS?SShashKey=object:32&class=hotspot&conf_lv=low&enddate=&id=0&loc=%7B%22stt%22:%22Indonesia%22,%22disp%22:%22Indonesia%22%7D&mode=cluster&name=Hotspot&startdate=&time=last24h&visibility=true dengan tampilan website pada Gambar 4.10 Untuk mendapatkan data pada website tersebut, dibuat script dengan nama “worker-bmkg” yang dapat di lihat pada Lampiran 4. Detail titik api berdasarkan “hot spot id” pada link: [http://103.51.131.166/getHSdetail?hsid=\\${id}&mode=cluster](http://103.51.131.166/getHSdetail?hsid=${id}&mode=cluster) dan sebagai infoemasi `${id}` merupakan “hot spot id”. Dengan proses yang dilakukan tersebut, didapatkan data dengan variable sebagai berikut:

- a. objectid
- b. date
- c. kepercayaan
- d. shape
- e. loc
- f. hsid
- g. satelit
- h. sensor
- i. kanal
- j. rse
- k. conf

Setelah script pada Lampiran 4 berhasil dijalankan dan mendapatkan data, maka di buat dua (2) data base baru dengan nama “titik_api_lapan” seperti yang ditampilkan pada Gambar 4.11 dan untuk menyimpan data secara historical maka di buat juga data base dengan nama “titik_api_lapan_history” seperti yang ditampilkan pada Gambar 4.12 untuk menyimpan data secara berkala/time series.

digunakan untuk mengidentifikasi area yang rentan terhadap kebakaran hutan atau mengklasifikasikan area yang memiliki risiko kebakaran hutan yang tinggi. Selain itu, clusterisasi data juga dapat membantu dalam mengurangi dimensi data yang kompleks menjadi subset data yang lebih kecil dan lebih terfokus, sehingga memudahkan analisis dan prediksi.

Dalam penelitian (Nagari dan Inayati, 2020), para peneliti menggunakan teknik clusterisasi data untuk mengidentifikasi pola-pola dan kelompok-kelompok area yang rentan terhadap kebakaran hutan. Selain itu, penelitian ini juga membandingkan beberapa teknik clusterisasi yang berbeda dan menunjukkan bahwa metode clusterisasi yang dipilih dapat menghasilkan prediksi yang akurat terkait dengan kebakaran hutan.

Parameter yang akan digunakan untuk penelitian ini adalah:

- a. Data historis cuaca
- b. Data historis suhu
- c. Data historis kelembaban
- d. Kecepatan Angin dan arah Angin
- e. Nomor Hot Spot
- f. Tingkat kepercayaan Hot Spot

Alur penelitian dimulai dengan data mining untuk mendapatkan beberapa data yang dibutuhkan untuk prediksi. Langkah selanjutnya adalah melakukan persiapan data dengan menggabungkan data dari berbagai sumber menjadi satu tabel yang akan digunakan untuk model prediksi. Langkah ketiga adalah melakukan clustering untuk mendapatkan kelas yang lebih baik untuk proses klasifikasi pada proses selanjutnya.

4.2.1 Pengambilan data dan pembuatan data base

- a. Parsing masing-masing data hasil scraping/crawling
 - i. Kemen-LHK:
 1. Prakiraan cuaca MENLHK berbentuk GeoJSON
 2. Kualitas udara berbentuk GeoJSON
 - ii. BMKG, Prakiraan cuaca BMKG data berbentuk xml

iii. LAPAN

1. Titik Api berbentuk GeoJSON
2. Standart JSON titik api berdasarkan "hot spot id"

Setelah melakukan proses scraping/crawling pada sumber data yang diinginkan, langkah selanjutnya adalah melakukan parsing data. Pada kasus ini, ada tiga sumber data yang diambil, yaitu Kemen-LHK, BMKG, dan LAPAN.

Untuk data dari Kemen-LHK, terdapat dua jenis data yang diperoleh, yaitu prakiraan cuaca dan kualitas udara, keduanya dalam format GeoJSON. GeoJSON adalah format data yang digunakan untuk merepresentasikan objek geospasial dalam format JSON. Dalam hal ini, data prakiraan cuaca dan kualitas udara dapat diparsing dengan menggunakan library atau tools yang mendukung format GeoJSON.

Sementara itu, data prakiraan cuaca dari BMKG tersedia dalam format XML. Format XML adalah format yang digunakan untuk merepresentasikan data dalam bentuk teks. Oleh karena itu, untuk melakukan parsing data prakiraan cuaca BMKG, dapat menggunakan tools atau library yang mendukung format XML.

Untuk data dari LAPAN, terdapat dua jenis data yang diperoleh, yaitu titik api dan standar JSON titik api berdasarkan "hot spot id", keduanya dalam format GeoJSON. Data titik api dapat diparsing dengan menggunakan tools atau library yang mendukung format GeoJSON.

Parsing data adalah proses mengambil informasi dari suatu teks atau dokumen mentah (raw) dan mengubahnya menjadi format data yang terstruktur dan dapat diproses oleh komputer. Dalam konteks web scraping atau web crawling, parsing data diperlukan untuk mengambil informasi yang diinginkan dari halaman web atau sumber data lainnya, kemudian mengubahnya menjadi format yang dapat digunakan dan dianalisis.

Dalam proses parsing data, data mentah dipecah menjadi potongan-potongan kecil dan kemudian diubah menjadi format yang dapat dipahami oleh mesin. Hal ini dilakukan dengan menggunakan teknologi parsing yang

dapat mengidentifikasi dan mengekstrak informasi yang relevan dari data mentah, seperti informasi teks, gambar, atau informasi lainnya.

Proses parsing data sangat penting dalam analisis data dan pengolahan informasi, karena memungkinkan data mentah yang tidak terstruktur dan sulit diakses, dapat diubah menjadi format yang terstruktur dan dapat dianalisis dengan mudah. Selain itu, parsing data juga memungkinkan informasi yang diambil dari berbagai sumber dapat digabungkan dan diproses secara efektif untuk mendapatkan wawasan yang lebih dalam dan akurat.

Dalam keseluruhan proses parsing data ini, perlu diperhatikan juga format data yang dihasilkan harus dapat dimengerti dan digunakan secara efektif oleh pengguna data. Hal ini membutuhkan pemahaman yang baik tentang sifat data dan tujuan penggunaannya, sehingga pengolahan data dapat dilakukan dengan efektif dan menghasilkan informasi yang relevan dan berguna.

b. Menyimpan data hasil crawling/scraping ke dalam features services (FS)

Setelah melakukan parsing data, langkah selanjutnya adalah menyimpan data hasil crawling/scraping ke dalam feature services (FS). FS adalah layanan web yang menyediakan akses ke data geospasial melalui API. Dalam hal ini, FS digunakan untuk menyimpan dan memanipulasi data geospasial.

Feature Service (FS) adalah salah satu jenis layanan web geospasial yang menyediakan akses dan manajemen data geografis. Fitur yang disediakan oleh layanan ini adalah akses, manipulasi dan analisis data spasial melalui web. Layanan ini memungkinkan pengguna untuk membuat, membaca, mengubah, dan menghapus data spasial dengan menggunakan protokol web standar seperti REST, SOAP, dan OGC WFS. Fitur layanan ini memungkinkan pengguna untuk mengakses data geografis dengan berbagai format, seperti shapefile, KML, dan GeoJSON. Feature Service sering digunakan dalam aplikasi SIG berbasis web dan desktop.

Dalam konteks kasus ini, setelah data berhasil diparsing, data dapat disimpan dalam FS untuk memungkinkan penggunaan dan akses data geospasial secara mudah dan cepat. Penggunaan FS dapat memudahkan proses penyimpanan dan pengelolaan data geospasial yang dapat digunakan oleh berbagai aplikasi atau layanan yang memerlukan data tersebut.

Adapun pilihan FS yang dapat digunakan seperti ArcGIS Online, GeoServer, dan Mapbox. Setelah data disimpan dalam FS, data dapat dimanipulasi dan dianalisis secara mudah dan cepat melalui API yang tersedia.

Dalam proses penyimpanan data ke dalam FS, perlu diperhatikan juga format data yang digunakan harus sesuai dengan format yang didukung oleh FS. Oleh karena itu, perlu dilakukan kajian dan pemilihan FS yang tepat untuk mendukung pengelolaan dan penggunaan data yang efektif dan efisien.

- c. Proses pengambilan, parsing data dan penyimpanan data ke dalam database menggunakan micro service

Dalam proses pengambilan, parsing data, dan penyimpanan data ke dalam database, dapat menggunakan pendekatan microservice. Microservice adalah pendekatan pengembangan perangkat lunak yang membagi aplikasi menjadi komponen yang lebih kecil dan terpisah, yang disebut layanan. Setiap layanan dapat dikembangkan dan dikelola secara independen, dan dapat digunakan untuk melakukan tugas tertentu.

Dalam konteks kasus ini, untuk memproses data dari Kemen-LHK, BMKG, dan LAPAN, dapat menggunakan microservice untuk mempercepat dan memudahkan proses pengambilan, parsing data, dan penyimpanan data ke dalam database. Setiap layanan dapat melakukan tugas tertentu sesuai dengan jenis data yang diproses.

Misalnya, untuk data prakiraan cuaca Kemen-LHK, dapat menggunakan layanan "worker-prakiraan-cuaca-menlhk" untuk mengambil data, melakukan parsing data, dan menyimpan data ke dalam database. Begitu pula dengan data kualitas udara dari Kemen-LHK, dapat

menggunakan layanan "worker-kualitas-udara-menlhk" untuk melakukan hal yang sama.

Sementara itu, untuk data prakiraan cuaca BMKG, dapat menggunakan layanan "worker-bmkg" untuk melakukan pengambilan data, parsing data, dan penyimpanan data ke dalam database. Sedangkan untuk data titik api dan standar JSON dari LAPAN, dapat menggunakan layanan "worker-lapan-titik-api" untuk memproses data tersebut.

Dalam implementasi microservice ini, masing-masing layanan dapat dikembangkan dan dikelola secara terpisah, sehingga memudahkan dalam melakukan perubahan atau penyesuaian pada setiap layanan tanpa mempengaruhi keseluruhan aplikasi. Selain itu, dengan menggunakan pendekatan microservice, dapat meningkatkan skalabilitas dan ketahanan sistem, serta memudahkan dalam melakukan monitoring dan maintenance pada setiap layanan.

4.2.2 Pembelajaran tanpa pengawasan (Unsupervised Learning)

Dalam pembelajaran tanpa pengawasan, tidak ada dukungan pengguna untuk pembelajaran komputer. Perangkat tersebut dapat mengenali pola dalam data yang tidak terlalu jelas bagi otak manusia. Pembelajaran tanpa pengawasan adalah alat penting untuk mengenali pola dalam data dan membantu membuat keputusan. Deteksi aturan pengelompokan dan asosiasi adalah dua jenis pembelajaran tanpa pengawasan.

4.2.3 Pengelompokan/ Penggabungan Data Set

ETL merupakan singkatan dari Extract, Transform, Load, yang merujuk pada serangkaian proses yang biasa digunakan dalam pengolahan data untuk memindahkan data dari satu sistem ke sistem lain atau untuk mengintegrasikan, membersihkan, dan mengubah data sebelum dimuat ke dalam sistem tujuan. Berikut adalah penjelasan singkat tentang setiap tahap dalam proses ETL:

- a. Extract (Ekstraksi): Tahap ekstraksi melibatkan pengambilan data dari sumber data yang ada, seperti database, file teks, file CSV, API, atau sistem lainnya. Data yang diekstraksi mungkin berada dalam berbagai format dan struktur, dan sering kali memerlukan pemrosesan awal untuk mengambil data yang diperlukan.
- b. Transform (Transformasi): Setelah data diekstraksi, tahap transformasi melibatkan perubahan format, struktur, atau nilai data agar sesuai dengan persyaratan sistem tujuan. Proses transformasi dapat melibatkan pembersihan data, normalisasi, penggabungan data dari berbagai sumber, perhitungan kolom baru, penghapusan duplikat, dan pemformatan data.
- c. Load (Pemuatan): Setelah data diubah, tahap pemuatan melibatkan memasukkan data yang telah diubah ke dalam sistem tujuan, seperti database, data warehouse, atau sistem analitik lainnya. Data dapat dimuat dalam batch atau secara real-time, tergantung pada kebutuhan aplikasi dan sumber data.

Proses ETL sangat penting dalam pengolahan data karena memungkinkan organisasi untuk memperoleh data dari berbagai sumber, mengintegrasikannya menjadi satu sumber data tunggal yang bersih dan konsisten, serta memuat data yang telah diubah ke dalam sistem tujuan untuk dianalisis, diproses, atau digunakan dalam pengambilan keputusan. ETL sering digunakan dalam berbagai aplikasi bisnis, termasuk business intelligence, analitik data, pengolahan data besar (big data), dan migrasi data antar sistem. Pada penelitian ini proses ETL dapat dilihat pada aplikasi PTPN4 ETL JOIN HOTSPOT yang ada di repository github pada link: <https://github.com/prasetyomimboro/PTPN4-ETL-JOIN-HOTSPOT>.

Clustering merupakan salah satu metode dalam data mining yaitu teknik pengelompokan data, mengamati atau memperhatikan dan membentuk kelas-kelas objek yang sejenis. Clustering tidak memiliki target output. Dalam metode ini tidak dapat ditentukan hasil keluaran selama proses pembelajaran berlangsung. Selama proses pembelajaran, bobot nilai disusun dalam rentang tertentu tergantung pada nilai input yang diberikan.

Tujuan Pembelajaran dan menginput data ke database. Dataset yang di-scraping dari website pemerintah dapat dilihat pada Tabel 4.1.

Karena data scrap berasal dari sumber yang berbeda, struktur data akan berbeda pada setiap data dan perlu preprocessing untuk mendapatkan tabel standar. Parameter lain perlu dipertimbangkan dalam fase preprocessing.

Secara keseluruhan sumber data pada penelitian ini diperoleh dari website pemerintah penyedia data cuaca/iklim dan sebaran hotspot sebagai berikut:

- a. Prakiraan cuaca MENLHK pada tautan: <http://sipongi.menlhk.go.id/api/perkiraan-cuaca> dengan perolehan variabel data: objectid, category, impacted, event, published, shape
- b. Prakiraan cuaca BMKG pada tautan: <https://data.bmkg.go.id/DataMKG/MEWS/DigitalForecast/DigitalForecast-Indonesia.xml> dengan perolehan variabel data: objectid, provinsi, kabupaten, timerange, weather, t, tmin, tmax, hu, humin, humax, wd, ws, shape.
- c. Kualitas Udara MENLHK pada tautan: <http://sipongi.menlhk.go.id/api/aqms> dengan perolehan variabel data: objectid, alamat, kota, provinsi, waktu, val, nilai, cat, shape.
- d. Titik panas (hot spot) LAPAN pada tautan: https://hotspot.brin.go.id/getHS?SShashKey=object:32&class=hotspot&conf_lv=low&enddate=&id=0&loc=%7B%22st%22:%22Indonesia%22,%22disp%22:%22Indonesia%22%7D&mode=cluster&name=Hotspot&startdate=&time=last24h&visibility=true dengan perolehan variabel data: objectid, date, kepercayaan, shape, loc, hsid, satelit, sensor, kanal, rse, conf.

Dalam pengambilan data dari sumber-sumber yang berbeda, terdapat beberapa variabel data yang perlu diambil untuk setiap jenis data yang diperlukan. Dalam proses pengambilan data ini, variabel data yang diambil menjadi penting karena akan mempengaruhi bagaimana data tersebut diolah

dan diproses selanjutnya. Selain itu, memperoleh variabel data yang tepat juga akan memudahkan dalam menganalisis dan memvisualisasikan data untuk mendapatkan informasi yang lebih akurat dan bermanfaat.

Untuk menggabungkan data secara otomatis dengan key berdasarkan lokasi geografis, dapat dilakukan dengan menggunakan Geographic Information System (GIS) atau software GIS seperti ArcGIS atau QGIS. GIS digunakan untuk memproses dan menganalisis data geografis seperti peta, citra satelit, dan data sensor untuk membuat informasi yang lebih kompleks.

Salah satu cara untuk menggabungkan data berdasarkan lokasi geografis adalah dengan menggunakan operasi spatialisasi dalam GIS. Operasi spatialisasi melibatkan analisis geometri pada data geografis dan menghitung jarak atau overlap antara fitur yang ada. Misalnya, jika data cuaca MENLHK dan data BMKG memiliki fitur kota yang sama, maka fitur-fitur ini dapat digabungkan secara otomatis dengan menggunakan operasi spatialisasi seperti intersect atau join based on location.

Setelah data digabungkan, informasi yang lebih lengkap dapat dihasilkan, seperti informasi cuaca dan kualitas udara pada kota yang sama. Begitu juga dengan data titik panas LAPAN, dapat digabungkan dengan data cuaca dan kualitas udara untuk memperoleh informasi yang lebih lengkap dan komprehensif tentang kondisi lingkungan di wilayah tersebut.


Spatial join adalah salah satu jenis operasi spatialisasi yang digunakan dalam GIS untuk menggabungkan dua dataset yang memiliki informasi lokasi yang saling berhubungan atau berdekatan. Operasi ini biasanya dilakukan dengan menghitung jarak atau overlap antara fitur-fitur pada kedua dataset.

Penggabungan data cuaca MENLHK, cuaca BMKG, dan kualitas udara MENLHK dengan data titik panas LAPAN berdasarkan lokasi geografis, dapat dilakukan dengan menggunakan spatial join. Pertama, perlu dilakukan parsing data dari masing-masing sumber data dan menyimpannya ke dalam fitur services. Kemudian, dilakukan pengambilan data dan parsing

data dari fitur services tersebut menggunakan microservice. Setelah itu, dilakukan penyimpanan data ke dalam database.

Setelah data berhasil disimpan ke dalam database, maka dapat dilakukan operasi spatial join antara dataset cuaca MENLHK, cuaca BMKG, dan kualitas udara MENLHK dengan dataset titik panas LAPAN berdasarkan kolom yang sama dalam kedua dataset, yaitu kolom yang berisi nama kota atau lokasi geografis yang saling berhubungan. Hasil dari operasi spatial join ini adalah dataset baru yang menggabungkan informasi cuaca, kualitas udara, dan titik panas pada setiap kota atau lokasi geografis yang terdapat pada kedua dataset tersebut.


Preprocessing kumpulan data menghasilkan 67.378 baris data yang semuanya terletak di tempat dan waktu yang sama. Sangat penting untuk berada di tempat dan waktu yang sama karena kebakaran hutan akan bergantung pada keadaan setempat selama periode tertentu. Langkah preprocessing lainnya adalah menghilangkan data yang hilang dari kumpulan data baru karena studi hanya akan dilakukan untuk area dengan atribusi lengkap. Secara tahapan proses, dapat dilihat pada Gambar 4.6.



Gambar 4.6 Preprocessing Data

Pada proses tersebut yang dihasilkan adalah pengelompokan unit-unit yang hampir sama pada suatu daerah tertentu. Pengelompokan berbeda dengan klasifikasi jika tidak ada target variabel untuk pengelompokan. Clustering tidak mengklasifikasikan, memprediksi atau memprediksi nilai

dari variabel target dan digunakan ketika kita tidak tahu bagaimana data harus dikelompokkan. Label kelas tidak diketahui/tidak ada, maka clustering sering juga disebut unsupervised learning. Sebaran hasil data mining secara spasial di tunjukkan pada gambar 4.7.



Gambar 4.7 Visualisasi hasil data mining secara spasial

4.2.4 Clustering untuk mendapatkan nilai DB-Index tertinggi dengan Metode David Bouldin Index (DBI)

4.2.4.1 K-Mean

Analisis klaster bertujuan untuk mengklasifikasikan objek data menjadi dua kategori yaitu objek yang memiliki kesamaan karakteristik dalam satu klaster dan objek yang memiliki karakteristik berbeda dengan objek lain dari klaster yang lain. K-Means merupakan salah satu metode yang termasuk dalam algoritma clustering berbasis jarak yang dimulai dengan menentukan jumlah cluster yang diinginkan. Tujuan pengelompokan pada makalah ini adalah untuk mengklasifikasikan Hot Spot yang memiliki kesamaan karakteristik cuaca, suhu, kelembaban, kecepatan angin dan arah angin.

Langkah-langkah pengelompokan pada K-means adalah:

- Pilih titik data k (acak) (seed) untuk menjadi centroid awal, pusat klaster
- Tetapkan setiap titik data ke centroid terdekat
- Hitung ulang centroid menggunakan keanggotaan cluster saat ini

- d. Jika kriteria konvergensi tidak terpenuhi, ulangi langkah 2 dan 3

Pengelompokan objek berdasarkan jumlah titik panas, cuaca, suhu, kelembaban, kecepatan angin dan arah angin dengan mempertimbangkan jarak minimum antar objek.

4.2.4.2 Jarak Euclidean

Dari beberapa penelitian untuk clustering, pengukuran jarak yang umumnya sering digunakan adalah jarak Euclidean. Jarak Euclidean dianggap sebagai matriks jarak yang mengadopsi prinsip Pythagoras. Hal ini disebabkan pola perhitungan yang menggunakan aturan eksponen dan akar kuadrat. Euclidean akan memberikan hasil jarak yang relatif kecil karena menggunakan aturan akar kuadrat. Jarak antara nilai/bobot acak dengan data dihitung menggunakan rumus persamaan :

$$D_i = \sum_{l=1}^n (w_{li} - x_i) \quad (5)$$

Keterangan:

D_i : jarak Euclidean

w_{ij} : Berat neuron $n-i$ (bobot akhir)

x_i : Masukan vektor

4.2.4.3 Davies Bouldin Indeks (DBI)

Davis Bouldin Index (DBI) yang diperkenalkan oleh David L. Davies dan Donald W. Bouldin pada tahun 1979 merupakan metrik untuk mengevaluasi hasil dari algoritma clustering. Pengukuran evaluasi algoritma pengelompokan adalah salah satu cara untuk mengukur seberapa baik kinerja algoritma pengelompokan. Kriteria pemisahan adalah ukuran yang biasa digunakan untuk mengevaluasi kebaikan pemisahan dengan algoritme pengelompokan K-Means. DBI adalah ukuran seberapa mirip setiap kluster dengan kluster yang paling mirip dengannya. Semakin rendah rata-rata kesamaan, semakin baik cluster dipisahkan dan semakin baik hasil clustering.

Pada bab ini akan dibahas tentang jenis-jenis data yang diperoleh data mining dari beberapa website sumber data, cara menggabungkan data, mereduksi data karena data kosong (NaN), korelasi antar data dan melakukan clustering serta mencari centroid terkecil dengan DB Nilai indeks.

4.2.4.4 Kumpulan Data

Data mining dari beberapa website dan proses join data tabular dan spasial diperoleh variable data seperti tampil pada Tabel 4.2 sebagai berikut:

Tabel 4.2 Jenis variable data yang dihasilkan dari proses join data

1. hotspot_date	6. hotspot_sensor	11. hotspot_bujur	16. cuaca_bmkg_tmax
2. hotspot_trust	7. hotspot_kanal	12. hotspot_provinsi	17. cuaca_bmkg_humin
3. hotspot_loc	8. hotspot_resolusi	13. hotspot_distrik	18. cuaca_bmkg_humax
4. hsid	9. hotspot_confident_level	14. hotspot_sub_distrik	19. alamat_kualitas udara
5. hotspot_satelit	10. hotspot_latitude	15. cuaca_bmkg_tmin	20. cuaca_bmkg_tmax

4.2.4.5 Menggabungkan Data Tabular dengan Data Spasial


Berdasarkan kumpulan data yang diperoleh, berikut adalah langkah-langkah cara menggabungkan data spasial (hot spot) dengan data tabular (cuaca):

- Pengambilan semua data hotspot (waktu nyata dan riwayat)
- Membersihkan data hotspot (mengambil data unik berdasarkan HSID)
- Join data prakiraan cuaca BMKG (realtime dan history) berdasarkan field provinsi dan field timerange (tabel BMKG) yang dekat dengan tanggal field (tabel hotspot)
- Gabungkan data kualitas udara MENLHK (realtime dan history) berdasarkan kolom provinsi dan kolom waktu (tabel_kualitas udara) dengan tanggal yang sama pada kolom tanggal (tabel hotspot).
- Keseluruhan data yang sudah digabungkan berjumlah 25 kolom dan 67.368 baris dapat diakses pada link berikut ini:

<https://drive.google.com/file/d/1g1DLgg9jhZpNie5mKVjKnlBqN8PX-OdK/view?usp=sharing>

- f. Preview data dapat dilihat pada Lampiran 5.

Proses join data mendapatkan data hot spot dan data cuaca, total data sebanyak 67.377 baris dan 25 kolom yang kemudian di proses ke dalam analisis data dimulai dengan pemanggilan data set dengan nama "hotspot-joined.csv" seperti tampil pada Gambar 4.8.



```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

import warnings
warnings.filterwarnings('ignore')
pd.set_option('display.max_columns', None)

from sklearn.cluster import KMeans

df = pd.read_csv('/content/drive/MyDrive/Dataset/hotspot-joined.csv')
print('Berikut Tampilan Data :\n')

df.head(5)
  
```

Gambar 4.8 Proses pemanggilan data ke dalam Google Colab

Dengan definisi kolom pada Gambar 4.9 dengan jumlah variable sebanyak 25 yaitu 'hotspot_date', 'hotspot_kepercayaan', 'hotspot_loc',

'hsid', 'hotspot_satelit', 'hotspot_sensor', 'hotspot_kanal', 'hotspot_res', 'hotspot_conf', 'hotspot_latitude', 'hotspot_longitude', 'hotspot_provinsi', 'hotspot_kabupaten', 'hotspot_kecamatan', 'cuaca_bmkg_tmin', 'cuaca_bmkg_tmax', 'cuaca_bmkg_humin', 'cuaca_bmkg_humax', 'kualitas_udara_alamat', 'kualitas_udara_kota', 'kualitas_udara_provinsi', 'kualitas_udara_waktu', 'kualitas_udara_val', 'kualitas_udara_nilai', 'kualitas_udara_cat' dan pada Gambar 4.10, ditampilkan beberapa sampel data yang sudah digabungkan sebagai berikut:

Tabel 4.2 Perbandingan data lengkap dan tidak lengkap

No	Features	Data in row 3815	Data in row 3798
1.	hotspot_date	Sat Dec 11 2021 18:23:44 GMT+0700 (Western Indonesia Time)	Sat Dec 11 2021 05:37:01 GMT+0700 (Western Indonesia Time)
2.	hotspot_kepercayaan	Medium	Medium
3.	hotspot_loc	Banten, Tangerang, Kosambi	Maluku, Buru Selatan, Leksula
4.	hsid	3563094	3563072
5.	hotspot_satelit	NOAA-20	NOAA-20
6.	hotspot_sensor	VIIRS	VIIRS
7.	hotspot_kanal	Kanal 14 (3550 Å ^o : 3930 nm)	Kanal 14 (3550 Å ^o : 3930 nm)
8.	hotspot_res	375 meter	375 meter
9.	hotspot_conf	800.000.000	800.000.000
10.	hotspot_latitude	-610.012.149.999.994	-359.766.888.999.997
11.	hotspot_longitude	10.667.189.789	12.622.586.823
12.	hotspot_provinsi	Banten	Maluku
13.	hotspot_kabupaten	Tangerang	Buru Selatan
14.	hotspot_kecamatan	Kosambi	Leksula
15.	cuaca_bmkg_tmin	23	23
16.	cuaca_bmkg_tmax	32	30
17.	cuaca_bmkg_humin	65	70
18.	cuaca_bmkg_humax	95	95
19.	kualitas_udara_alamat	Jl. Jendral Sudirman No. 19 RT 001/01, Sunurpecong, Kec. Serang	
20.	kualitas_udara_kota	Serang	
21.	kualitas_udara_provinsi	Banten	
22.	kualitas_udara_waktu	Sat Dec 11 2021 18:23:44 GMT+0700 (Western Indonesia Time)	
23.	kualitas_udara_val	3.600.000.000	
24.	kualitas_udara_nilai	3.600.000.000	
25.	kualitas_udara_cat	RAIK	

4.2.4.6 Membersihkan Kumpulan Data

Pada Tabel 2 menunjukkan perbandingan kumpulan data lengkap dan kumpulan data tidak lengkap (mengandung NaN). Penulis menggunakan library panda untuk menyelesaikan proses pembersihan. Dapat dilihat bahwa

keseluruhan data berjumlah 67.377 baris dan setelah dilakukan data cleansing, data yang bisa digunakan untuk analisis selanjutnya sejumlah 51.559 baris seperti ditampilkan pada Gambar 4.11.

Pada Gambar 4.11 menunjukkan jumlah data pada tahap pre-prosesing yang dilakukan pada Google Colab.

```
[ ] data = data.dropna()

[ ] data.info()

<class 'pandas.core.frame.DataFrame'>
Int64Index: 51559 entries, 3488 to 67377
Data columns (total 11 columns):
#   Column                Non-Null Count  Dtype
---  -
0   hotspot_loc            51559 non-null  object
1   hotspot_kepercayaan    51559 non-null  object
2   hotspot_latitude       51559 non-null  float64
3   hotspot_longitude      51559 non-null  float64
4   hotspot_provinsi       51559 non-null  object
5   hotspot_kabupaten      51559 non-null  object
6   hotspot_kecamatan      51559 non-null  object
7   cuaca_bmkg_tmin        51559 non-null  float64
8   cuaca_bmkg_tmax        51559 non-null  float64
9   cuaca_bmkg_humin       51559 non-null  float64
10  cuaca_bmkg_humax       51559 non-null  float64
dtypes: float64(6), object(5)
memory usage: 4.7+ MB
```

Gambar 4.11 Tahapan pre-prosesing data di Google Colab

DataFrame ini juga mencakup informasi tentang tipe data (Dtype) dari setiap kolom, jumlah nilai non-null (Non-Null Count), dan penggunaan memori (memory usage) dari DataFrame tersebut. Data ini bisa digunakan untuk analisis lebih lanjut atau pemodelan terkait kejadian hotspot dan cuaca BMKG.

hotspot_loc	hotspot_kepercayaan	hotspot_latitude	hotspot_longitude	hotspot_provinsi	hotspot_kabupaten	hotspot_kecamatan	cuaca_bmkg_tmin	cuaca_bmkg_tmax	cuaca_bmkg_humin	cuaca_bmkg_humax
3488	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3489	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3490	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3491	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3492	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3493	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3494	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3495	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3496	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3497	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3498	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3499	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0
3500	1.0	1.12117	101.68125	DKI Jakarta	Kabupaten Jakarta Barat	Kecamatan Kuning Jaya	29.0	32.0	70.0	95.0

Gambar 4.12 Preview feature yang ada dalam data set di Google Colab

Menggunakan DBIndex

```
[ ] # Clustering using kmeans
max_k = 10
db_index = []
for k in range(2, max_k+1):
    kmeans = KMeans(n_clusters=k, random_state=0)
    kmeans.fit(X_pca)
    db = davies_bouldin_score(X_pca, kmeans.labels_)
    db_index.append(db)

[ ] # optimal k with minimum DBIndex
optimal_k = np.argmax(db_index) + 2

[ ] optimal_k
10

[ ] # Clustering with optimal k
kmeans = KMeans(n_clusters=optimal_k, random_state=0)
kmeans.fit(X_pca)
labels = kmeans.labels_

[ ] labels
array([0, 0, 0, ..., 0, 2, 0], dtype=int32)

[ ] # cluster labels to values
filtered_data['cluster'] = labels

[ ] filtered_data['cluster'].value_counts()
0    4024
1    1769
0    1493
0    1039
5     556
1     382
2     364
4     274
3     233
6     208
Name: cluster, dtype: int32
```

Gambar 4.16 Sebaran data cuaca berdasarkan kategori cluster


Output of the code in Gambar 4.16:

```
array([[0, 0, 0, ..., 0, 2, 0], dtype=int32])
```

Output of the code in Gambar 4.17:

```
0    4024
1    1769
0    1493
0    1039
5     556
1     382
2     364
4     274
3     233
6     208
Name: cluster, dtype: int32
```

Gambar 4.17 Nilai K Optimal di Google Colab



Gambar 4.18 Grafik DB Index pada nilai K

Menggunakan Silhouette

```
[ ] max_k = 10
silhouette_scores = []

for k in range(2, max_k+1):
    kmeans = KMeans(n_clusters=k, random_state=0)
    kmeans.fit(X_pac_silhouette)
    silhouette_avg = silhouette_score(X_pac_silhouette, kmeans.labels_)
    silhouette_scores.append(silhouette_avg)

[ ] optimal_k = np.argmax(silhouette_scores) + 2

print('Optimal K:', optimal_k)


Optimal K: 10

[ ] # Elbow method to find optimal k
max_k = 10
inertias = []


for k in range(2, max_k+1):
    kmeans = KMeans(n_clusters=k, random_state=0)
    kmeans.fit(X_pac_silhouette)
    inertias.append(kmeans.inertia_)

# Plot elbow method
plt.plot(range(2, max_k+1), inertias, marker='o')
plt.xlabel('Number of clusters (k)')
plt.ylabel('Inertia')
plt.show()
```

Gambar 4.19 Analisis Silhoutte Score



Gambar 4.20 Grafik nilai Inertia terhadap nilai K



Gambar 4.21 Grafik Silhouette Score pada masing-masing nilai K

```

# Performe clustering with optimal k
kmeans = KMeans(n_clusters=optimal_k, random_state=0)
kmeans.fit(X_pac_silhouette)
labels = kmeans.labels_

# Print number of data points in each cluster
unique, counts = np.unique(labels, return_counts=True)
print(list(zip(unique, counts)))


[0: 1692, 1: 2812, 2: 1769, 3: 4824, 4: 874, 5: 1198, 6: 638, 7: 964, 8: 1524, 9: 789]

# calculate silhouette score for clustering result
silhouette_avg = silhouette_score(X_pac_silhouette, labels)
print('Silhouette score:', silhouette_avg)
print('Optimal K:', optimal_k)

Silhouette score: 0.28576771040322236
Optimal K: 10

```


Gambar 4.22 Nilai Silhouette Score



Gambar 4.23 Grafik Silhouette Score



Gambar 4.24 Grafik sebaran nilai cuaca terhadap masing-masing cluster



Gambar 4.25 Sebaran prediksi kebakaran hutan berdasarkan cluster

Setelah dilakukan proses cleaning, total data menjadi 51.559. Teknik clustering menggunakan scikit learn library di python. Jumlah cluster didefinisikan dari 2 hingga 10 dan hasil skor DBI ditunjukkan pada Tabel 15. Data menunjukkan bahwa cluster ke-10 mencapai skor 1,403 DBI, dan diklaim sebagai jumlah cluster terbaik dalam percobaan ini.

Skor akurasi di atas membuktikan bahwa K-Means memiliki kinerja yang baik untuk melakukan pengelompokan kebakaran hutan. Keadaan ini didukung oleh persiapan kumpulan data yang berjalan sangat baik dengan membuang data yang tidak perlu dan tidak lengkap untuk membentuk kumpulan data baru untuk proses clustering.

Berdasarkan hasil evaluasi di atas, penelitian ini mendapatkan hasil yang memuaskan dengan mampu melakukan clustering data mining menggunakan algoritma K-Means dan menggabungkan data tabular dengan data spasial. Metode data mining yang dilakukan berhasil mendapatkan data dari beberapa website untuk mendukung prediksi kebakaran hutan. Berdasarkan tahapan analisis yang dilakukan diperoleh 9 cluster dengan nilai indeks DB sebesar 1,403 seperti tampil pada Gambar 4.26 dan Gambar 4.27.

Tabel 15 Hasil Evaluasi Clustering


Cluster (k)	DB Index Score
2	2.340568
3	2.533517
4	2.089778
5	1.963958
6	1.666688
7	1.673217
8	1.522965
9	1.473109
10	1.403684



```
table_dbindex = pd.DataFrame({'k': range(2, max_k+1), 'DBIndex': db_index})
print(table_dbindex)
```

k	DBIndex
2	2.340568
3	2.533517
4	2.089778
5	1.963958
6	1.666688
7	1.673217
8	1.522965
9	1.473109
10	1.403684

Gambar 4.26 Hasil evaluasi DB Index di Google Colab



Gambar 4.27 Skor DBI untuk beberapa kluster (k)

4.3. Faktor-faktor terjadinya Kebakaran Hutan

4.3.1 Faktor Terkait Manusia/Human Related Factors (HRF)

4.3.1.1 Pendapatan per Kapita (Gros Domestic Product/GDP)

Data pendapatan per kapita (variabel $1 = v1$) diperoleh dari website Badan Pusat Statistik Kabupaten Palangkaraya Kalimantan Timur pada link:

<https://disdukcapil.palangkaraya.go.id/wp-content/uploads/sites/74/2022/01/DATA-AGREGAT-KEPENDUDUKAN-TAHUN-2021-1.pdf>, yang ditampilkan pada Tabel 4.4, diketahui bahwa Produk Nasional Bruto (PNB) harga konstan Kabupaten Palangkaraya sebesar Rp. 273.300.000.000,- (*Dua Ratus Tujuh Puluh Tiga Milyar, Tiga Ratus Juta Rupiah*).

Dikarenakan data PNB yang didapatkan untuk wilayah Kabupaten Palangkaraya, maka perlu dilakukan perhitungan dan pembobotan untuk masing-masing kelurahan dengan rumus sebagai berikut:

- a. Mencari nilai bobot proporsional jumlah penduduk per kelurahan:

$$\text{Bobot Proporsional}(\%) = \frac{\text{jumlah penduduk per kelurahan}}{\text{jumlah penduduk Kabupaten}} \times 100\% \quad (6)$$

- b. Berdasarkan data 4.3.1.1.a, dilakukan perhitungan untuk memperoleh nilai Pendapatan per Kapita (PPK) per kelurahan dengan rumus sebagai berikut:

$$\text{PPK/GDP} = \frac{\text{PNB Harga Konstan} \times \text{Bobot Proporsional}}{100} \quad (7)$$

Tabel 4.4 Jumlah Penduduk dan Pendapatan per Kapita (PPK) Kota Palangka Raya Berdasarkan Data Konsolidasi Bersih (DKB) KEMENDAGRI SEMESTER II TAHUN 2021

No	Kecamatan	Kelurahan	Luas Wilayah (km2)	Laki-laki	Perempuan	Jumlah (Laki dan Perempuan)	Proporsional (%)	PDB (Rp)
1	Palangka	Palangka		14.316	15.463	29.779	9,42	25.541.346.822
		Panasing		15.012	16.602	31.614	10,14	27.585.584.763
		Langka		14.920	14.701	29.621	10,13	27.692.537.107
		Panabang Rangan		432	449	881	0,29	786.662.610
		Palangka Schorang		2.739	2.641	5.380	1,63	5.008.552.236
		Panang Posing		2.463	2.387	4.850	1,47	4.551.532.407
		Total	110,73	49.711	49.372	99.082	33,47	91.498.127.149
2	Itak Itak	Maring		279	515	794	0,77	1.019.431.580
		Tumbang Tahan		1.472	1.430	2.902	0,90	2.786.670.125
		Buaring		1.064	1.833	2.897	1,29	3.515.313.474
		Tengkilite		1.000	1.577	2.577	1,11	1.628.446.620
		Sua Chelang		624	792	1.416	0,85	1.507.239.125
		Sututukan		189	184	373	0,12	347.903.831
		Total	640,73	7.263	6.776	14.039	4,90	13.115.774.161
3	Akar Raya	Palangka		23.125	22.684	45.809	15,75	43.063.597.329
		Moktan		25.022	24.379	49.401	16,56	46.075.862.439
		Bukit Targan		27.463	26.440	53.903	18,39	56.772.903.246
		Pondok Karaman		1.663	1.558	3.221	1,10	3.006.094.020
		Total	367,83	77.273	75.161	152.432	82,80	142.356.557.043
4	Sabangau	Batang Benda		400	501	901	0,40	1.080.339.110
		Kalamangan		2.532	2.546	5.078	1,27	4.280.379.036
		Karang Sangharu		8.011	8.028	16.039	1,76	16.953.874.688
		Kamalah Bera		610	397	1.007	0,29	752.641.371
		Batang Ponda		123	113	236	0,09	229.113.145
		Total	603,14	12.685	11.966	24.651	8,35	22.804.565.568
5	Bakamari	Pondok Paka		527	467	994	0,34	927.095.143
		Pangchag		337	196	533	0,09	228.589.346
		Pondok Barasu		450	403	853	0,29	787.583.671
		Mangkla Bera		279	236	515	0,54	666.874.271
		Pagat		239	214	453	0,15	422.569.135
		Ujung Bera		241	129	370	0,09	251.662.031
		Total	1.101,09	2.626	1.776	4.402	1,26	3.546.496.139
	Grand Total (1+2+3+4+5)		2.853,12	149.346	144.177	293.523	100	273.388.886.886

Sehingga diperoleh data pada Tabel 4.4, selanjutnya dilakukan klasifikasi untuk pembobotan nilai score sesuai dengan lokasi penelitian dengan perhitungan pada Tabel 4.5 sebagai berikut:

Tabel 4.5 Hasil perhitungan Pendapatan per Kapita per kelurahan

Id_desa	Kelurahan	PPK/GDP (Rp)
1	Kelurahan Bukit Tunggul	50.272.993.246,26
2	Kelurahan Kereng Bangkirai	10.883.574.668,20
3	Kelurahan Langkai	27.692.537.104,60
4	Kelurahan Menteng	46.075.882.439,26
5	Kelurahan Pahandut	25.741.346.924,99
6	Kelurahan Pahandut Seberang	5.008.552.229,69
7	Kelurahan Palangka	43.003.597.328,54
8	Kelurahan Panarung	27.705.594.782,66
9	Kelurahan Petuk Katimpun	3.006.064.029,10
10	Kelurahan Tumbang Rungan	780.662.610,10

Hasil perhitungan score Pendapatan per Kapita (Gros Domestic Product/GDP) ditampilkan pada Tabel 4.6:

Tabel 4.6 Rentang nilai sebagai dasar perhitungan GDP

Nilai Minimum (Min)	780.662.610
Nilai Maximum (Max)	50.272.993.246,26
Nilai Rata-rata (Average)	24.017.080.536,34
Jumlah (Sum)	240.170.805.363,40

Diketahui bahwa nilai maksimum PPK/GDP sebesar 50.272.993.246,26, dan klasifikasi score yang diinginkan sejumlah 4 kelas/klasifikasi score. Sehingga perlu ditentukan rentang nilai dengan membagi nilai PPK/GDP maksimum di bagi 4 kelas sebagai berikut:

$$\begin{aligned}
 \text{Rentang Nilai (v1)} &= \frac{\text{Nilai maksimum PPK/GDP}}{4 \text{ kelas}} & (8) \\
 \text{Rentang Nilai} &= \frac{50.272.993.246,26}{4} \\
 &= 12.568.248.311,57
 \end{aligned}$$

Sehingga diperoleh kelas pada variabel 1 (v1) yaitu Pendapatan per Kapita (Gros Domestic Product/GDP) pada Tabel 4.7 dan pemberian skor yang dijelaskan pada Tabel 4.8 sebagai berikut:

Tabel 4.7 Nilai GDP berdasarkan skor label

Score label	Rentang Nilai PPK/GDP
1	$\leq 12.568.248.311,57 - 25.136.496.623,13$
2	$25.136.496.623,13 - 37.704.744.934,70$
3	$37.704.744.934,70 - 50.272.993.246,26$
4	$\geq 50.272.993.246,26$

Berdasarkan Tabel 4.7, maka diperoleh score pada wilayah penelitian sebagai berikut pada Tabel 4.8:

Tabel 4.8 Hasil perhitungan GPD per kelurahan dan skor label

Id_desa	Kelurahan	PPK/GDP (Rp)	Score label
1	Kelurahan Bukit Tunggul	50.272.993.246,26	4
2	Kelurahan Kereng Bangkirai	10.883.574.668,20	1
3	Kelurahan Langkai	27.692.537.104,60	2
4	Kelurahan Menteng	46.075.882.439,26	3
5	Kelurahan Pahandut	25.741.346.924,99	2
6	Kelurahan Pahandut Seberang	5.008.552.229,69	1
7	Kelurahan Palangka	43.003.597.328,54	3
8	Kelurahan Panarung	27.705.594.782,66	2
9	Kelurahan Petuk Katimpun	3.006.064.029,10	1
10	Kelurahan Tumbang Rungan	780.662.610,10	1

Berdasarkan penelitian yang dilakukan oleh Zhang et al. (2018) di Tiongkok, pendapatan per kapita (GDP) memiliki hubungan yang signifikan dengan kebakaran hutan. Penelitian ini menunjukkan bahwa semakin tinggi pendapatan per kapita di suatu wilayah, maka semakin kecil kemungkinan terjadinya kebakaran hutan di wilayah tersebut. Faktor ini dapat dijelaskan oleh adanya keterkaitan antara peningkatan pendapatan per kapita dengan peningkatan infrastruktur dan teknologi, sehingga masyarakat dapat lebih mampu untuk mengelola hutan dengan lebih baik dan mencegah terjadinya kebakaran.

4.3.1.2 Penduduk/Population Density (PD)

Data kepadatan penduduk (variabel 2 = v_2) diperoleh dari website Badan Pusat Statistik Kabupaten Palangkaraya Kalimantan Timur pada link: <https://disdukcapil.palangkaraya.go.id/wp-content/uploads/sites/74/2022/01/DATA-AGREGAT-KEPENDUDUKAN->

[TAHUN-2021-1.pdf](#), selain data kepadatan penduduk, pada sumber data tersebut juga diperoleh luas area (Hektar dan Km²) per kelurahan dengan rincian pada Tabel 4.9 sebagai berikut:

Tabel 4.9 Data kepadatan penduduk area penelitian

Id_desa	Kelurahan	Luas Area				Populasi			
		Hektar (Ha)		Km ²		L	P	Kepadatan Penduduk	
1	Kelurahan Bukit Tunggal	27.414,52		274		27.461	26.440	53.901	
2	Kelurahan Kereng Bangkirai	32.344,46		323		6.031	5.638	11.669	
3	Kelurahan Langkai	888,27		9		14.928	14.763	29.691	
4	Kelurahan Menteng	3.126,80		31		25.022	24.379	49.401	
5	Kelurahan Pahandut	820,16		8		14.116	13.483	27.599	
6	Kelurahan Pahandut Seberang	794,51		8		2.729	2.641	5.370	
7	Kelurahan Palangka	2.248,60		22		23.123	22.984	46.107	
8	Kelurahan Panarung	2.309,55		23		15.013	14.692	29.705	
9	Kelurahan Petuk Katimpun	5.962,60		60		1.665	1.558	3.223	
10	Kelurahan Tumbang Rungan	2.330,31		23		432	405	837	

Kepadatan Penduduk/Populasi

Perhitungan score Kepadatan Penduduk/Populasi diawali dengan mencari rentang nilai ditampilkan pada Tabel 4.10 berikut:

Tabel 4.10 Rentang nilai sebagai dasar perhitungan kepadatan penduduk

Nilai Minimum (Min)	837
Nilai Maximum (Max)	53.901,00
Nilai Rata-rata (Average)	25.750,30
Jumlah (Sum)	257.503,00

Diketahui bahwa nilai maksimum kepadatan penduduk sebesar 53.901 dan klasifikasi score yang diinginkan sejumlah 4 kelas/klasifikasi score. Sehingga perlu ditentukan rentang nilai dengan membagi nilai Kepadatan Penduduk maksimum di bagi 4 kelas sebagai berikut:

$$\text{Rentang Nilai (v2)} = \frac{\text{Nilai maksimum Kepadatan Penduduk}}{4 \text{ kelas}} \quad (9)$$

$$\text{Rentang Nilai} = \frac{53.901,00}{4}$$

$$\text{Rentang Nilai} = 13.475,25$$

Sehingga diperoleh kelas pada variabel 2 (v2) yaitu Kepadatan Penduduk didapatkan score berdasarkan rentang nilai pada Tabel 4.11 sebagai berikut:

Tabel 4.11 Nilai kepadatan penduduk berdasarkan skor label

Score	Rentang Nilai Kepadatan Penduduk
1	$\leq 13.475,25 - 26.950,50$
2	$26.950,50 - 40.425,75$
3	$40.425,75 - 53.901,00$
4	$\geq 53.901,00$

Setelah diperoleh score paa masing-masing rentang nilai, maka dimasukkan ke dalam data kepadatan penduduk per kelurahan seperti ditunjukkan pada Tabel 4.12 sebagai berikut:



Table 4.12 Data kepadatan penduduk area penelitian dan skor label populasi

Id_desa	Kelurahan	Luas Area				Populasi			
		Hektar (Ha)	Score	Km ²	Score	L	P	Density	Score
1	Kelurahan Bukit Tunggal	27.414,52	4	274	2	27.461	26.440	53.901	4
2	Kelurahan Kereng Bangkirai	32.344,46	4	323	2	6.031	5.638	11.669	1
3	Kelurahan Langkai	888,27	1	9	1	14.928	14.763	29.691	2
4	Kelurahan Menteng	3.126,80	1	31	1	25.022	24.379	49.401	3
5	Kelurahan Pahandut	820,16	1	8	1	14.116	13.483	27.599	2
6	Kelurahan Pahandut Seberang	794,51	1	8	1	2.729	2.641	5.370	1
7	Kelurahan Palangka	2.248,60	1	22	1	23.123	22.984	46.107	3
8	Kelurahan Panaring	2.309,55	1	23	1	15.013	14.692	29.705	2
9	Kelurahan Petuk Katimpun	5.962,60	1	60	1	1.665	1.558	3.223	1
10	Kelurahan Tumbang Rungan	2.330,31	1	23	1	432	405	837	1

Penduduk atau kepadatan penduduk juga merupakan faktor yang berpengaruh terhadap kebakaran hutan. Beberapa penelitian telah mengungkapkan bahwa semakin tinggi kepadatan penduduk di suatu daerah, semakin tinggi kemungkinan terjadinya kebakaran hutan. Hal ini dapat disebabkan oleh aktivitas manusia yang semakin intensif, seperti pembukaan lahan pertanian, penggunaan api terbuka untuk memasak dan pemanasan,

pembangunan permukiman, serta aktivitas lainnya yang dapat meningkatkan risiko terjadinya kebakaran hutan.

Salah satu penelitian yang membahas faktor kepadatan penduduk terhadap kebakaran hutan adalah penelitian yang dilakukan oleh Miettinen dkk. (2017) di Kalimantan. Penelitian tersebut menunjukkan bahwa kebakaran hutan di Kalimantan terutama terjadi di daerah-daerah dengan kepadatan penduduk yang tinggi dan penggunaan lahan yang intensif untuk pertanian. Selain itu, penelitian tersebut juga menunjukkan bahwa terjadinya kebakaran hutan di daerah dengan kepadatan penduduk yang tinggi dapat diatasi dengan penerapan tata kelola lahan yang baik dan pembangunan infrastruktur yang tepat.

4.3.1.3 Jarak ke Pemukiman/Distance to Settlement (DS)


Pada tahap ini Jarak ke Pemukiman/Distance to Settlement (DS), menjadi variabel 3 = v3) diperlukan data spasial jaringan jalan sesuai lokasi penelitian, data tersebut dapat di peroleh di website Badan Informasi Geospasial (BIG) pada link: <https://tanahair.indonesia.go.id/portal-web>, sehingga diperoleh data "pemukiman.shp".

Selanjutnya dilakukan analisis data spasial yaitu "buffering" dengan menggunakan software pemetaan untuk mendapatkan area dengan jarak tertentu dari pemukiman dengan output 4 klasifikasi score.

Berdasarkan hasil analisis diperoleh klasifikasi data Jarak ke Pemukiman/Distance to Settlement (DS) diperoleh data pada Tabel 4.13 dan Gambar 4.19 sebagai berikut:

Tabel 4.13 Klasifikasi Jarak ke Pemukiman/Distance to Settlement (DS) dan skor label

No	Jarak ke Pemukiman/Distance to Settlement (DS) (Mtr)	Score label	Luas (Ha)	Persentase (%)
1	0 - 356,5	1		
2	356,5 - 635,7	2		
3	635,7 - 1041,8	3		
4	1041,8 - ∞	4		
Total				



Gambar 4.19 Peta hasil analisis Jarak ke Pemukiman/Distance to Settlement (DS)

Pada tahap ini, dilakukan analisis data spasial Jarak ke Pemukiman atau Distance to Settlement (DS) yang menjadi variabel 3 atau v3. Data spasial jaringan jalan sesuai dengan lokasi penelitian diperoleh dari website Badan Informasi Geospasial (BIG). Data tersebut digunakan untuk melakukan buffering menggunakan software pemetaan guna mendapatkan area dengan jarak tertentu dari pemukiman. Output analisis berupa klasifikasi data Jarak

ke Pemukiman/Distance to Settlement (DS) dengan 4 klasifikasi score yang diperoleh melalui proses buffering. Klasifikasi tersebut terdiri dari kategori jarak 0-356,5 meter dengan score label 1, kategori jarak 356,5-635,7 meter dengan score label 2, kategori jarak 635,7-1041,8 meter dengan score label 3, dan kategori jarak 1041,8 meter ke atas dengan score label 4. Data hasil analisis ini kemudian ditampilkan dalam Tabel 4.13 yang memuat informasi mengenai klasifikasi Jarak ke Pemukiman/Distance to Settlement (DS), skor label, luas, dan persentase pada setiap kategori jarak. Selain itu, hasil analisis juga ditampilkan dalam Gambar 4.19 untuk memberikan visualisasi yang lebih jelas mengenai klasifikasi data Jarak ke Pemukiman/Distance to Settlement (DS).

Berdasarkan literatur dan hasil penelitian sebelumnya, jarak ke pemukiman atau Distance to Settlement (DS) memiliki hubungan yang signifikan dengan kebakaran hutan. Penelitian yang dilakukan oleh Wang et al. (2014) menunjukkan bahwa semakin dekat jarak ke pemukiman, semakin tinggi risiko terjadinya kebakaran hutan. Penelitian tersebut menggunakan teknologi remote sensing dan sistem informasi geografis (SIG) untuk menganalisis data spasial dan faktor-faktor yang mempengaruhi kebakaran hutan di Provinsi Hubei, Tiongkok.

Penelitian lain yang dilakukan oleh Satria et al. (2020) di wilayah Taman Nasional Bukit Duabelas, Jambi, Indonesia, juga menunjukkan hubungan yang signifikan antara jarak ke pemukiman dan kebakaran hutan. Hasil penelitian tersebut menunjukkan bahwa semakin dekat jarak ke pemukiman, semakin tinggi risiko terjadinya kebakaran hutan. Penelitian ini menggunakan analisis data spasial dan metode Regresi Logistik untuk menganalisis faktor-faktor yang mempengaruhi kebakaran hutan.

4.3.1.4 Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR)

Pada tahap ini (Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR)), menjadi variabel $4 = 1 \times 4$ diperlukan data spasial jaringan jalan


sesuai lokasi penelitian, data tersebut dapat di peroleh dari website Badan Informasi Geospasial (BIG) pada link: <https://tanahair.indonesia.go.id/portal-web>, sehingga diperoleh data "jalan.shp".

Selanjutnya dilakukan analisis data spasial yaitu "*buffering*" sejauh +/- 800 meter pada sisi kiri dan kanan jalan dengan menggunakan software pemetaan untuk mendapatkan area dengan jarak tertentu dari jalan dengan output 4 klasifikasi score.

Berdasarkan hasil analisis diperoleh klasifikasi data Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR) yang disajikan pada Tabel 5.14 dan Gambar 4.20 sebagai berikut:

Tabel 4.15 Klasifikasi Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR) dan skor label

No	Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR) (Mtr)	Score label	Luas (Ha)	Persentase (%)
1	0 - 832,6	1		
2	832,6 - 2043,7	2		
3	2043,7 - 3860,3	3		
4	3860,3 - ∞	4		
Total				



Gambar 4.20 Peta hasil analisis Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR)

Pada tahap ini, dilakukan pengukuran jarak antara kejadian kebakaran dengan jaringan jalan yang ada di lokasi penelitian, yang kemudian menjadi variabel 4 (v4) dengan nama Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR). Untuk memperoleh data jaringan jalan, dapat diperoleh dari website Badan Informasi Geospasial (BIG) pada link: <https://tanahair.indonesia.go.id/portal-web>, dengan format data berupa file "jalan.shp". Selanjutnya dilakukan analisis data spasial dengan melakukan buffering sejauh +/- 800 meter pada sisi kiri dan kanan jalan menggunakan software pemetaan untuk mendapatkan area dengan jarak tertentu dari jalan, dengan output 4 klasifikasi score. Berdasarkan hasil analisis, diperoleh klasifikasi data Jarak Kejadian Kebakaran dengan Jalan/Distance to Road (DR) yang disajikan pada Tabel 5.14 dan Gambar 4.20.

Beberapa literatur dan hasil penelitian menunjukkan adanya hubungan antara jarak kejadian kebakaran dengan jalan atau distance to road (DR) dengan kebakaran hutan. Studi yang dilakukan oleh Ribeiro et al. (2018) di Brasil menemukan bahwa kebakaran hutan lebih cenderung terjadi di area

dengan jarak yang lebih dekat dengan jalan. Hal ini disebabkan oleh adanya aksesibilitas yang lebih mudah untuk mengakses kawasan hutan yang berdekatan dengan jalan sehingga meningkatkan risiko kebakaran hutan.

Penelitian yang dilakukan oleh Koutsias et al. (2012) di Yunani juga menunjukkan hasil yang serupa, yaitu bahwa jarak kejadian kebakaran dengan jalan berpengaruh signifikan terhadap risiko kebakaran hutan. Hasil penelitian tersebut menunjukkan bahwa kebakaran hutan cenderung lebih sering terjadi di area dengan jarak yang lebih dekat dengan jalan.

4.3.1.5 Kejadian Kebakaran Hutan/Historical Fire (HiF)

Data kejadian kebakaran (variabel 5 = v5) hutan yang diperoleh dari website <https://dibi.bnpb.go.id/> dengan kurun waktu kejadian tahun 2018-2021 diperoleh sebanyak 104 data ditampilkan pada Tabel 4.16.

Pada data tersebut informasi yang diperoleh ada beberapa variable yaitu: Identitas, Kategori, Latitude, Longitude, Tanggal, Sumber, Bencana, Provinsi, Kab/Kota, Keterangan, Kerusakan Lain dan Luas (Ha).

Dengan adanya informasi koordinat (Latitude dan Longitude) dilakukan analisis lanjutan dengan software pemetaan untuk menampilkan lokasi kejadian kebakaran hutan sehingga mempermudah visualisasi yang ditampilkan pada Gambar 4.21 dan Gambar 4.22 dan analisis lanjutan yang diperlukan dalam pembuatan model machine learning.


Tabel 4.16 Data Kejadian Kebakaran Hutan di wilayah penelitian periode tahun 2018-2021

No	Identitas	Kejadian	Latitude	Longitude	Tanggal	Sumber	Bencana	Provinsi	Kab/Kota	Keterangan	Kerusakan Lain	(Ha)
1	6201107201806140	Kebakaran Hutan dan Lahan	-2,78118	111,87884	14/06/2018	DamdimBpk. Roni Via Tlp(081213605999)	107. Kebakaran Hutan dan Lahan	Kalimantan Tengah	6201. KOTAWARINGIN BARAT	-	Kebun	2
2	6201107201805120	Kebakaran Hutan dan Lahan	-2,92494	111,87818	12/05/2018	BPBD Prov. Kalteng. Bpk. Japalmen Rajagukguk. (Srv. Pusdalops). Via Tlp. (0812-5151-0110).	107. Kebakaran Hutan dan Lahan	Kalimantan Tengah	6201. KOTAWARINGIN BARAT	-	Tidak ada	


104	6201107202202130	Kebakaran Hutan dan Lahan	-3.00360	111.56300	2/13/2022	BPBD Kab. KOTAWARINGIN BARAT	107. Kebakaran Hutan dan Lahan	Kalimantan Tengah	6201. KOTAWARINGIN BARAT	Desa Teluk Bogam Kec. Kumai Kab. Kotawaringin Barat	Tidak ada	0

Pada tahap ini dilakukan pengumpulan data kejadian kebakaran hutan (HiF) yang diperoleh dari website <https://dibi.bnpb.go.id/> dengan periode tahun 2018-2021 sebanyak 104 data. Data tersebut memuat informasi seperti identitas, kategori, lokasi (latitude dan longitude), tanggal kejadian, sumber, provinsi, kabupaten/kota, keterangan, kerusakan lain, dan luas terdampak. Informasi lokasi tersebut digunakan untuk melakukan analisis lanjutan dengan software pemetaan dan memvisualisasikan lokasi kejadian kebakaran hutan pada Gambar 4.21 dan Gambar 4.22. Data kejadian kebakaran hutan ini akan menjadi salah satu variabel dalam pembuatan model machine learning untuk memprediksi kejadian kebakaran hutan di masa depan.

Berdasarkan literatur yang ada, kejadian kebakaran hutan di masa lalu (HiF) memiliki hubungan yang signifikan dengan kejadian kebakaran di masa depan. Beberapa penelitian menunjukkan bahwa wilayah yang pernah mengalami kebakaran hutan memiliki risiko yang lebih tinggi untuk mengalami kebakaran hutan kembali di masa depan, terutama dalam jangka waktu yang relatif singkat setelah kejadian HiF tersebut (Chuvieco et al., 2004; Vega-Garcia et al., 2005; Liu et al., 2013). Selain itu, penelitian juga menunjukkan bahwa faktor-faktor seperti intensitas kebakaran dan ukuran area yang terbakar di masa lalu dapat mempengaruhi risiko kebakaran di masa depan (San-Miguel-Ayanz et al., 2012).



Gambar 4.21 Data Historis Kebakaran Hutan (a)



Gambar 4.22 Data Historis Kebakaran Hutan (b)

Pada penelitian ini, dilakukan analisis terhadap data kejadian kebakaran hutan yang diperoleh dari website <https://dibi.bnpb.go.id/> dengan kurun waktu kejadian tahun 2018-2021. Data tersebut terdiri dari beberapa variabel

seperti Identitas, Kategori, Latitude, Longitude, Tanggal, Sumber, Bencana, Provinsi, Kab/Kota, Keterangan, Kerusakan Lain dan Luas (Ha). Dalam upaya untuk memperbanyak jumlah data kejadian kebakaran hutan, dilakukan metode buffering pada jarak 7,5 kilometer dari setiap titik lokasi kejadian kebakaran hutan/lahan, sehingga dihasilkan data extrapolasi seperti yang ditampilkan pada Gambar 4.23. Dari hasil analisis extrapolasi, buffer, dan overlay, dilakukan klasifikasi ulang data kejadian kebakaran hutan pada area penelitian dengan klasifikasi score baru pada rentang 1-7 yang ditampilkan pada Tabel 4.18. Klasifikasi tersebut diharapkan dapat digunakan sebagai dasar dalam pembuatan model machine learning untuk memprediksi potensi terjadinya kebakaran hutan di area penelitian.

Tabel 4.17 Klasifikasi Kejadian Kebakaran Hutan/Historical Fire (HiF) dan skor label 4 kelas

No	Klasifikasi Kejadian Kebakaran Hutan/Historical Fire (HiF) unit/(100 km ² .year)	Score label	Luas (Ha)	Persentase (%)
1	0 - 1	1		
2	1 - 2,4	2		
3	2,4 - 4,5	3		
4	4,5 - ∞	4		
Total				

Dapat dilihat pada Tabel 4.16 dan Gambar 4.21, Gambar 4.22 jumlah kejadian kebakaran hutan hanya sebanyak 7 kejadian kebakaran hutan selama kurun waktu 2018 – 2022. Hal ini akan mempengaruhi pembuatan model machine learning karena jumlah data sedikit.

Untuk memperbanyak jumlah data kejadian kebakaran hutan dilakukan extrapolasi data dengan metode buffering pada jarak 7,5


kilometer dari setiap titik lokasi kejadian kebakaran hutan/lahan, sehingga dihasilkan data seperti pada Gambar 4.23 di bawah ini.

Konsept penggunaan teknik buffer untuk mengekstrak fitur-fitur spasial dalam pengolahan citra satelit dan data spasial telah banyak digunakan dalam penelitian kebakaran hutan dan prediksi bahaya kebakaran hutan.

Sebagai contoh, penelitian oleh Liu et al. (2020) menggunakan teknik buffer pada citra satelit untuk mengekstrak fitur-fitur spasial seperti jenis lahan, topografi, dan jarak ke pemukiman untuk meningkatkan akurasi prediksi bahaya kebakaran hutan. Selain itu, penelitian oleh Lian et al. (2019) juga menggunakan teknik buffer pada data spasial untuk mengukur pengaruh faktor-faktor seperti jarak ke jalan, jarak ke sungai, dan jarak ke permukiman terhadap kejadian kebakaran hutan.

Dalam konteks pembuatan dataset machine learning, teknik buffer dapat digunakan untuk memperluas cakupan data kejadian kebakaran hutan dan meningkatkan akurasi prediksi bahaya kebakaran hutan. Penelitian oleh Qin et al. (2021) menggunakan teknik buffer pada data spasial untuk memperluas cakupan data kejadian kebakaran hutan dan membangun dataset machine learning untuk prediksi bahaya kebakaran hutan dengan akurasi yang lebih baik.

Pada Gambar 4.23 dapat dilihat bahwa setiap titik kejadian kebakaran hutan saling ter-overlay (tumpang tindih) yang dijadikan dasar dalam penentuan jumlah score kejadian kebakaran hutan pada rentang kejadian kebakaran 1-7.



Gambar 4.23 Data hasil buffer titik kejadian kebakaran hutan

Berdasarkan hasil analisis extrapolasi, buffer dan overlay diperoleh klasifikasi data Kejadian Kebakaran Hutan/ Historical Fire (HiF) pad area penelitian dengan klasifikasi score baru pada rentang 1-7 ditampilkan pada Tabel 4.18 sebagai berikut:

Tabel 4.18 Klasifikasi Kejadian Kebakaran Hutan/ Historical Fire (HiF) dan skor label 7 kelas

No	Re-Klasifikasi Kejadian Kebakaran Hutan/ Historical Fire (HiF) unit/(100 km ² .year)	Score label	Luas (Ha)	Persentase (%)
1	0 - 1	1		
2	> 1 - 2	2		
3	> 2 - 3	3		
4	> 4 - 5	4		
5	> 5 - 6	5		
6	> 6 - 7	6		
7	> 7 - ∞	7		

Penelitian yang berjudul "Predicting Forest Fires Using Machine Learning: A Case Study in Galicia, Spain" oleh Perez-Guerrero et al. (2018) menggunakan metode buffer untuk menentukan area lingkungan terdekat dari lokasi kebakaran hutan dan menghitung sejumlah variabel yang berkaitan dengan faktor risiko kebakaran seperti curah hujan, topografi, jenis tanah, dan jarak ke jalan. Penelitian ini juga memanfaatkan data kejadian kebakaran historis dan berbagai data satelit untuk membuat model prediksi kebakaran hutan dengan menggunakan algoritma Random Forest. Hasil penelitian menunjukkan bahwa penggunaan model machine learning dengan input data yang tepat dapat membantu memprediksi potensi kebakaran hutan di masa depan dengan akurasi yang tinggi.

4.3.2 Faktor Fisik Lingkungan/*Physical-Environmental Factors*


4.3.2.1 Material atau Bahan yang dapat terbakar dan tersedia di hutan/Fuel

Data fuel (variabel 6 = v_6) diperoleh berdasarkan citra satelit Sentinel 2, setelah data diperoleh lalu dilakukan analisis citra dengan software pemetaan untuk mendapatkan jenis tanaman yang ada di area penelitian.

Berdasarkan hasil analisis diperoleh klasifikasi data fuel pada Tabel 4.19 dan sebaran secara geografis pada Gambar 4.24 sebagai berikut:

Tabel 4.19 Klasifikasi Material atau Bahan yang dapat terbakar dan tersedia di hutan/Fuel Load dan skor label

No	Material atau Bahan yang dapat terbakar dan tersedia di hutan/Fuel Load (t/km^2)	Score label	Luas (Ha)	Persentase (%)
1	0 - 1	1		
2	1 - 13	2		
3	13 - 23,3	3		
4	23,3 - ∞	4		
Total				



Gambar 4.24 Peta hasil analisis material atau bahan yang dapat terbakar dan tersedia di hutan/*Fuel Load*

Bahan atau material yang dapat terbakar dan tersedia di hutan atau yang biasa disebut dengan istilah "fuel" merupakan faktor fisik lingkungan yang mempengaruhi kebakaran hutan. Beberapa penelitian menunjukkan bahwa kondisi bahan atau material yang dapat terbakar di hutan memengaruhi kejadian kebakaran hutan. Misalnya, penelitian yang dilakukan oleh Yebra et al. (2013) menunjukkan bahwa tingkat kebakaran hutan meningkat ketika jumlah dan densitas material atau bahan yang dapat terbakar meningkat.

Penelitian lainnya yang dilakukan oleh Pausas dan Keeley (2014) menunjukkan bahwa beberapa jenis bahan atau material yang dapat terbakar, seperti semak dan semak belukar, memiliki kemampuan untuk menopang api dan meningkatkan intensitas kebakaran hutan. Selain itu, penelitian juga menunjukkan bahwa ketersediaan bahan atau material yang dapat terbakar di hutan dipengaruhi oleh berbagai faktor, seperti iklim, topografi, dan jenis tanaman.

Jenis fuel atau bahan yang dapat terbakar yang tersedia di hutan merupakan faktor penting dalam kebakaran hutan. Beberapa penelitian sebelumnya telah mengidentifikasi jenis-jenis fuel yang berkontribusi pada kebakaran hutan. Misalnya, penelitian di hutan tropis di Brasil menunjukkan bahwa jenis-jenis fuel seperti dedaunan, kayu mati, dan serasah merupakan sumber bahan bakar yang signifikan dalam kebakaran hutan (Cochrane et al., 1999). Di hutan Amerika Utara, jenis-jenis fuel seperti semak belukar dan rumput kering juga diketahui berkontribusi pada kebakaran hutan (Schoennagel et al., 2017).

4.3.2.2 Indeks Vegetasi/ *Normalized Difference Vegetation Index* (NDVI)

Data NDVI (variabel 7 = v7) diperoleh dengan mendownload citra satelit Sentinel 2 di website USGS (<https://earthexplorer.usgs.gov/>), setelah data diperoleh lalu dilakukan analisis NDVI dengan software pemetaan untuk mendapatkan rentang nilai NDVI di area penelitian.

Nilai NDVI mempunyai rentang antara -1 (minus) hingga 1 (positif). Nilai yang mewakili vegetasi berada pada rentang 0.1 hingga 0.7, jika nilai NDVI di atas nilai ini menunjukkan tingkat kesehatan dari tutupan vegetasi yang lebih baik. Rentang nilai kisaran NDVI lebih lengkap dapat dilihat pada Tabel 4.20 di bawah ini. Nilai NDVI diperoleh dari perhitungan:

$$NDVI = \frac{(pNir - pRed)}{(pNir + pRed)} \quad (10)$$

Tabel 4.20 Rentang Nilai NDVI [107]


Kelas	Tingkat Lerapatan	Kisaran Nilai NDVI
1	Lahan Tidak Bervegetasi	-1 – 0,12
2	Vegetasi sangat rendah	0,12 – 0,22
3	Vegetasi rendah	0,22 – 0,42
4	Vegetasi sedang	0,42 – 0,72
5	Vegetasi tinggi	0,72 - 1

Berdasarkan hasil analisis diperoleh rentang nilai, klasifikasi dan score NDVI pada lokasi penelitian pada Tabel 4.21 dan ditampilkan pada Gambar 4.26 dan Gambar 4.27 sebagai berikut:


Tabel 4.21 Klasifikasi nilai NDVI

Nilai NDVI	Kelas	Score label	Luas (Ha)	Persentase (%)
-1 – 0,12	Lahan Tidak Bervegetasi	1	1.166,98	0,83
0,12 – 0,22	Vegetasi sangat rendah	2	564,30	0,40
0,22 – 0,42	Vegetasi rendah	3	3.643,34	2,59
0,42 – 0,72	Vegetasi sedang	4	45.253,67	32,18
0,72 – 1	Vegetasi tinggi	5	89.993,80	64,00
Total			140.622,10	100,00


Sebaran Nilai NDVI berdasarkan citra satelit Sentinel 2 dan hasil perhitungan NDVI diperoleh nilai NDVI terendah adalah -0,29 dan nilai NDVI tertinggi adalah 0,89 seperti tampil pada Gambar 4.25. Persebaran nilai NDVI berdasarkan klasifikasi kelas vegetasi menunjukkan bahwa sebagian besar tutupan lahan berupa vegetasi tinggi seluas 89.993,80 hektar atau 64%, dan yang terkecil berupa vegetasi sangat rendah seluas 564,30 hektar atau 0,40% dari total luasan wilayah penelitian. Kelas 1 sampai dengan 2 merupakan area yang tidak bervegetasi seperti badan air, pemukiman dan lahan kosong, sedangkan kelas 3 merupakan kelas vegetasi rendah seperti semak belukar padang rumput, kelas 4 vegetasi sedang seperti sawah atau pertanian, dan kelas 5 merupakan vegetasi tinggi seperti perkebunan dan hutan. Selanjutnya, berdasarkan perhitungan NDVI ini, digunakan sebagai dasar analisis lanjutan untuk mendapatkan kelas vegetasi Jenis Vegetasi/Vegetation Type.



Gambar 4.25 Citra NDVI dan sebaran nilai NDVI (terendah – tertinggi)



Gambar 4.26 Peta hasil analisis reklasifikasi nilai NDVI menjadi 4 kriteria



Gambar 4.27 Peta hasil nilai NDVI berdasarkan 4 kriteria

Data NDVI (Normalized Difference Vegetation Index) digunakan untuk mengukur tingkat kehijauan dari suatu wilayah dengan rentang nilai antara -1 hingga 1. Nilai yang mewakili vegetasi berada pada rentang 0.1 hingga 0.7, jika nilai NDVI di atas nilai ini menunjukkan tingkat kesehatan dari tutupan vegetasi yang lebih baik. Rentang nilai kisaran NDVI lebih lengkap dapat dilihat pada tabel yang disajikan. Pada penelitian ini, nilai NDVI diperoleh dengan mengunduh citra satelit Sentinel 2 di website USGS dan dilakukan analisis NDVI dengan software pemetaan untuk mendapatkan rentang nilai NDVI di area penelitian. Berdasarkan hasil analisis, diperoleh rentang nilai, klasifikasi, dan score NDVI pada lokasi penelitian. Sebagian besar tutupan lahan berupa vegetasi tinggi seluas 89.993,80 hektar atau 64%, dan yang terkecil berupa vegetasi sangat rendah seluas 564,30 hektar atau 0,40% dari total luasan wilayah penelitian. Kelas NDVI digunakan sebagai dasar analisis lanjutan untuk mendapatkan kelas vegetasi Jenis Vegetasi/Vegetation Type. Perhitungan NDVI ini menjadi penting dalam mengevaluasi kesehatan tutupan vegetasi di suatu wilayah dan membantu dalam identifikasi tingkat kerentanan terhadap kebakaran hutan.

Indeks Vegetasi atau Normalized Difference Vegetation Index (NDVI) dapat digunakan sebagai indikator untuk memonitor kondisi vegetasi dan juga memprediksi potensi kebakaran hutan. Sebuah penelitian yang dilakukan oleh Kuswanto dan Sari (2019) di Kecamatan Kalianda, Lampung menunjukkan bahwa terdapat korelasi negatif antara nilai NDVI dan kejadian kebakaran hutan. Artinya, semakin rendah nilai NDVI, maka semakin tinggi potensi kebakaran hutan. Hasil penelitian ini juga menunjukkan bahwa NDVI dapat digunakan sebagai alat untuk memetakan daerah dengan potensi risiko kebakaran hutan yang tinggi.

4.3.2.3 Jenis Vegetasi/*Vegetation Type*

Data Jenis Vegetasi (variabel 8 = v8) diperoleh dari website Badan Informasi Geospasial (BIG) pada link: <https://tanahair.indonesia.go.id/portal-web>, setelah data diperoleh lalu dilakukan analisis dengan menggunakan software pemetaan untuk mengetahui attribute table jenis vegetasi di area penelitian.

Berdasarkan hasil analisis diperoleh jenis vegetasi pada Tabel 4.22 sebagai berikut:

Tabel 4.22 Klasifikasi Jenis Vegetasi dan skor label

No	Jenis Vegetasi	Score label	Luas (Ha)	Persentase (%)
1	Desert, Swamp, Cultivated plants	1		
2	Meadow, Grassland, Alpine vegetation	2		
3	Broad-leaved forest, Shrub	3		
4	Coniferous forest, theropencedrymion	4		
Total			140.622,10	100,00


Berdasarkan hasil perhitungan NDVI dan Tabel 4.22 Kelas 1 sampai dengan 2 merupakan area yang tidak bervegetasi seperti badan air, pemukiman dan lahan kosong, sedangkan kelas 3 merupakan kelas vegetasi rendah seperti semak belukar padang rumput, kelas 4 vegetasi sedang seperti sawah atau pertanian, dan kelas 5 merupakan vegetasi tinggi seperti perkebunan dan hutan yang divisualisasikan pada Gambar 4.28.

Data Jenis Vegetasi atau Vegetation Type diperoleh dari website Badan Informasi Geospasial (BIG) dan dianalisis dengan menggunakan software pemetaan untuk mengetahui attribute table jenis vegetasi di area penelitian. Berdasarkan hasil analisis, ditemukan jenis vegetasi yang terdiri dari 4 klasifikasi dengan skor label yang terkait. Klasifikasi tersebut adalah: 1) Desert, Swamp, Cultivated plants dengan skor label 1, 2) Meadow, Grassland, Alpine vegetation dengan skor label 2, 3) Broad-leaved forest, Shrub dengan skor label 3, dan 4) Coniferous forest, theropencedrymion dengan skor label 4. Informasi mengenai jenis vegetasi ini akan digunakan sebagai dasar analisis lanjutan terkait dengan faktor penyebab kebakaran hutan pada wilayah penelitian.

Penelitian oleh Suroto et al. (2020) menunjukkan bahwa jenis vegetasi mempengaruhi kebakaran hutan di Taman Nasional Baluran, Jawa Timur. Hasil penelitian menunjukkan bahwa kebakaran hutan di area tersebut cenderung terjadi pada vegetasi jenis Semak Belukar dan Sabana yang memiliki tingkat kelembaban yang lebih rendah dibandingkan dengan vegetasi hutan yang lebih lebat. Selain itu, vegetasi semak belukar dan sabana juga memiliki kandungan bahan bakar yang lebih mudah terbakar.

Tabel 4.23 Klasifikasi Curah Hujan/*Precipitation* dan skor label

No	Curah Hujan/ <i>Precipitation</i> (mm)	Score label	Luas (Ha)	Persentase (%)
1	0 - 173,1	1		
2	173,1 - 195,1	2		
3	195,1 - 209,6	3		
4	209,6 - ∞	4		
Total				

Gambar 4.29 Peta hasil analisis curah hujan/*precipitation* berdasarkan 4 kriteria

Berdasarkan data BMKG dan hasil analisis, di wilayah penelitian hanya terdapat 1 kriteria Curah Hujan/*Precipitation* yaitu dengan nilai curah hujan > 1.700 mm/tahun.

Data curah hujan (variabel 9) merupakan salah satu faktor yang berpengaruh pada kebakaran hutan. Semakin tinggi curah hujan di suatu daerah, semakin kecil kemungkinan terjadi kebakaran hutan karena kelembaban di lingkungan akan lebih tinggi. Sebaliknya, semakin rendah curah hujan, kemungkinan terjadi kebakaran hutan akan semakin besar karena kelembaban di lingkungan akan semakin rendah.

Pada penelitian ini, data curah hujan diperoleh dari website BMKG dan dilakukan analisis overlay dengan menggunakan software pemetaan untuk mengetahui nilai curah hujan di area penelitian. Berdasarkan hasil analisis, curah hujan pada area penelitian dibagi ke dalam 4 kategori dengan skor label dari 1 hingga 4. Kategori dengan skor label 1 menunjukkan daerah dengan curah hujan paling rendah, sedangkan kategori dengan skor label 4 menunjukkan daerah dengan curah hujan paling tinggi.

Hasil analisis curah hujan pada penelitian ini dapat membantu dalam menentukan faktor penyebab kebakaran hutan di area penelitian. Selain itu, data curah hujan juga dapat digunakan sebagai acuan untuk melakukan prediksi terhadap kemungkinan terjadinya kebakaran hutan di masa depan. Curah hujan atau precipitation adalah salah satu faktor lingkungan yang mempengaruhi terjadinya kebakaran hutan. Penelitian oleh Kurnia et al. (2020) menunjukkan bahwa curah hujan yang rendah meningkatkan risiko terjadinya kebakaran hutan di Indonesia. Penelitian tersebut juga menemukan bahwa periode curah hujan yang pendek dan intensitas hujan yang tinggi dapat meningkatkan risiko terjadinya kebakaran hutan.

4.3.2.5 Penggunaan Lahan (*Land Usage*)


Data penggunaan lahan (variabel 10 = v_{10}) diperoleh dari website Badan Informasi Geospasial (BIG) pada link: <https://tanahair.indonesia.go.id/portal-web>, setelah data diperoleh selanjutnya dilakukan analisis dengan menggunakan software pemetaan untuk mengetahui attribute table penggunaan lahan di area penelitian.

Berdasarkan hasil analisis diperoleh jenis dan variasi penggunaan lahan pada Tabel 4.24 dan divisualisasikan pada Gambar 4.30 sebagai berikut:

Tabel 4.24 Klasifikasi Jenis Vegetasi dan skor label

No	Jenis Vegetasi	Score label	Luas (Ha)	Persentase (%)
1	Paddy field, Dry land, Water area, Unused land, Urban-rural fringe, Industrial and mining	1		
2	Meadow, Grassland, Alpine vegetation	2		
3	Broad-leaved forest, Shrub	3		
4	Coniferous forest, Theropencedrymion	4		
Total			140.622,10	100,00

Penggunaan lahan atau land usage dapat mempengaruhi risiko terjadinya kebakaran hutan. Data penggunaan lahan (variabel 10) dalam penelitian ini diperoleh dari website Badan Informasi Geospasial (BIG) dan dianalisis menggunakan software pemetaan untuk mengetahui variasi penggunaan lahan di area penelitian. Berdasarkan hasil analisis, diperoleh jenis dan variasi penggunaan lahan yang terdiri dari Paddy field, Dry land, Water area, Unused land, Urban-rural fringe, Industrial and mining, Meadow, Grassland, Alpine vegetation, Broad-leaved forest, Shrub, dan Coniferous forest, Theropencedrymion. Analisis penggunaan lahan ini dapat membantu untuk memahami kondisi lahan yang berpotensi terkena kebakaran hutan, misalnya penggunaan lahan yang tidak terawat atau lahan yang terlalu kering dapat meningkatkan risiko terjadinya kebakaran hutan.



Gambar 4.30 Peta hasil analisis penggunaan lahan (*land usage*) berdasarkan 4 kriteria

Penggunaan lahan dapat menjadi faktor penting dalam kebakaran hutan. Beberapa penelitian menunjukkan bahwa lahan pertanian, perkebunan, dan hutan tanaman dapat meningkatkan risiko kebakaran hutan karena pengelolaan yang tidak tepat seperti pembakaran lahan dan penggunaan api terbuka. Sedangkan, lahan yang tidak terpakai atau terlantar dapat meningkatkan risiko kebakaran karena kepadatan material yang mudah terbakar seperti dedaunan dan kayu kering. Salah satu contoh penelitian yang membahas faktor penggunaan lahan terhadap kebakaran hutan adalah penelitian yang dilakukan oleh Sitorus et al. (2018) di Kabupaten Deli Serdang, Sumatera Utara. Hasil penelitian tersebut menunjukkan bahwa kebakaran hutan di daerah tersebut terkait dengan aktivitas manusia seperti pembakaran lahan pertanian dan perkebunan.

4.3.2.6 Temperatur/Temperature

Data temperature (variabel 11 = *v11*) diperoleh dari website BMKG pada link: <https://dataonline.bmkg.go.id/home>, setelah data diperoleh lalu

dilakukan analisis overlay dengan menggunakan software pemetaan untuk mengetahui nilai temperature di area penelitian.

Berdasarkan hasil analisis diperoleh nilai temperature pada Tabel 4.25 dan divisualisasikan pada Gambar 4.31 sebagai berikut:


Tabel 4.25 Klasifikasi Temperatur/Temperature dan skor label

No	Temperatur/Temperature ($^{\circ}\text{C}$)	Score label	Luas (Ha)	Persentase (%)
1	0 - 19,9	1		
2	19,9 - 21,5	2		
3	21,5 - 22,8	3		
4	22,8 - ∞	4		
Total				

Data temperatur atau suhu (variabel 11 = v11) dalam penelitian ini diperoleh dari website BMKG. Data tersebut kemudian diolah dan dianalisis menggunakan software pemetaan untuk mengetahui nilai suhu di area penelitian. Berdasarkan hasil analisis, nilai suhu kemudian diklasifikasikan menjadi empat kategori, yaitu suhu 0-19,9 $^{\circ}\text{C}$ (skor label 1), suhu 19,9-21,5 $^{\circ}\text{C}$ (skor label 2), suhu 21,5-22,8 $^{\circ}\text{C}$ (skor label 3), dan suhu di atas 22,8 $^{\circ}\text{C}$ (skor label 4).

Temperatur memiliki peran penting dalam kebakaran hutan karena suhu yang tinggi dapat meningkatkan kekeringan pada tumbuhan dan tanah, sehingga meningkatkan risiko terjadinya kebakaran. Beberapa penelitian sebelumnya menunjukkan bahwa suhu mempengaruhi terjadinya kebakaran hutan. Contohnya, penelitian yang dilakukan oleh Huang et al. (2015) di Amerika Serikat menunjukkan bahwa peningkatan suhu yang diakibatkan oleh perubahan iklim dapat meningkatkan frekuensi dan intensitas kebakaran hutan. Begitu juga dengan penelitian yang dilakukan oleh Wiryono et al.

(2018) di Kabupaten Bandung, Indonesia, yang menemukan adanya hubungan positif antara suhu dan kebakaran hutan di wilayah tersebut. Oleh karena itu, variabel suhu atau temperatur perlu diperhitungkan dalam analisis faktor risiko kebakaran hutan.



Gambar 4.31 Peta hasil analisis temperatur/temperature berdasarkan 4 kriteria

Berdasarkan data BMKG dan hasil analisis, di wilayah penelitian hanya terdapat 1 kriteria Temperatur/Temperature yaitu dengan nilai rata-rata suhu $22,8^{\circ}\text{C}$.

Temperatur tinggi merupakan salah satu faktor yang mempengaruhi terjadinya kebakaran hutan. Dalam penelitian yang dilakukan oleh Prayitno et al. (2019), ditemukan bahwa temperatur yang tinggi berkontribusi pada peningkatan risiko kebakaran hutan di kawasan hutan Lindung Gunung Merbabu, Indonesia. Penelitian lain yang dilakukan oleh Setiawan et al. (2020) juga menunjukkan bahwa suhu udara yang tinggi berhubungan positif dengan tingkat kebakaran hutan di Jawa Tengah, Indonesia.

4.3.2.7 Ketinggian/Elevation

Data ketinggian/elevasi (variabel $12 = v12$) diperoleh dari citra *Digital Elevation Model* (DEM) website BIG pada link: <https://tanahair.indonesia.go.id/demnas/#/>, setelah data diperoleh lalu dilakukan analisis dengan menggunakan software pemetaan untuk mengetahui sebaran nilai ketinggian/elevasi di area penelitian.


Berdasarkan hasil analisis diperoleh sebaran nilai ketinggian/elevasi pada Tabel 4.26 sebagai berikut:

Tabel 4.26 Klasifikasi ketinggian/elevasi dan skor label

Nilai Elevasi	Score label	Luas (Ha)	Persentase (%)
-34 – 0	1	123,76	0,08
0 – 55	2	140.538,34	99,91
Total		140.662,10	100


Hasil analisis citra DEM dan divisualisasikan pada Gambar 4.32, diperoleh nilai elevasi terendah adalah -34 dan nilai elevasi tertinggi adalah 55 mdpl. Persebaran nilai elevasi berdasarkan ketinggian menunjukkan bahwa sebagian besar lahan berada pada elevasi 0-55 mdpl seluas 140.538,34 hektar atau 99,91% dan sisanya areal dengan elevasi -34-0 mdpl seluas 123,76 hektar atau 0,08%.

Berdasarkan penjelasan di atas, dapat kita lihat sebaran elevasi pada areal penelitian hanya terdapat 2 kriteria yaitu 0 dan 1 yang ditampilkan pada Gambar 4.33 dan selanjutnya dimasukkan ke dalam kriteria score 1 dan 2 yang ditampilkan pada Gambar 4.34.




Gambar 4.32 Citra DEM dan sebaran nilai ketinggian/elevation (terendah – tertinggi)

Ketinggian atau elevasi (variabel 12 = v12) adalah faktor penting dalam penentuan kebakaran hutan karena dapat mempengaruhi suhu dan kelembaban di suatu daerah. Menurut penelitian sebelumnya, ketinggian dapat memengaruhi kemunculan kebakaran hutan dengan cara yang berbeda-beda tergantung pada faktor-faktor lingkungan lainnya. Misalnya, beberapa penelitian menunjukkan bahwa daerah dengan ketinggian yang lebih tinggi cenderung memiliki tingkat kebakaran yang lebih rendah karena suhu dan kelembaban yang lebih rendah, sementara daerah dengan ketinggian yang lebih rendah cenderung memiliki tingkat kebakaran yang lebih tinggi karena kelembaban yang lebih rendah. Namun, ada juga penelitian yang menunjukkan tidak ada korelasi yang jelas antara ketinggian dan kebakaran hutan.



Gambar 4.33 Peta hasil analisis reklasifikasi nilai ketinggian/elevation menjadi 4 kriteria



Gambar 4.34 Peta hasil nilai ketinggian/elevation berdasarkan 4 kriteria

4.3.2.8 Lereng/Slope

Data lereng/slope (variabel 13 = v13) diperoleh dari citra *Digital Elevation Model* (DEM) website BIG pada link: <https://tanahair.indonesia.go.id/demnas/#/>, setelah data diperoleh lalu dilakukan analisis dengan menggunakan software pemetaan untuk mengetahui kemiringan lereng (%) di area penelitian.

Tahapan analisis yang dilakukan adalah:

- Reklasifikasi/reclass menjadi 5 kriteria ditampilkan pada Gambar 4.35.
- Mengkonversi data Raster ke Polygon (menjadi data vector) ditampilkan pada Gambar 4.36.
- Menghitung luasan area Calculate area (Hektar) ditampilkan pada Gambar 4.37.
- Menambah 1 kolom pada attribute table untuk lebl score

Berdasarkan hasil analisis diperoleh nilai kemiringan lereng (%) pada Tabel 4.27 sebagai berikut:

Tabel 4.27 Rentang nilai kelerengan/slope

Kelas	Kemiringan (%)	Klasifikasi
I	0-8	Datar
II	> 8 - 15	Landai
III	> 15 - 25	Agar Curam
IV	> 25 - 45	Curam
V	> 45	Sangat Curam

Tabel 4.28 Klasifikasi kelereng/slope dan skor label


Kemiringan (%)	Kelas	Score label	Luas (Ha)	Persentase (%)
0-8	I	1	139.235,33	98,99
> 8 - 15	II	2	1.369,72	0,97
> 15 - 25	III	3	55,64	0,04
> 25 - 45	IV	4	1,39	0,0 ^{9,935}
> 45	V	5	0	0
Total			140.622,10	100,00

Hasil analisis citra DEM ditampilkan pada Tabel 4.28 dan Gambar 4.35, diperoleh nilai kemiringan (%) terendah adalah 0 dan nilai elevasi tertinggi adalah 31.727. Persebaran nilai kelereng/slope berdasarkan % lereng/slope menunjukkan bahwa 98,99% lahan berada pada kemiringan 0-8 % seluas 139.235,33 hektar atau 99,91%, kemiringan lereng kelas II yaitu 18-15% seluas 1.369,72 hektar atau 0,97%, kelas lereng IV yaitu 25-45% seluas 1,39 hektar atau 0,0^{9,935} %, dan untuk kelas V di areal penelitian tidak ditemukan.


Data lereng/slope merupakan salah satu variabel yang penting dalam mengevaluasi potensi terjadinya kebakaran hutan. Kemiringan lereng dapat mempengaruhi kecepatan pergerakan api, karena semakin curam kemiringan lereng, maka semakin cepat api dapat menyebar ke area yang lebih luas. Berdasarkan hasil analisis pada area penelitian, dapat dilihat bahwa sebagian besar lahan memiliki kemiringan lereng yang datar hingga landai, dengan persentase luas lahan mencapai 98,99% pada kelas I (0-8% kemiringan) dan 0,97% pada kelas II (>8-15% kemiringan). Sedangkan untuk kemiringan lereng yang lebih curam, yaitu pada kelas III (15-25% kemiringan) dan kelas IV (25-45% kemiringan), hanya masing-masing 0,04% dan 0,09% dari total luas lahan yang ada di area penelitian. Pada kelas V (>45% kemiringan), tidak ditemukan lahan yang memenuhi kriteria. Oleh karena itu, dapat

disimpulkan bahwa area penelitian cenderung memiliki kemiringan lereng yang datar hingga landai, sehingga potensi terjadinya kebakaran hutan akibat kemiringan lereng yang curam cukup rendah.

Tingkat kemiringan lereng atau slope diketahui menjadi salah satu faktor yang mempengaruhi kejadian kebakaran hutan. Menurut penelitian yang dilakukan oleh Kobziar et al. (2019) di California, Amerika Serikat, terdapat korelasi yang signifikan antara kemiringan lereng dan kejadian kebakaran hutan. Hasil penelitian tersebut menunjukkan bahwa area dengan kemiringan lereng yang lebih curam memiliki risiko lebih tinggi untuk terkena kebakaran hutan. Hal ini disebabkan karena kemiringan lereng yang curam cenderung lebih sulit untuk diakses dan sulit untuk dilakukan pemadaman saat terjadi kebakaran.



Gambar 4.35 Citra DEM dan sebaran nilai lereng/slope (terendah – tertinggi)



Gambar 4.36 Peta hasil analisis reklasifikasi nilai lereng/slope menjadi 4 kriteria



Gambar 4.37 Peta hasil nilai lereng/slope berdasarkan 4 kriteria

4.3.2.9 Arah Lereng/Aspect

Data arah lereng/aspect (variabel 15 = v15) diperoleh dari citra *Digital Elevation Model* (DEM) website BIG pada link: <https://tanahair.indonesia.go.id/demnas/#/>, setelah data diperoleh lalu dilakukan analisis dengan menggunakan software pemetaan untuk mengetahui arah lereng dengan klasifikasi sebagai berikut:

- Reklasifikasi/reclass menjadi 6 kriteria ditampilkan pada Gambar 4.40.
- Mengkonversi data Raster ke Polygon (menjadi data vector) ditampilkan pada Gambar 4.41.
- Menghitung luasan area Calculate area (Hektar).
- Menambah 1 kolom pada attribute table untuk lebl score


Berdasarkan hasil analisis diperoleh nilai arah lereng/aspect pada Tabel 4.29 sebagai berikut:

Tabel 4.29 Klasifikasi arah lereng/aspect dan skor label


Arah Lereng/Aspect ($^{\circ}$)	Kelas	Score label	Luas (Ha)	Persentase (%)
0°	Flat	1	5,288.73	3.76
$0^{\circ} - 45^{\circ}$	North	2	17,170.54	12.21
$45^{\circ} - 135^{\circ}$	East	3	35,070.79	24.94
$135^{\circ} - 225^{\circ}$	South	4	34,387.58	24.45
$225^{\circ} - 315^{\circ}$	West	5	13,446.28	9.56
$315^{\circ} - 360^{\circ}$	U	6	35,266.81	25.08
	Total		140,622.10	100,00

Hasil analisis citra DEM, diperoleh nilai arah lereng/aspect ($^{\circ}$) terendah adalah -1 dan nilai tertinggi adalah 359,37 seperti tampil pada Gambar 4.38 dan untuk mempermudah pembaca melihat sisi 3 dimensi area penelitian dapat melihat Gambar 4.39 sehingga mendapatkan gambaran sebaran arah lereng.

Sebaran nilai arah lereng berdasarkan ($^{\circ}$) Flat ($-1 - 0^{\circ}$) seluas 5.288,73 hektar atau 3,76%, North ($0^{\circ} - 45^{\circ}$) seluas 17.170,54 hektar atau 12,21%, East ($45^{\circ} - 135^{\circ}$) seluas 35.070,79 hektar atau 24,94%, South ($135^{\circ} - 225^{\circ}$) seluas 34.381,58 hektar atau 24,45 %, West ($225^{\circ} - 315^{\circ}$) seluas 13.446,28 hektar atau 9,56%, dan U ($315^{\circ} - 360^{\circ}$) seluas 35.226,81 hektar atau 25,08%.



Gambar 4.38 Citra DEM dan sebaran nilai arah lereng/aspect (terendah – tertinggi)




Gambar 4.39 Citra DEM dan sebaran nilai arah lereng/aspect (terendah – tertinggi) warna grayscale


Data arah lereng/aspect adalah salah satu faktor yang dapat mempengaruhi kebakaran hutan. Untuk menganalisis arah lereng/aspect pada area penelitian, digunakan citra Digital Elevation Model (DEM) dari website Badan Informasi Geospasial (BIG). Setelah data diperoleh, dilakukan analisis dengan menggunakan software pemetaan untuk mengklasifikasikan arah lereng menjadi enam kriteria, yaitu Flat, North, East, South, West, dan U. Hasil analisis menunjukkan bahwa luasan area yang memiliki arah lereng/aspect Flat (0° - 1°) sebesar 5.288,73 hektar atau 3,76%, North (0° - 45°) sebesar 17.170,54 hektar atau 12,21%, East (45° - 135°) sebesar 35.070,79 hektar atau 24,94%, South (135° - 225°) sebesar 34.381,58 hektar atau 24,45%, West (225° - 315°) sebesar 13.446,28 hektar atau 9,56%, dan U (315° - 360°) sebesar 35.266,81 hektar atau 25,08%. Informasi mengenai arah lereng/aspect ini penting untuk memperkirakan risiko kebakaran hutan, karena arah lereng dapat mempengaruhi ketersediaan air dan kelembaban di suatu area, sehingga perlu dipertimbangkan dalam upaya mitigasi kebakaran hutan.

Beberapa penelitian sebelumnya menunjukkan adanya hubungan antara arah lereng/aspect dengan kebakaran hutan. Sebagai contoh, penelitian oleh Wu et al. (2013) yang dilakukan di Cina menunjukkan bahwa area-area dengan lereng menghadap ke arah barat daya dan tenggara cenderung lebih rentan terhadap kebakaran hutan. Hal ini dikaitkan dengan fakta bahwa area-area tersebut terkena sinar matahari langsung dalam waktu yang lebih lama, sehingga lebih kering dan rentan terhadap kebakaran.

Penelitian lainnya oleh Lee dan Kim (2018) di Korea Selatan juga menunjukkan hasil yang serupa, dimana area-area dengan lereng menghadap ke arah barat dan selatan cenderung lebih rentan terhadap kebakaran hutan. Hal ini disebabkan oleh kombinasi antara pengaruh arah angin dan sinar matahari yang membuat area-area tersebut lebih kering dan rentan terhadap kebakaran.



Gambar 4.40 Peta hasil analisis reklasifikasi nilai arah lereng/aspect menjadi 6 kriteria



Gambar 4.41 Peta hasil nilai nilai arah lereng/aspect menjadi 6 kriteria

4.3.3 Machine Learning

4.3.2.1 Pembangunan Model Klasifikasi Menggunakan Support Vector Machine (SVM)

Pembangunan model klasifikasi menggunakan Support Vector Machine (SVM) dapat dilakukan dengan langkah-langkah sebagai berikut:

1. Persiapan Data

Langkah pertama adalah melakukan persiapan data dengan melakukan beberapa tindakan seperti menghapus data yang hilang atau tidak relevan, membagi data menjadi dua subset yaitu data latih dan data uji, dan melakukan normalisasi data jika diperlukan.

2. Pemilihan Fitur

Setelah data siap, pemilihan fitur adalah langkah selanjutnya. Pemilihan fitur ini dilakukan dengan memilih subset fitur yang paling relevan dalam memprediksi kelas target. Beberapa teknik pemilihan fitur yang dapat digunakan adalah Information Gain, Chi-Square, dan Principal Component Analysis (PCA).

3. Pelatihan Model SVM

Setelah fitur terpilih, langkah selanjutnya adalah melakukan pelatihan model SVM dengan menggunakan data latih. Pada tahap ini, beberapa parameter SVM seperti kernel, C , dan gamma harus ditentukan dengan benar untuk memaksimalkan akurasi model.

4. Validasi Model

Setelah model SVM dilatih, langkah selanjutnya adalah melakukan validasi model dengan menggunakan data uji. Hasil prediksi model dibandingkan dengan kelas target pada data uji untuk menghitung akurasi model.

5. Tuning Parameter

Jika akurasi model belum memuaskan, tuning parameter dapat dilakukan dengan mengubah beberapa parameter SVM dan melakukan pelatihan ulang model.

6. Evaluasi Model

Setelah model SVM optimal didapatkan, evaluasi model dilakukan dengan menghitung beberapa metrik evaluasi seperti confusion matrix, precision, recall, F1-score, dan ROC curve.

7. Penggunaan Model

Terakhir, model SVM dapat digunakan untuk memprediksi kelas target pada data baru.

Dengan mengikuti langkah-langkah di atas, model klasifikasi menggunakan Support Vector Machine (SVM) dapat dibangun dengan baik dan akurasi yang tinggi dapat dicapai.

4.3.2.2 Pembangunan Model Klasifikasi Menggunakan Random Forest (RF)

Pembangunan model klasifikasi menggunakan Random Forest (RF) dapat dilakukan dengan langkah-langkah sebagai berikut:

1. Persiapan Data

Langkah pertama adalah melakukan persiapan data dengan melakukan beberapa tindakan seperti menghapus data yang hilang atau tidak relevan, membagi data menjadi dua subset yaitu data latih dan data uji, dan melakukan normalisasi data jika diperlukan.

2. Pemilihan Fitur

Setelah data siap, pemilihan fitur adalah langkah selanjutnya. Pemilihan fitur ini dilakukan dengan memilih subset fitur yang paling relevan dalam memprediksi kelas target. Beberapa teknik pemilihan fitur yang dapat digunakan adalah Information Gain, Chi-Square, dan Principal Component Analysis (PCA).

3. Pelatihan Model RF

Setelah fitur terpilih, langkah selanjutnya adalah melakukan pelatihan model RF dengan menggunakan data latih. Pada tahap ini, beberapa parameter RF seperti jumlah pohon keputusan, kedalaman pohon keputusan, dan jumlah fitur acak harus ditentukan dengan benar untuk memaksimalkan akurasi model.

4. Validasi Model

Setelah model RF dilatih, langkah selanjutnya adalah melakukan validasi model dengan menggunakan data uji. Hasil prediksi model dibandingkan dengan kelas target pada data uji untuk menghitung akurasi model.

5. Tuning Parameter

Jika akurasi model belum memuaskan, tuning parameter dapat dilakukan dengan mengubah beberapa parameter RF dan melakukan pelatihan ulang model.

6. Evaluasi Model

Setelah model RF optimal didapatkan, evaluasi model dilakukan dengan menghitung beberapa metrik evaluasi seperti confusion matrix, precision, recall, F1-score, dan ROC curve.

7. Penggunaan Model

Terakhir, model RF dapat digunakan untuk memprediksi kelas target pada data baru.

Dengan mengikuti langkah-langkah di atas, model klasifikasi menggunakan Random Forest (RF) dapat dibangun dengan baik dan akurasi yang tinggi dapat dicapai. Model ini juga dapat digunakan untuk melakukan analisis pentingnya fitur (feature importance) dalam memprediksi kelas target pada data.

4.3.2.3 Pembuatan pengujian algoritma SVM dan RF menggunakan K Fold

Pengujian algoritma SVM dan RF menggunakan K Fold dapat dilakukan dengan langkah-langkah sebagai berikut:

1. Persiapan Data

Langkah pertama adalah melakukan persiapan data dengan melakukan beberapa tindakan seperti menghapus data yang hilang atau tidak relevan, dan melakukan normalisasi data jika diperlukan. Selanjutnya, data dibagi menjadi dua subset yaitu data latih dan data uji.

2. Pemilihan Fitur

Setelah data siap, pemilihan fitur adalah langkah selanjutnya. Pemilihan fitur ini dilakukan dengan memilih subset fitur yang paling relevan dalam memprediksi kelas target. Beberapa teknik pemilihan fitur yang dapat digunakan adalah Information Gain, Chi-Square, dan Principal Component Analysis (PCA).

3. Pembuatan Model SVM dan RF

Langkah selanjutnya adalah membuat model SVM dan RF dengan menggunakan data latih. Pada tahap ini, beberapa parameter SVM dan RF seperti kernel, C, dan gamma untuk SVM, serta jumlah pohon dan kedalaman pohon untuk RF harus ditentukan dengan benar untuk memaksimalkan akurasi model. Setelah model dibuat, dilakukan pengujian dengan K Fold untuk mengevaluasi performa model.

4. K Fold Cross Validation

K Fold Cross Validation adalah teknik validasi model yang melibatkan pemisahan data menjadi k fold subset, di mana model dilatih pada k-1 subset dan diuji pada subset yang tersisa. Proses ini dilakukan sebanyak k kali dengan memvariasikan subset yang digunakan untuk pengujian. Pada akhirnya, nilai akurasi rata-rata dari semua iterasi digunakan untuk mengevaluasi performa model.

5. Evaluasi Model

Setelah melakukan K Fold Cross Validation pada model SVM dan RF, evaluasi model dilakukan dengan menghitung beberapa metrik evaluasi seperti confusion matrix, precision, recall, F1-score, dan ROC curve. Dari hasil evaluasi, dapat dianalisis apakah model SVM atau RF yang lebih baik untuk digunakan dalam memprediksi kelas target pada data yang diberikan.

Dengan mengikuti langkah-langkah di atas, dapat dilakukan pengujian algoritma SVM dan RF menggunakan K Fold Cross Validation. Hal ini akan membantu memilih model yang lebih baik dan dapat memberikan

akurasi yang lebih tinggi dalam memprediksi kelas target pada data yang diberikan.

4.4. Integrasi dan Implementasi Machine Learning ke dalam Sistem Informasi Geografis (SIG)

Sistem Informasi Geografis (SIG) adalah sistem yang digunakan untuk memetakan dan menganalisis data berbasis lokasi. SIG dapat digunakan untuk memetakan kejadian kebakaran hutan, seperti titik api, arah angin, dan kondisi cuaca di suatu wilayah.

Dalam integrasi dengan SIG, prediksi kebakaran hutan dapat ditampilkan dalam bentuk peta yang dapat memberikan informasi tentang daerah-daerah yang rentan terhadap kebakaran hutan. SIG dapat memperlihatkan faktor-faktor seperti jenis tanah, vegetasi, suhu, kelembaban udara, dan topografi yang dapat mempengaruhi terjadinya kebakaran hutan.

Dalam keseluruhan, integrasi data mining dan SIG dalam prediksi kebakaran hutan dapat membantu mempercepat respons terhadap kebakaran hutan, serta membantu pengambilan keputusan dalam penanggulangan dan pencegahan kebakaran hutan.

Data mining untuk prediksi kebakaran hutan terintegrasi dengan Sistem Informasi Geografis (SIG) merupakan suatu pendekatan yang dapat membantu mengidentifikasi pola dan hubungan antara faktor-faktor yang mempengaruhi terjadinya kebakaran hutan di masa lalu dan memprediksi kemungkinan terjadinya kebakaran hutan di masa depan.

Dalam integrasi dengan SIG, penelitian oleh Liu et al. (2019) menggunakan data mining dan SIG untuk memprediksi risiko kebakaran hutan di Kabupaten Pingnan, Provinsi Fujian, China. Hasil penelitian menunjukkan bahwa model prediksi yang dibangun mampu memperkirakan risiko kebakaran hutan dengan akurasi yang tinggi.

4.4.1. Pembangunan Back End

Pembangunan back end dapat dilakukan dengan beberapa tahap berikut:

1. Desain Database

Tahap pertama adalah merancang dan membuat struktur database yang akan digunakan dalam aplikasi. Desain database meliputi pembuatan tabel, kolom, relasi antar tabel, dan indeks. Beberapa hal yang perlu dipertimbangkan dalam desain database adalah skalabilitas, performa, dan keamanan.

2. Pembuatan Database

Setelah desain database selesai, langkah selanjutnya adalah membuat database yang akan digunakan oleh aplikasi. Database dapat dibuat menggunakan berbagai macam software database seperti MySQL, PostgreSQL, atau MongoDB.

3. Pembangunan Rest API dengan Django Framework

Setelah database selesai dibuat, langkah selanjutnya adalah membuat Rest API menggunakan Django Framework. Django adalah framework Python yang populer untuk pembuatan aplikasi web. Django menyediakan banyak fitur yang berguna seperti ORM (Object-Relational Mapping), middleware, dan sistem autentikasi.

4. Embed Algoritma

Setelah pembangunan Rest API selesai, langkah selanjutnya adalah memasukkan algoritma ke dalam aplikasi. Algoritma yang dimasukkan dapat berupa algoritma machine learning seperti SVM, Random Forest, atau Decision Tree, yang digunakan untuk memproses data pada

database. Algoritma dapat ditempatkan pada file Python terpisah dan diimpor ke dalam aplikasi.

5. Pengujian Aplikasi

Setelah aplikasi selesai dibangun, langkah terakhir adalah melakukan pengujian aplikasi. Pengujian dapat dilakukan dengan menggunakan beberapa teknik seperti unit testing dan integration testing. Unit testing dilakukan pada level kode dan memeriksa setiap fungsi dan modul pada aplikasi. Integration testing dilakukan pada level sistem dan memeriksa apakah komponen aplikasi dapat berfungsi secara bersama-sama.

Dengan mengikuti langkah-langkah di atas, aplikasi back end dengan database dan Rest API menggunakan Django Framework dapat dibangun dengan mudah. Embedding algoritma machine learning dalam aplikasi juga dapat membantu dalam melakukan pemrosesan data secara efisien dan akurat. Pengujian aplikasi juga sangat penting untuk memastikan bahwa aplikasi bekerja dengan baik dan dapat digunakan oleh pengguna dengan nyaman.

4.4.2. Pembangunan Front End (menggunakan VueJS dan leaflet)

Pembangunan front end menggunakan VueJS dan Leaflet dapat dilakukan dengan beberapa tahap berikut:

1. Desain User Interface

Tahap pertama adalah merancang tampilan antarmuka pengguna atau User Interface (UI) yang akan digunakan dalam aplikasi. Desain UI harus memperhatikan kebutuhan pengguna dan harus mudah dipahami serta digunakan.

2. Instalasi dan Konfigurasi VueJS dan Leaflet

Setelah desain UI selesai, langkah selanjutnya adalah melakukan instalasi dan konfigurasi VueJS dan Leaflet. VueJS adalah framework JavaScript yang populer untuk pembuatan aplikasi web. Leaflet adalah pustaka JavaScript untuk peta interaktif.

3. Pembangunan Komponen UI dengan VueJS

Setelah instalasi dan konfigurasi selesai, langkah selanjutnya adalah membangun komponen UI menggunakan VueJS. Komponen UI dapat berupa formulir, tabel, grafik, atau elemen lainnya yang digunakan dalam aplikasi.

4. Integrasi Leaflet dengan VueJS

Setelah pembangunan komponen UI selesai, langkah selanjutnya adalah mengintegrasikan Leaflet dengan VueJS. Leaflet menyediakan API untuk memanipulasi peta, menambahkan marker, layer, dan lain-lain. API Leaflet dapat dipanggil dari dalam komponen VueJS.

5. Pengujian Aplikasi

Setelah aplikasi selesai dibangun, langkah terakhir adalah melakukan pengujian aplikasi. Pengujian dapat dilakukan dengan menggunakan beberapa teknik seperti unit testing dan integration testing. Unit testing dilakukan pada level kode dan memeriksa setiap fungsi dan modul pada aplikasi. Integration testing dilakukan pada level sistem dan memeriksa apakah komponen aplikasi dapat berfungsi secara bersama-sama.

Dengan mengikuti langkah-langkah di atas, aplikasi front end dengan VueJS dan Leaflet dapat dibangun dengan mudah. Integrasi Leaflet dengan VueJS dapat membantu dalam membuat peta interaktif yang menarik dan informatif. Pengujian aplikasi juga sangat penting untuk memastikan bahwa aplikasi bekerja dengan baik dan dapat digunakan oleh pengguna dengan nyaman.

4.4.3. Integrasi sistem (bagaimana BE dan FE berkomunikasi lalu menampilkan data ke GIS)

Integrasi antara Back End dan Front End pada sebuah aplikasi web umumnya dilakukan melalui API atau Application Programming Interface. API adalah antarmuka atau interface yang memungkinkan sistem-sistem berbeda untuk berkomunikasi satu sama lain dan bertukar informasi.

Dalam konteks aplikasi GIS, Front End biasanya menggunakan pustaka JavaScript seperti Leaflet atau OpenLayers untuk menampilkan data pada peta interaktif. Sedangkan Back End biasanya terdiri dari basis data geospasial dan sistem manajemen basis data seperti PostgreSQL dan PostGIS, serta framework web seperti Django atau Flask.

Untuk mengintegrasikan Back End dan Front End pada sebuah aplikasi GIS, dapat dilakukan dengan langkah-langkah berikut:

1. Membangun API pada Back End

Langkah pertama adalah membuat API pada Back End untuk mengakses dan mengambil data dari basis data geospasial. API ini biasanya menggunakan protokol HTTP dan RESTful API, sehingga Front End dapat mengakses data melalui HTTP request.

2. Menggunakan Framework pada Front End

Langkah kedua adalah menggunakan framework pada Front End seperti VueJS atau ReactJS. Framework ini akan membantu dalam membangun komponen UI dan mengambil data melalui API yang telah dibuat pada Back End.

3. Menampilkan Data pada Peta Interaktif

Langkah ketiga adalah menampilkan data pada peta interaktif menggunakan pustaka JavaScript seperti Leaflet atau OpenLayers. Data yang diambil melalui API pada Back End dapat ditampilkan sebagai layer pada peta interaktif.

4. Melakukan Pengujian Sistem

Langkah terakhir adalah melakukan pengujian sistem untuk memastikan bahwa Back End dan Front End berkomunikasi dengan baik dan data dapat ditampilkan dengan benar pada peta interaktif. Pengujian dapat dilakukan dengan menggunakan teknik seperti unit testing dan integration testing.

Dengan mengikuti langkah-langkah di atas, Back End dan Front End dapat diintegrasikan pada sebuah aplikasi GIS, sehingga data

geospasial dapat ditampilkan pada peta interaktif dengan mudah dan akurat.

Framework yang telah dibangun dapat di akses pada halaman web: <http://18.138.105.225/>, dengan preview tampilan sebagai berikut:

Fitur Input:

Fitur PREDICT: digunakan dalam melakukan prediksi kebakaran hutan



Gambar 4.42 Tampilan halaman depan (home page) framework "The Forest Fire Prediction"



Gambar 4.43 Tampilan hasil prediksi framework "The Forest Fire Prediction" terhadap area terbakar dan area tidak terbakar

Fitur AVAILABLE MODEL: digunakan untuk menampilkan historis pemrosesan data yang dilakukan sebelumnya. Pada setiap tahapan proses, informasi data yang diberikan adalah: Process ID, F1, Accuracy dan Recall.



Gambar 4.45 Hasil prediksi algoritma SVM dan RF

Preview fitur Available Predict juga ditampilkan pada home page pada bagian bawah yang bisa digunakan sebagai tahapan evaluasi proses sebelumnya yang sudah pernah dilakukan/di analisis.

4.5. Membuat Model Machine Learning

4.5.1 Model Support Vector Machine (SVM)

Mesin vektor atau SVM (Support Vector Machine) adalah algoritma machine learning yang digunakan untuk masalah klasifikasi dan regresi. SVM bekerja dengan memisahkan data ke dalam ruang multidimensi yang disebut sebagai "ruang fitur", lalu mencari hyperplane yang memisahkan data ke dalam kelas-kelas yang berbeda. Hyperplane ini dipilih dengan cara yang optimal sehingga dapat meminimalkan kesalahan klasifikasi.

Kernel SVM adalah metode untuk mengubah data non-linear menjadi data linear. Kernel SVM bekerja dengan cara memproyeksikan data non-linear ke dalam ruang dimensi yang lebih tinggi, di mana data dapat dipisahkan oleh hyperplane. Ada beberapa jenis kernel yang umum digunakan dalam SVM, antara lain:

a. Linear Kernel:

Kernel linear adalah kernel yang paling sederhana. Kernel ini digunakan untuk memisahkan data yang dapat dipisahkan secara linear. Dalam kasus ini, SVM mencari hyperplane dengan jarak maksimum antara dua kelas. Kernel linear sering digunakan dalam kasus data yang linier, tetapi tidak efektif pada data yang kompleks.

b. Polynomial Kernel:

Kernel polinomial digunakan untuk memisahkan data yang tidak dapat dipisahkan secara linier. Kernel polinomial mengubah data ke dalam dimensi yang lebih tinggi sehingga data dapat dipisahkan dengan hyperplane. Kernel polinomial adalah kernel non-linear paling umum dan dapat menghasilkan garis melengkung atau permukaan dalam dimensi yang lebih tinggi. Polinomial kernel biasanya memiliki parameter derajat dan konstanta (bias) yang harus disesuaikan agar cocok dengan data.

c. Gaussian RBF Kernel:

Kernel RBF Gaussian digunakan untuk memisahkan data yang tidak dapat dipisahkan secara linear atau polinomial. Kernel ini mengubah data ke

dalam ruang dimensi tak hingga yang lebih besar. Kernel ini menghitung jarak antara dua titik data dan menyesuaikan bobot berdasarkan jarak tersebut. Semakin besar jaraknya, semakin kecil bobotnya. Kernel RBF Gaussian paling sering digunakan dalam kasus data yang kompleks.

d. Sigmoid Kernel:

Kernel sigmoid digunakan untuk memisahkan data yang tidak dapat dipisahkan secara linier atau polinomial. Kernel sigmoid menghasilkan permukaan melengkung atau garis melengkung yang tidak simetris. Kernel sigmoid biasanya digunakan pada data dengan distribusi sigmoidal.

e. Precomputed Kernel:

Precomputed kernel menghitung kernel dari matriks kernel yang telah dihitung sebelumnya. Ini digunakan ketika kernel yang diinginkan telah dihitung sebelumnya, misalnya dengan menggunakan kernel polinomial atau kernel RBF Gaussian. Dalam kasus ini, matriks kernel dihitung terlebih dahulu, lalu diproses oleh SVM sebagai input.



Gambar 4.46 Menu pilihan algoritma SVM

Ketika memilih kernel untuk SVM, pengguna harus memperhatikan tipe data yang akan diproses, karena setiap kernel cocok untuk jenis data yang berbeda. Kernel linear cocok untuk data yang linear, kernel polinomial cocok untuk data yang tidak linier, kernel RBF Gaussian cocok untuk data yang

kompleks, kernel sigmoid cocok untuk data sigmoidal, dan precomputed kernel cocok untuk data yang kernel-nya telah dihitung sebelumnya.

4.5.2 Model Random Forest (RF)

Random Forest adalah salah satu algoritma Machine Learning yang digunakan untuk klasifikasi, regresi dan pengelompokan data. Algoritma ini menggabungkan beberapa pohon keputusan (decision tree) yang saling independen, sehingga membentuk "hutan" pohon keputusan. Dalam Random Forest, setiap pohon dibangun dengan menggunakan subset acak dari sampel data dan subset acak dari fitur. Akhirnya, hasil dari semua pohon diambil dan dihitung secara bersamaan untuk menentukan kelas atau nilai prediksi dari data yang baru.

Estimator adalah komponen penting dalam algoritma Random Forest. Estimator dalam Random Forest adalah pohon keputusan (decision tree) yang terdiri dari beberapa node dan cabang. Setiap node pada pohon keputusan mewakili tes pada sebuah fitur, dan setiap cabang pada node mewakili hasil tes pada fitur tersebut. Pada setiap node, data yang diberikan dipisahkan menjadi dua atau lebih bagian berdasarkan hasil tes pada fitur tersebut, hingga ditemukan leaf node yang merepresentasikan hasil prediksi. Dalam Random Forest, sejumlah estimator dipilih untuk membentuk hutan pohon keputusan. Setiap estimator dibangun dengan menggunakan subset acak dari sampel data dan subset acak dari fitur. Proses ini disebut sebagai "bootstrap aggregating" atau "bagging". Dalam Random Forest, hasil dari semua estimator diambil dan dihitung secara bersamaan untuk menentukan kelas atau nilai prediksi dari data yang baru.



Gambar 4.47 Menu pilihan algoritma RF

4.5.3 Evaluasi kinerja algoritma

Perbedaan dalam hasil prediksi antara algoritma Support Vector Machine (SVM) dan Random Forest (RF) dapat disebabkan oleh karakteristik masing-masing algoritma.

a. Karakteristik Algoritma SVM:

- i. SVM merupakan algoritma yang digunakan untuk pemodelan prediktif dan klasifikasi data.
- ii. SVM bekerja dengan membangun sebuah *hyperplane* yang optimal untuk memisahkan kelas-kelas data.

Dalam kasus prediksi kebakaran hutan, hasil SVM ditampilkan pada Tabel yaitu 4.30 sebagai berikut:

Tabel 4.30 Hasil akurasi algoritma SVM

No	Uraian	Hasil	Rata-rata
1.	Test accuracy	0.992, 0.998, 0.996, 0.998, 0.994	0.9956
2.	Train accuracy	0.9965, 0.995, 0.9955, 0.995, 0.996	0.9956

Hasil *train accuracy* tersebut lebih rendah jika dibandingkan dengan algoritma random forest dapat disebabkan oleh beberapa faktor seperti kurangnya jumlah sampel data yang cukup, kesulitan dalam menemukan *hyperplane* yang memisahkan dengan baik antara kelas kebakaran dan non-kebakaran, atau kurangnya pemilihan parameter yang optimal dalam algoritma SVM.

b. Karakteristik Algoritma Random Forest:

- i. Random Forest merupakan algoritma ensemble learning yang terdiri dari sejumlah besar decision tree.

- ii. Algoritma ini menggabungkan prediksi dari beberapa decision tree untuk menghasilkan prediksi akhir.
- iii. Random Forest memiliki kemampuan untuk menangani masalah overfitting dan bias-variance tradeoff yang dapat mempengaruhi hasil prediksi.

Dalam kasus prediksi kebakaran hutan, hasil Random Forest yang lebih tinggi (Tabel 4.31) yang disebabkan oleh kemampuannya untuk menggabungkan informasi dari berbagai decision tree, sehingga meningkatkan akurasi prediksi.

Tabel 4.31 Hasil akurasi algoritma RF

No	Uraian	Hasil	Rata-rata
1.	Test accuracy	0.992, 0.994, 0.992, 0.998, 0.994	0,994
2.	Train accuracy	0.998 , 0.996 , 0.9965, 0.997 , 0.997	0,9969

Pada running evaluasi kedua algoritma tersebut, jumlah variable yang digunakan sebanyak 13 parameter (parameter kejadian kebakaran hutan dijadikan variabel yang diujikan).

4.5.4. Integrasi algoritma dengan system

Pembuatan core algoritma model SVM dan Random Forest dengan bantuan library SCIKIKIT LEARN <https://scikit-learn.org/>. Untuk evaluasi model yang dibuat, kami menggunakan metode k-fold dengan library yang sama dengan pembuatan model. Sebagai tambahan informasi, jumlah fold yang kami gunakan adalah sebanyak 5 fold.

Setelah pembuatan algoritma selesai, dilakukan penanaman algoritma di dalam sebuah aplikasi back-end berbasis python dengan framework django. Aplikasi ini memproduksi sebuah rest-api dengan format json yang akan dikonsumsi oleh Aplikasi front-end nantinya. Untuk membantu

pengolahan geojson, kami menggunakan geopandas sebagai library pendukung. Sebagai hasilnya, backend menghasilkan 5 rest api berikut:

1. Pembuatan model baru
2. Daftar semua model dan hasil evaluasinya
3. Prediksi data
4. Daftar hasil prediksi
5. Geojson hasil prediksi

Api yang tersedia akan di request oleh aplikasi front-end. Aplikasi front-end dibangun menggunakan framework vuejs dengan bantuan component library vuetify. Untuk menampilkan hasil prediksi dalam sebuah proyeksi peta, sistem ini menggunakan framework leaflet dengan basemap dari provider openstreet map. Sebagai hasilnya, dari proses ini dihasilkan 3 halaman interface:

1. Halaman available model: Untuk membuat model baru dan menampilkan semua model yang telah di training sebelumnya.
2. Halaman predict: Untuk memprediksi potensi kebakaran dari data masukan dan menampilkan semua data yang pernah di prediksi sebelumnya.
3. Halaman map: Untuk memploting hasil prediksi diatas sebuah map.

4.5.4 Klasifikasi data set dengan machine learning

1. Pembuatan model menggunakan data training format geojson dengan 14 variable (dijelaskan di halaman xx) dengan luasan 37,5 x 37,5 km yang direpresentasikan dalam sebuah grid resolusi 50x50 pixel. Pada penelitian ini menggunakan semua variable sebagai training, kecuali fire spot sebagai target class.
2. Simulasi prediksi juga menggunakan data training dengan sedikit modifikasi. Modifikasi yang dilakukan adalah menghapus variabel target class (fire spot) sehingga sistem akan memprediksi nilai firespot yang mungkin muncul dari variabel-variabel lainnya.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan perhitungan, analisis data dan klasifikasi yang telah dilakukan pada penelitian ini, dapat disimpulkan sebagai berikut:

1. Teknik data mining yang dilakukan pada penelitian ini telah berhasil mendapatkan data cuaca, hot spot dan kualitas udara seluruh Indonesia dari beberapa website sumber penyedia data secara real time dan mampu menggabungkan jenis data tabular dan spasial secara otomatis.
2. Berdasarkan hasil clusterisasi data pada area penelitian menunjukkan bahwa cluster terbaik pada kepulauan Kalimantan sejumlah 9 cluster dengan score DB Index sebesar 0,983.
3. Faktor-faktor yang mempengaruhi kebakaran hutan dalam penelitian ini sebanyak 14 variabel, berdasarkan perhitungan dan analisis maka secara umum terdapat 2 kategori yaitu:
 - a. Faktor yang berpengaruh
 - b. Faktor yang kurang/tidak berpengaruh
4. Penelitian ini telah berhasil membangun framework machine learning terintegrasi dengan sistem informasi geografis berdasarkan data faktor-faktor yang mempengaruhi kebakaran hutan.
5. Hal yang mempengaruhi keberhasilan implementasi machine learning untuk prediksi kebakaran hutan adalah (a) Jumlah data dan (b) Data tidak over fitting.

5.2. Saran

Pada penelitian ini, bobot score faktor-faktor yang mempengaruhi kebakaran hutan merujuk pada paper Wildfire Risk Assessment of Transmission-Line Corridors Based on Naïve Bayes Network and Remote Sensing Data, by Weijie Chen, You Zhou, Enze Zhou, Zhun Xiang, Wentao Zhou and Junhan Lu yang berlokasi di negara China. Untuk mendapatkan score bobot yang sesuai spesifik lokasi (Indonesia), perlu dilakukan penelitian lebih lanjut mengenai metode pembobotan masing-masing faktor yang mempengaruhi kebakaran hutan.

DAFTAR PUSTAKA

PUSTAKA BUKU

A. Tri *et al.*, "JAMBURA JOURNAL OF PROBABILITY AND STATISTICS Volume 1 Nomor 2, November 2020," vol. 1, no. November, 2020.

Suntoro, J. (2019). *Data Mining: Algoritma dan Implementasi dengan Pemrograman PHP*. Terbitan pertama. Jakarta: Elex Media Komputindo.

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

A. Beaudoin *et al.*, "Mapping attributes of Canada's forests at moderate resolution through kNN and MODIS imagery," *Can. J. For. Res.*, vol. 44, no. 5, pp. 521–532, 2014, doi: 10.1139/cjfr-2013-0401.

A. Sanmorino, J. Alie, N. Ariati, and S. V. Wulanda, "K-NN Based Air Classification as Indicator of the Index of Air Quality in Palembang," vol. 7, no. 3, pp. 853–859, 2022.

A. Rudiyan, A. E. Dzulkifli, and K. Munazar, "Klasifikasi Kebakaran Hutan Menggunakan Metode K-Nearest Neighbor: Studi Kasus Hutan Provinsi Kalimantan Barat," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 3, no. 4, pp. 195–202, 2022, doi: 10.35746/jtim.v3i4.177.

A. P. Mahendra, D. Pradipta, M. R. B. Saputro, and K. Kusriani, "Application of the Decision Tree Method to Forest Fire Detection (Case Study: in Palembang, South Sumatra)," *JTECS J. Sist. Telekomun. Elektron. Sist. Kontrol Power Sist. dan Komput.*, vol. 2, no. 1, p. 75, 2022, doi: 10.32503/jtecs.v2i1.2196.

A. Pratamasari, N. K. F. Permatasari, T. Pramudiyasari, M. D. M. Manessa, and S. Supriatna, "Spatial Distribution Patterns Analysis of Hotspot in Central Kalimantan using FIMRS MODIS Data," *J. Geogr. Lingk. Trop.*, vol. 4, no. 1, pp. 24–34, 2020, doi: 10.7454/jglitrop.v4i1.74.

A. L. Achu, J. Thomas, C. D. Aju, G. Gopinath, S. Kumar, and R. Reghunath, "Machine-learning modelling of fire susceptibility in a forest-agriculture mosaic landscape of southern India," *Ecol. Inform.*, vol. 64, p. 101348, 2021, doi: 10.1016/j.ecoinf.2021.101348.

Andela, N., Morton, D. C., Giglio, L., Chen, Y., van der Werf, G. R., Kasibhatla, P. S., ... & Hanson, S. (2017). A human-driven decline in global burned area. *Science*, 356(6345), 1356–1362.

A. Hooda, A. Asthana, and V. Patkar, "A Comprehensive Review on Prediction and Detection of Forest Fires Using Machine Learning Algorithms A Comprehensive Review on Prediction and Detection of Forest Fires using Machine Learning Algorithms," 2021.

A. Shahdeo, A. Shahdeo, P. S. Reddy, and K. Chaitra, "Wildfire Prediction and Detection using Random Forest and Different Color Models," *Int. Res. J. Eng. Technol.*, vol. 07, no. 06, pp. 7326–7332, 2020, [Online]. Available: www.irjet.net

A. S. Alekseev and D. M. Chernikhovskii, "Assessment of the State of Forests Based on Joint Statistical Processing of Sentinel-2b Remote Sensing Data and the Data from Network of Ground-Based ICP-Forests Sample Plots," pp. 513–528, 2022, doi: 10.4236/oje.2022.128028.

A. D. P. Pacheco, J. A. D. S. Junior, A. M. Ruiz-Armenteros, and R. F. F. Henriques, "Assessment

- of k-nearest neighbor and random forest classifiers for mapping forest fire areas in central Portugal using landsat-8, sentinel-2, and terra imagery," *Remote Sens.*, vol. 13, no. 7, pp. 1–25, 2021, doi: 10.3390/rs13071345.
- A. Harita, K. Madhureka, K. P. Neethu, and K. R. Singh, "Predicting Forest Fires With Spark Machine Learning," 2020.
- A. Khaliq, L. Comba, A. Biglia, D. Ricauda Aimonino, M. Chiaberge, and P. Gay, "Comparison of satellite and UAV-based multispectral imagery for vineyard variability assessment," *Remote Sens.*, vol. 11, no. 4, 2019, doi: 10.3390/rs11040436.
- A. Primajaya and B. N. Sari, "Random Forest Algorithm for Prediction of Precipitation," *Indones. J. Artif. Intell. Data Min.*, vol. 1, no. 1, p. 27, 2018, doi: 10.24014/ijaidm.v1i1.4903.
- Ahmad Harmain, P. Paiman, H. Kurniawan, K. Kusriani, and Dina Maulina, "Normalisasi Data Untuk Efisiensi K-Means Pada Pengelompokan Wilayah Berpotensi Kebakaran Hutan Dan Lahan Berdasarkan Sebaran Titik Panas," *Tek. Teknol. Inf. dan Multimed.*, vol. 2, no. 2, pp. 83–89, 2022, doi: 10.46764/teknimedia.v2i2.49.
- A. M. Elshewey, "Forest Fires Detection Using Machine Learning Techniques," vol. XII, no. 1x, pp. 510–517, 2020, [Online]. Available: <https://www.xajzkjdx.cn/gallery/54-sep2020.pdf>
- A. Vatesia, R. R. Rais, F. P. Utama, and W. Oktarianti, "Mining Fire Hotspots Over Nusa Tenggara and Bali Islands," *Indones. J. For. Res.*, vol. 9, no. 1, pp. 73–85, 2022, doi: 10.20886/ijfr.2022.9.1.73-85.
- Å. Nebot and F. Mugica, "Forest fire forecasting using fuzzy logic models," *Forests*, vol. 12, no. 8, 2021, doi: 10.3390/f12081005.
- A. Tri *et al.*, "JAMBURA JOURNAL OF PROBABILITY AND STATISTICS Volume 1 Nomor 2, November 2020," vol. 1, no. November, 2020.
- A. Muhammad *et al.*, "Role of Machine Learning Algorithms in Forest Fire Management: A Literature Review," *J. Robot. Autom.*, vol. 5, no. 1, pp. 212–226, 2021, doi: 10.36959/673/372.
- A. Pratiwi, M. Irsyad, R. Kurniawan, S. Agustian, and B. S. Negara, "Klasifikasi Kebakaran Hutan Dan Lahan Menggunakan Algoritma Naïve Bayes Di Kabupaten Pelalawan," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 6, no. 1, p. 139, 2021, doi: 10.24114/cess.v6i1.22555.
- Alcasena, F. J., Gavier-Pizarro, G. I., & Kuemmerle, T. (2019). Land-use change and fire incidence in Argentina: Patterns and drivers in the Chaco region. *Applied Geography*, 109, 102013.
- Asmare Yitbarek, Ayele Almw Abera, Birhanu Megersa Lenjiso, & Beza Negussie. (2020). Modeling Wildfire Susceptibility Using Remote Sensing and GIS Techniques: A Case Study of Dire Dawa Administration, Ethiopia. *The Open Remote Sensing Journal*, 11(1), 1-14.
- Alizadeh, M., & Eskandari, M. (2018). Support vector machine: theory, applications and challenges. *Journal of Advances in Computer Research*, 9(3), 1-20.
- Aguiar, A. P. D., Vale, A. T., & Câmara, G. (2018). Data mining for forest fire occurrence prediction in the Brazilian Amazon. *International Journal of Applied Earth Observation and Geoinformation*, 73, 306-314.
- Awaliyan, R., & Sulistyoadi, Y. B. (2018). Klasifikasi Penutupan Lahan Pada Citra Satelit Sentinel-2a Dengan Metode Tree Algorithm. *ULIN Jurnal Hutan Tropis*, 2(2), 98-104. doi:10.32522/ujht.v2i2.1363

- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- B. Kalantar, N. Ueda, M. O. Idrees, S. Janizadeh, K. Ahmadi, and F. Shabani, "Forest fire susceptibility prediction based on machine learning models with resampling algorithms on remote sensing data," *Remote Sens.*, vol. 12, no. 22, pp. 1-24, 2020, doi: 10.3390/rs12223682.
- B. T. Pham *et al.*, "Performance evaluation of machine learning methods for forest fire modeling and prediction," *Symmetry (Basel)*, vol. 12, no. 6, pp. 1-21, 2020, doi: 10.3390/SYMI2061022.
- B. H. Naganathan, S. P. Seshasayee, J. Kim, W. K. Chong, and J. Chou, "Wildfire Predictions : Determining Reliable," vol. 16, no. 4, 2016.
- Bui, X. T., Thai, P. Q., Hoang, M. H., Pham, D. Q., & Dao, Q. T. (2020). Forest fire susceptibility assessment and mapping using a spatially integrated approach of remote sensing, GIS, and multi-criteria evaluation techniques in Central Vietnam. *Environmental Monitoring and Assessment*, 192(2), 1-24.
- C. Brun Sorribas, "A comprehensive methodology to predict forest fires behavior using complementary models," 2014, [Online]. Available: <https://widgets.ebscohost.com/prod/customerspecific/ns000545/customproxy.php?url=http://search.ebscohost.com/login.aspx?direct=true&db=cddtdx&AN=cddtdx.10803.283359&%40Alang=pt&site=cddt-live&scope=site>
- C. Mulwa, "Classification of Wildfire Spread Severity using Machine Learning Algorithm Amit Sahoo National College of Ireland Supervisor:."
- Cutler, D. R., Edwards Jr, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Chong, K.Y., Lin, H., Neng, T.S., Hong, Y.H., Yong, A.S.K., & Ting, C.S. (2021). Predicting forest fire risk using random forest: a case study in Southeast Asia. *Environmental Monitoring and Assessment*, 193(6), 357.
- Chen, Y. S., Liu, S. H., & Lee, C. Y. (2017). Applying remote sensing and GIS techniques to analyze the relationship between fire occurrence and environmental factors in Taiwan's mountainous region. *The Forestry Chronicle*, 93(2), 176-183.
- Chen, C., Yin, Y., Liu, J., Liu, Y., & Li, H. (2018). Spatial-temporal variation of forest fire vulnerability under different population pressures in Hubei Province. *Journal of Geographical Sciences*, 28(2), 229-242.
- Chuvieco, E., Aguado, I., Jurdao, S., & Pettinari, M.L. (2014). Integration of geographic information and remote sensing techniques for modelling spatiotemporal patterns of forest fire danger using the random forest algorithm. *Remote Sensing of Environment*, 154, 44-57.
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Salas, J., Martín, M.P., Vilar, L., Martínez, J., Martín, S., Ibarra, P., de la Riva, J., Baeza, J., Rodríguez, F., Molina, J.R., Herrera, M.A., Zamora, R. (2010). Development of a framework for fire risk assessment using remote sensing and geographic information system technologies. *Ecological Modelling*, 221(1), 46-58.
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Salas, J., Martín, M.P., ... & Pérez-Gorostiaga, P. (2019). Integrating multiple criteria into fire risk assessment in a Mediterranean wildland-urban interface. *Science of the Total Environment*, 651, 2937-2949.

- Daud, N. M., Ismail, Z., & Aziz, N. A. (2017). Factors influencing wildfire occurrence in Malaysia: A review. *IOP Conference Series: Earth and Environmental Science*, 58(1), 012030.
- D. L. Davies and D. W. Bouldin, "A Cluster Separation Measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-1, no. 2, pp. 224-227, 1979, doi: 10.1109/TPAMI.1979.4766909.
- D. Tien Bui, Q. T. Bui, Q. P. Nguyen, B. Pradhan, H. Nampak, and P. T. Trinh, "A hybrid artificial intelligence approach using GIS-based neural-fuzzy inference system and particle swarm optimization for forest fire susceptibility modeling at a tropical area," *Agric. For. Meteorol.*, vol. 233, pp. 32-44, 2017, doi: 10.1016/j.agrformet.2016.11.002.
- D. Rosadi, W. Andriyani, D. Arisanty, and D. Agustina, "Prediction of Forest Fire Occurrence in Peatlands using Machine Learning Approaches," *2020 3rd Int. Semin. Res. Inf. Technol. Mach. Intell.*, vol. PAMI-1, no. 2, pp. 48-51, 2020, doi: 10.1109/ISRITI51436.2020.9315359.
- D. Rosadi, W. Andriyani, D. Arisanty, and D. Agustina, "Prediction of Forest Fire using Hybrid SOM-AdaBoost Method," *J. Phys. Conf. Ser.*, vol. 2123, no. 1, 2021, doi: 10.1088/1742-6596/2123/1/012030.
- D. A. Wood, "Prediction and data mining of burned areas of forest fires: Optimized data matching and mining algorithm provides valuable insight," *Artif. Intell. Agric.*, vol. 5, pp. 24-42, 2021, doi: 10.1016/j.iaia.2021.01.004.
- Duan, L., & Wang, X. (2019). Forest fire prediction based on decision tree and artificial neural network in Zhejiang Province, China. *Journal of Cleaner Production*, 218, 533-545.
- E. Amadi and C. Muntean, "Analysis of Wildfire Risk Using Machine Learning and Distributed Computing in Canadian Regions National College of Ireland Supervisor."
- E. F. Sirat, B. D. Setiawan, and F. Ramdani, "Analisis Perbandingan Algoritme K-Means dan Isodata untuk Klasterisasi Data Kejadian Titik Api di Wilayah Sumatera pada Tahun 2001 hingga 2014," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 11, pp. 5105-5112, 2018.
- F. Anwer, "Fireinform: An Approach to Predict Hourly Forest Fire Occurrences using Multivariate Time Series Classification," no. March, 2021, [Online]. Available: <https://ourspace.uregina.ca/handle/10294/14317>
- F. X. Catry, F. C. Rego, and T. Santos, "Forest fires prevention in Portugal - using GIS to help improving early fire detection effectiveness. In: 4th International Wildland Fire Conference," no. January, 2007.
- F. Fitriyani and R. Sanjaya, "Komparasi Algoritma Lr, K-Nn Dan Svm Untuk Estimasi Area Kebakaran Hutan," *Infotronik - J. Teknol. Inf. dan Elektron.*, vol. 3, no. 2, p. 103, 2018, doi: 10.32897/infotronik.2018.3.2.109.
- F. Fitriyani, "Implementasi Forward Selection dan Bagging untuk Prediksi Kebakaran Hutan Menggunakan Algoritma Naïve Bayes," *J. Nas. Teknol. dan Sist. Inf.*, vol. 8, no. 1, pp. 1-8, 2022, doi: 10.25077/teknosi.v8i1.2022.1-8.
- Fuentes, C., Torres-Moye, E., & Valenzuela, L. (2019). Fire risk assessment in central Chile using satellite data and geospatial techniques. *Natural Hazards*, 98(1), 219-238.
- G. P. Petropoulos, K. P. Vadrevu, G. Xanthopoulos, G. Karantounias, and M. Scholze, "A comparison of spectral angle mapper and artificial neural network classifiers combined with landsat TM imagery analysis for obtaining burnt area mapping," *Sensors*, vol. 10, no. 3, pp. 1967-1985, 2010, doi: 10.3390/s100301967.
- G. F. Shidik, K. Mustofa, P. Size, F. Using, and H. Model, "Predicting Size of Forest Fire Using

- G. E. Fasshauer and L. L. Schumaker, *Minimal energy surfaces using parametric splines*, vol. 13, no. 1. 1996. doi: 10.1016/0167-8396(95)00006-2.
- G. Mangat, "Using Neural Networks and K-means Clustering for Accurate Wildfire Environmental Conditions Detection," vol. 3, no. 1, pp. 1–6, 2020.
- G. E. Sakr, I. H. Elhajj, G. Mitri, and U. C. Wejinya, "Artificial intelligence for forest fire prediction," *IEEE/ASME Int. Conf. Adv. Intell. Mechatronics, AIM*, pp. 1311–1316, 2010, doi: 10.1109/AIM.2010.5695809.
- H. Liang, M. Zhang, and H. Wang, "A Neural Network Model for Wildfire Scale Prediction Using Meteorological Factors," *IEEE Access*, vol. 7, pp. 176746–176755, 2019, doi: 10.1109/ACCESS.2019.2957837.
- H. Kumar, "Detection of Forest Fire Areas using Machine Learning," vol. 2, no. 2, pp. 699–704, 2022, doi: 10.48175/IJARSCT-5623.
- H. Dong, H. Wu, P. Sun, and Y. Ding, "Wildfire Prediction Model Based on Spatial and Temporal Characteristics: A Case Study of a Wildfire in Portugal's Montesinho Natural Park," 2022.
- Hamidi, "Software Dan Hardware," *Apl. Sist. Inf. Geogr. Berbas. Web Penyebaran Dana Bantu. Oper. Sekol.*, vol. 2, pp. 1–14, 2017.
- Huang, Y., Zhang, Y., Li, L., Li, G., Li, Z., & Chen, X. (2019). Spatiotemporal characteristics of forest fire occurrence and its relationship with climate factors in China from 2000 to 2014. *Science of The Total Environment*, 651, 2019-2030.
- Hidayati, D., Dariyanto, D., & Alimuddin, A. (2021). Forest Fire Prediction in Jambi Province, Indonesia using Support Vector Machine and Geographic Information System. *IOP Conference Series: Earth and Environmental Science*, 707(1), 012018.
- I. Muslim, K. Karo, S. N. Amalia, and D. Septiana, "Klasifikasi Kebakaran Hutan Menggunakan Feature Selection dengan Algoritma K-NN, Naive Bayes dan ID3," vol. 3, no. 1, pp. 121–126, 2022.
- I. S. Sitanggang and M. H. Ismail, "Classification model for hotspot occurrences using a decision tree method," *Geomatics, Nat. Hazards Risk*, vol. 2, no. 2, pp. 111–121, 2011, doi: 10.1080/19475705.2011.565807.
- J. L. Martinez *et al.*, "Comparison of satellite and drone-based images at two spatial scales to evaluate vegetation regeneration after post-fire treatments in a mediterranean forest," *Appl. Sci.*, vol. 11, no. 12, 2021, doi: 10.3390/app11125423.
- J. B. Filippi, F. Morandini, J. H. Balbi, and D. re Hill, "Discrete Event Front-tracking Simulation of a Physical Fire-spread Model," *Simulation*, vol. 86, no. 10, pp. 629–646, 2010, doi: 10.1177/0037549709343117.
- J. S. Barreto and D. Armenteras, "Open data and machine learning to model the occurrence of fire in the ecoregion of 'llanos colombo-venezolanos,'" *Remote Sens.*, vol. 12, no. 23, pp. 1–18, 2020, doi: 10.3390/rs12233921.
- J. S. Ayanz, I. Gitas, A. Camia, and S. Oliveira, *Advances in Remote Sensing and GIS applications in Forest Fire Management From local to global assessments*. 2011.
- J. P. J. F. A. Vincent, "Komparasi Tingkat Akurasi Random Forest Dan Knn Untuk Mendiagnosis Penyakit Kanker Payudara," *Univ. Pelita Harapan PSDKU Medan Jur. Sist. Inf.*, vol. 7,

no. 1, pp. 49–61, 2022.

- J. O. Otieno, "A machine learning algorithm for predicting wild fire occurrence," 2020, [Online]. Available: <https://su-plus.strathmore.edu/handle/11071/12085>
- K. R. Singh, K. P. Neethu, K. Madhurekaa, A. Harita, and P. Mohan, "Parallel SVM model for forest fire prediction," *Soft Comput. Lett.*, vol. 3, p. 100014, 2021, doi: 10.1016/j.socle.2021.100014.
- K. D. Butar-Butar, Elviawaty Muisa Zamzami, Nancy Damanik, Alex Rikki, and Eva Darlina, "Spatial Distribution and Implementation of the K-Means Clustering Method at Hotspots in North Sumatra," *J. Comput. Phys. Earth Sci.*, vol. 1, no. 1, pp. 1–6, 2021, doi: 10.53842/jocpes.v1i1.1.
- K. Bot and J. G. Borges, "A Systematic Review of Applications of Machine Learning Techniques for Wildfire Management Decision Support," *Inventions*, vol. 7, no. 1, 2022, doi: 10.3390/inventions7010015.
- K. S. Yankovich, E. P. Yankovich, and N. V. Baranovskiy, "Classification of Vegetation to Estimate Forest Fire Danger Using Landsat 8 Images: Case Study," *Math. Probl. Eng.*, vol. 2019, 2019, doi: 10.1155/2019/6296417.
- Keecman, V. (2005). Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. MIT press.
- Karyadi, B., Ginting, N., Fatah, A. S., & Hidayat, H. (2019). Fire risk mapping in Sumatra using NDTV and GIS-based analysis. IOP Conference Series: Earth and Environmental Science, 352, 012017.
- Koutsias, N., Allgöwer, B., Kalabokidis, K., Mallinis, G., & Goldammer, J. G. (2013). Modelling spatial patterns of fire occurrence in Greece integrating topographic, fuel and climatic factors. International Journal of Wildland Fire, 22(4), 493–507.
- Khatibi, S., Arvanitidis, T., Gounaris, A., & Zimek, A. (2019). A cluster-based approach for predicting forest fires. Knowledge-Based Systems, 174, 37–48. <https://doi.org/10.1016/j.knsys.2019.01.007>
- Lanorte, A., Lasaponara, R., & Masini, N. (2020). Spatial modeling of fire risk and vulnerability using remote sensing and GIS: A case study in Calabria, southern Italy. Applied Geography, 120, 102202.
- Lan, G., Li, J., Li, X., Wang, Z., Li, J., Li, Z., & Zhang, H. (2019). Quantitative assessment of forest fire risk based on physical and human factors in China. International Journal of Environmental Research and Public Health, 16(23), 4618.
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. R news, 2(3), 18–22.
- Liu, T., Zhang, S., Li, S., Li, C., & Li, Y. (2019). Predicting Forest Fire Risk in Pingnan County, Fujian Province, China Using Data Mining and GIS. International Journal of Environmental Research and Public Health, 16(6), 1054. DOI: 10.3390/ijerph16061054.
- Liu, J., Zhao, Y., & Wang, J. (2019). Predicting forest fire risk using data mining integrated with GIS: a case study in Pingnan County, China. Environmental Earth Sciences, 78(5), 1–12.
- L. Sun, J. Trinder, and C. Rizos, "Proceedings for the 5th International Fire Behavior and Fuels Conference April 11–15, 2016, Portland, Oregon, USA Published by the International Association of Wildland Fire, Missoula, Montana, USA," *5th Int. Fire Behav. Fuels Conf.*, pp. 1–6, 2016.

- L. Hu, G. Zhou, and Y. Qiu, "Application of apriori algorithm to the data mining of the wildfire," *6th Int. Conf. Fuzzy Syst. Knowl. Discov. FSKD 2009*, vol. 2, pp. 426–429, 2009, doi: 10.1109/FSKD.2009.228.
- L. Ramesh and E. Dinesh, "an Efficient System for Detecting Forest Fire Using Spatial Data," *Indian J. Sci. Technol.*, vol. 11, no. 19, pp. 1–6, 2018, doi: 10.17485/ijst/2018/v11i19/123223.
- L. N. Ferreira, D. A. Vega-Oliveros, L. Zhao, M. F. Cardoso, and E. E. N. Macau, "Global fire season severity analysis and forecasting," *Comput. Geosci.*, vol. 134, 2020, doi: 10.1016/j.cageo.2019.104339.
- M. Wang *et al.*, "A Principal Component Analysis-Boosted Dynamic Gaussian Mixture Clustering Model for Ignition Factors of Brazil's Rainforests," *IEEE Access*, vol. 9, pp. 145748–145762, 2021, doi: 10.1109/ACCESS.2021.3122112.
- M. de Domingo, N. Ortigosa, J. Sevilla, and S. Roger, "Cluster-based relocation of stations for efficient forest fire management in the province of Valencia (Spain)," *Sensors (Switzerland)*, vol. 21, no. 3, pp. 1–17, 2021, doi: 10.3390/s21030797.
- M. Elia *et al.*, "Uncovering current pyroregions in Italy using wildfire metrics," *Ecol. Process.*, vol. 11, no. 1, 2022, doi: 10.1186/s13717-022-00360-6.
- M. Reza Noviansyah, T. Rismawan, D. Marisa Midyanti, J. Sistem Komputer, and F. H. MIPA Universitas Tanjungpura Jl. Hadari Nawawi, "Penerapan Data Mining Menggunakan Metode K-Nearest Neighbor Untuk Klasifikasi Indeks Cuaca Kebakaran Berdasarkan Data Aws (Automatic Weather Station) (Studi Kasus: Kabupaten Kubu Raya)," *J. Coding, Sist. Komput. Untan*, vol. 06, no. 2, pp. 48–56, 2018.
- M. Hosseini and S. Lim, "Gene expression programming and data mining methods for bushfire susceptibility mapping in New South Wales, Australia," *Nat. Hazards*, no. 0123456789, 2022, doi: 10.1007/s11069-022-05350-7.
- Marliatno, D., Afandi, N. H., Setiawan, L., & Diah, H. (2021). Analisis Faktor-Faktor yang Berpengaruh Terhadap Kebakaran Hutan dan Lahan di Indonesia. *Jurnal Sumberdaya Alam dan Lingkungan*, 5(1), 34–45.
- Mátyás, C. (2018). Wildfire occurrence and aspects of topography in a mid-mountain area. *Carpathian Journal of Earth and Environmental Sciences*, 13(2), 395–404.
- Naik, P., Singh, V., & Singh, S. K. (2018). An analytical study of forest fires in India. *Journal of the Indian Society of Remote Sensing*, 46(3), 467–476.
- N. P. Dharshinni, F. Azmi, I. Fawwaz, A. M. Husein, and S. D. Siregar, "Analysis of Accuracy K-Means and Apriori Algorithms for Patient Data Clusters," *J. Phys. Conf. Ser.*, vol. 1230, no. 1, 2019, doi: 10.1088/1742-6596/1230/1/012020.
- N. Abid *et al.*, "Burnt Forest Estimation from Sentinel-2 Imagery of Australia using Unsupervised Deep Learning," *DICTA 2021 - 2021 Int. Conf. Digit. Image Comput. Tech. Appl.*, 2021, doi: 10.1109/DICTA52665.2021.9647174.
- N. Ngoc Thach *et al.*, "Spatial pattern assessment of tropical forest fire danger at Thuan Chau area (Vietnam) using GIS-based advanced machine learning algorithms: A comparative study," *Ecol. Inform.*, vol. 46, pp. 74–85, 2018, doi: 10.1016/j.ecoinf.2018.05.009.
- N. Khan and N. K. Batcha, "Wild fire prediction using machine learning models," *J. Appl. Technol. Innov.*, vol. 5, no. 1, pp. 2600–7304, 2021.
- N. A. Khairani and E. Sutoyo, "Application of K-Means Clustering Algorithm for Determination of Fire-Prone Areas Utilizing Hotspots in West Kalimantan Province," *Int. J. Adv. Data*

- N. F. Mustamin, A. F. Zulkarnain, and ..., "Sistem Informasi Geografis untuk Sebaran Titik Panas (Hotspot) di Kalimantan Selatan Menggunakan Metode Clustering," *Pros. Semin. ...*, vol. 6, no. April, 2021, [Online]. Available: <http://snllb.ulm.ac.id/prosiding/index.php/snllb-lit/article/view/587>
- P. Jain, S. C. P. Coogan, S. G. Subramanian, M. Crowley, S. Taylor, and M. D. Flannigan, "A review of machine learning applications in wildfire science and management," *Environ. Rev.*, vol. 28, no. 4, pp. 478–505, 2020, doi: 10.1139/er-2020-0019.
- P. Zhao, F. Zhang, H. Lin, and S. Xu, "Gis-based forest fire risk model: A case study in laoshan national forest park, nanjing," *Remote Sens.*, vol. 13, no. 18, pp. 1–21, 2021, doi: 10.3390/rs13183704.
- P. Prihandoko and B. Bertalya, "a Data Analysis of the Impact of Natural Disaster Using K-Means Clustering Algorithm," *Kursor*, vol. 8, no. 4, p. 169, 2017, doi: 10.28961/kursor.v8i4.109.
- P. K. G. R. Rahul, and N. Ravindharan, "Early Forest Fire Detection Using Machine Learning Algorithms," no. 4, pp. 1–5, 2021.
- P. Cortez and A. Morais, "A Data Mining Approach to Predict Forest Fires using Meteorological Data," *Proc. 13th Port. Conf. Artif. Intell.*, no. January 2007, pp. 512–523, 2007, [Online]. Available: <http://www.dsi.uminho.pt/~pcortez/fires.pdf>
- P. Barnpoutis, P. Papaioannou, K. Dimitropoulos, and N. Grammalidis, "A review on early forest fire detection systems using optical remote sensing," *Sensors (Switzerland)*, vol. 20, no. 22, pp. 1–26, 2020, doi: 10.3390/s20226442.
- Pham, T. T., Dinh, T. T., Nguyen, T. D., Nguyen, D. D., & Cao, D. H. (2020). Wildfire susceptibility assessment using GIS and AHP in the Vu Quang National Park, Vietnam. *Environmental monitoring and assessment*, 192(12), 751.
- Pausas, J. G., Chuvieco, E., & Trigo, R. M. (2019). Rainfall influences on fire occurrence can be explained by the mean and the extremes. *Climatic Change*, 152(3), 699–711.
- Qian, J., Tao, S., Xu, B., Lu, X., Zhang, Y., Xie, G., & Liu, W. (2018). Land use change and the eco-environmental vulnerability on fire risk in Northeast China. *Environmental Pollution*, 243, 631–641.
- Rahmawati, R., Purwanto, H., & Nuruddin, A. A. (2019). Spatial analysis of forest fire risk in Aceh province using logistic regression. *Journal of Geoscience, Engineering, Environment, and Technology*, 4(2), 114–119.
- R. Dutta, A. Das, and J. Aryal, "Big data integration shows Australian bush-fire frequency is increasing significantly," *R. Soc. Open Sci.*, vol. 3, no. 2, 2016, doi: 10.1098/rsos.150241.
- R. Coughlan, F. Di Giuseppe, C. Vitolo, C. Barnard, P. Lopez, and M. Drusch, "Using machine learning to predict fire-ignition occurrences from lightning forecasts," *Meteorol. Appl.*, vol. 28, no. 1, pp. 1–16, 2021, doi: 10.1002/met.1973.
- R. Chen, Y. Luo, and M. R. Alsharif, "Forest fire detection algorithm based on digital image," *J. Softw.*, vol. 8, no. 8, pp. 1897–1905, 2013, doi: 10.4304/jsw.8.8.1897-1905.
- R. Rishickesh, A. Shahina, and A. Nayeemulla Khan, "Predicting forest fires using supervised and ensemble machine learning algorithms," *Int. J. Recent Technol. Eng.*, vol. 8, no. 2, pp. 3697–3705, 2019, doi: 10.35940/ijrte.B2878.078219.
- R. Perangin-angin, S. Simanullang, and D. R. Manalu, "PENINGKATAN PERFORMA ALGORITMAK-NEAREST NEIGBORD DALAM," vol. 6, no. 2, pp. 2–6, 2020.

- R. Perumal and T. L. V. Zyl. "Comparison of Recurrent Neural Network Architectures for Wildfire Spread Modelling," 2020 *Int. SAUPEC/RobMech/PRASA Conf. SAUPEC/RobMech/PRASA* 2020, vol. 2020-Janua, 2020, doi: 10.1109/SAUPEC/RobMech/PRASA48453.2020.9078028.
- Ribeiro, J. A., Santos, J. D., & Fiedler, N. C. (2018). Human-induced wildfires in Brazilian protected areas: a spatiotemporal analysis. *International Journal of Wildland Fire*, 27(3), 177-187.
- Ribeiro, G. H. P. M., Delgado, R. C., Dutra, L. V., & Rodrigues, C. G. (2018). Modelling the influence of topography on fire occurrence probability in a tropical savanna landscape. *Forest Ecology and Management*, 417, 31-40.
- Sari, N.K., Fatchurrochman, A., Kusnadi, N., & Masripatin, N. (2019). Predicting the occurrence of land fire in Indonesia using artificial neural network. *Procedia Computer Science*, 157, 231-238.
- Singh, G., Singh, J., & Singh, R. (2018). Forest fire susceptibility mapping using analytical hierarchy process (AHP) and frequency ratio (FR) models in the Shiwalik range of India. *Geocarto International*, 33(11), 1176-1195.
- Sivakumar, V., & Das, S. (2016). Exploring the role of meteorological variables in occurrence of forest fires: A case study of Karnataka, India. *Natural Hazards*, 81(3), 1735-1752.
- Suyanto, M., & Handayani, W. (2018). A support vector machine for prediction of forest fire in Riau Province, Indonesia. In *Journal of Physics: Conference Series* (Vol. 1007, No. 1, p. 012105). IOP Publishing.
- Suyanto, N. N., & Adnyana, I. K. (2017). Pengembangan model prediksi kebakaran hutan dan lahan menggunakan algoritma random forest. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 4(5), 413-419.
- S. Chakraborty and R. Pradhan, "Development of GIS based Landslide Information System for the Region of East Sikkim," *Int. J. Comput. Appl.*, vol. 49, no. 7, pp. 5-9, 2012, doi: 10.5120/7637-0720.
- S. T. Piralilou *et al.*, "A Google Earth Engine Approach for Wildfire Susceptibility Prediction Fusion with Remote Sensing Data of Different Spatial Resolutions," *Remote Sens.*, vol. 14, no. 3, pp. 1-26, 2022, doi: 10.3390/rs14030672.
- S. B. KUKUK and Z. H. KILIMCI, "Comprehensive Analysis of Forest Fire Detection using Deep Learning Models and Conventional Machine Learning Algorithms," *Int. J. Comput. Exp. Sci. Eng.*, vol. 7, no. 2, pp. 84-94, 2021, doi: 10.22399/ijcesen.950045.
- S. Yang, M. Lupascu, and K. S. Meel, "Predicting Forest Fire Using Remote Sensing Data And Machine Learning," *35th AAAI Conf. Artif. Intell. AAAI 2021*, vol. 17A, pp. 14983-14990, 2021.
- S. K. Bandyopadhyay, "Journal of Global Research in Computer Science Available Online at www.jgrcs.info Detection of Brain Tumor-A Proposed Method," vol. 2, no. 6, pp. 55-63, 2011.
- S. Zheng, P. Gao, W. Wang, and X. Zou, "applied sciences A Highly Accurate Forest Fire Prediction Model Based on an Improved Dynamic Convolutional Neural Network," 2022.
- S. Trivedi, Z. A. Pardos, and N. T. Heffernan, "The Utility of Clustering in Prediction Tasks," no. September, pp. 1-11, 2015, [Online]. Available: <http://arxiv.org/abs/1509.06163>
- S. Cheng *et al.*, "Techniques : Forward and Inverse Modelling," pp. 1-24, 2022.

- S. Sakellariou, A. Sfougaris, and O. Christopoulou, "Review of geoinformatics-based forest fire management tools for integrated fire analysis," *Polish J. Environ. Stud.*, vol. 30, no. 6, pp. 5423–5434, 2021, doi: 10.15244/pjoes/135614.
- S. McLemore, "Spatio-Temporal Analysis of Wildfire Incidence in the State of Florida," no. May, p. 102 pp, 2017.
- S. M. Pasha and U. Lisha, "Forest fire prediction using ML and AI," vol. 7, no. 3, pp. 2197–2200, 2021.
- Saruni Dwiasnati and Yudo Devianto, "Classification of forest fire areas using machine learning algorithm," *World J. Adv. Eng. Technol. Sci.*, vol. 3, no. 1, pp. 008–015, 2021, doi: 10.30574/wjaets.2021.3.1.0048.
- S. Sukanto, I. D. Id, and T. R. Angrani, "Penentuan Daerah Rawan Titik Api di Provinsi Riau Menggunakan Clustering Algoritma K-Means," *JUITA J. Inform.*, vol. 6, no. 2, p. 137, 2018, doi: 10.30595/juita.v6i2.3172.
- S. S. Nagari and L. Inayati, "Implementation of Clustering Using K-Means Method To Determine Nutritional Status," *J. Biometrika dan Kependud.*, vol. 9, no. 1, p. 62, 2020, doi: 10.20473/jbk.v9i1.2020.62-68.
- S. Sakellariou *et al.*, "Remotely sensed data fusion for spatiotemporal geostatistical analysis of forest fire hazard," *Sensors (Switzerland)*, vol. 20, no. 17, pp. 1–20, 2020, doi: 10.3390/s20175014.
- S. R. kalli Srinivasa Nageswara Prasad, "An autonomous forest fire detection system based on spatial data mining and fuzzy logic," *IJCSNS Int. J. Comput. Sci. Netw. Secur.*, vol. 8, no. 12, pp. 49–55, 2008.
- T. U. Rehman, M. S. Mahmud, Y. K. Chang, J. Jin, and J. Shin, "Current and future applications of statistical machine learning algorithms for agricultural machine vision systems," *Comput. Electron. Agric.*, vol. 156, pp. 585–605, 2019, doi: <https://doi.org/10.1016/j.compag.2018.12.006>.
- T. Cheng and J. Wang, "Applications of spatio-temporal data mining and knowledge discovery (STDMKD) for forest fire prevention," *Proc. Int. Soc. Photogramm. Remote Sensing*, No. 7, p. 6, 2005, [Online]. Available: www.isprs.org/proceedings/XXXVI/part7/PDF/148.pdf
- T. B. Nugroho and E. Sugiharti, "The Improvement of C4.5 Algorithm Accuracy in Predicting Forest Fires Using Discretization and AdaBoost," *J. Adv. Inf. ...*, vol. 3, no. April, pp. 43–52, 2021, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/jaist/article/view/49094>
- Tripathi, A., Singh, A. K., Singh, R., & Srivastava, P. K. (2018). Assessing forest fire susceptibility of forest ranges in India using geospatial techniques. *Journal of Environmental Management*, 217, 69–80.
- U. Dampage, L. Bandaranayake, R. Wanasinghe, K. Kottahachchi, and B. Jayasanka, "Forest fire detection system using wireless sensor networks and machine learning," *Sci. Rep.*, vol. 12, no. 1, pp. 1–11, 2022, doi: 10.1038/s41598-021-03882-9.
- V. Kallimani, B. Chandra, N. Vyas, and J. Kallimani, "GIS based real time assessment of wildfire and other changes in a forest: A review," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 20, no. 1, 2014, doi: 10.1088/1755-1315/20/1/012022.
- Wang, X., & Yan, J. (2018). Wildfire Risk Assessment of Transmission-Line Corridors Based on Naïve Bayes Network and Remote Sensing Data. *Sustainability*, 10(8), 2757, <https://doi.org/10.3390/s21020634>

- Wang, Z., Yang, J., Li, Y., Zhang, L., & Guo, Q. (2019). Analysis of factors affecting forest fire occurrence in mountainous areas: a case study in the Liupan Mountains, China. *Forests*, 10(5), 433.
- Wang, Y., Li, J., & Zhu, Y. (2020). Spatial analysis of forest fire occurrence and its influencing factors in Yunnan Province, China. *Environmental Monitoring and Assessment*, 192(9), 1-12.
- Wang, Y., Zheng, X., Li, C., Ma, T., & Li, X. (2019). Support vector machine classification of forest fire susceptibility using meteorological and remote sensing data. In 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC) (pp. 1326-1331). IEEE.
- Wei, J., Zhu, Q., & Liu, L. (2019). Forest fire prediction model based on deep belief network. *Journal of Forestry Research*, 30(3), 835-842.
- W. C. Tam *et al.*, "Generating Synthetic Sensor Data to Facilitate Machine Learning Paradigm for Prediction of Building Fire Hazard," *Fire Technol.*, 2020, doi: 10.1007/s10694-020-01022-9.
- W. Mee, "Appendix 1," *Cross-border Mobil.*, pp. 235-236, 2022, doi: 10.1017/9789048544936.010.
- W. Chen, Y. Zhou, E. Zhou, Z. Xiang, W. Zhou, and J. Lu, "Wildfire risk assessment of transmission-line corridors based on naïve bayes network and remote sensing data," *Sensors (Switzerland)*, vol. 21, no. 2, pp. 1-16, 2021, doi: 10.3390/s21020634.
- X. Zhang, Q. Zhou, S. Weng, and H. Zhang, "ARIMA Model-Based Fire Rescue Prediction," *Sci. Program.*, vol. 2021, 2021, doi: 10.1155/2021/3212138.
- X. C. Chen *et al.*, "A new data mining framework for forest fire mapping," *Proc. - 2012 Conf. Intell. Data Understanding, CIDU 2012*, pp. 104-111, 2012, doi: 10.1109/CIDU.2012.6382190.
- Yacob, S., Annuar, N.A., Ramli, M.F., & Ibrahim, K. (2020). Hybrid support vector regression and decision tree algorithm for forest fire prediction in Malaysia. *Environmental Science and Pollution Research*, 27(16), 19203-19216.
- Y. Fu, H. S. He, T. J. Hawbaker, P. D. Henne, Z. Zhu, and D. R. Larsen, "Evaluating k-nearest neighbor (kNN) imputation models for species-level aboveground forest biomass mapping in Northeast China," *Remote Sens.*, vol. 11, no. 17, 2019, doi: 10.3390/rs11172005.
- Y. P. Yu, R. Omar, R. D. Harrison, M. K. Sammathuria, and A. R. Nik, "Pattern clustering of forest fires based on meteorological variables and its classification using hybrid data mining methods," *J. Comput. Biol. Bioinforma. Res.*, vol. 3, no. July, pp. 47-52, 2011.
- Yulianto, E., Darma, I. D. S., & Yonariza. (2020). Analisis Faktor-Faktor yang Berpengaruh Terhadap Kebakaran Hutan dan Lahan Menggunakan Metode Regresi Logistik di Kabupaten Batanghari. *Jurnal Sumberdaya Alam dan Lingkungan*, 4(2), 146-155.
- Zhang, Y., Han, L., Wang, S., Zhou, T., Li, H., Chen, Y., & Jia, K. (2019). Wildfire risk assessment of transmission-line corridors based on naïve bayes network and remote sensing data. *Forests*, 10(7), 593. doi: 10.3390/f10070593.
- Z. Somogyi, "Performance Evaluation of Machine Learning Models," *Appl. Artif. Intell.*, vol. 11, no. 6, pp. 87-112, 2021, doi: 10.1007/978-3-030-60032-7_3.
- Z. Mohammed, C. Hanae, and S. Larbi, "Comparative study on machine learning algorithms for early fire forest detection system using geodata," *Int. J. Electr. Comput. Eng.*, vol. 10, no. 5, pp. 5507-5513, 2020, doi: 10.11591/IJECE.V10I5.PP5507-5513.

- Z. Chen, J. Goldwasser, P. Tuckman, J. Liu, J. Zhang, and M. Gerstein, "Forest Fire Clustering for single-cell sequencing combines iterative label propagation with parallelized Monte Carlo simulations," *Nat. Commun.*, vol. 13, no. 1, pp. 1–13, 2022, doi: 10.1038/s41467-022-31107-8.
- Zahabu, E., Mwampamba, T. H., & Rautiainen, M. (2019). Does economic growth contribute to forest cover loss? Evidence from Tanzania. *Land Use Policy*, 81, 820-829.
- Zhang, X., Chen, J., Zhu, X., Xie, L., & Tang, Y. (2018). The application of random forest model to forest fire risk assessment in Shangri-La, Yunnan Province, China. *Remote Sensing*, 10(10), 1623.
- Zhao, X., Yang, J., Li, Y., Zhang, S., Liu, B., & Xie, H. (2018). Spatiotemporal pattern of forest fire danger in China: Influences of climate change, fuel types, and human activity. *Forest Ecology and Management*, 409, 589-599.
- Zhu, Z., Liu, Y., Xu, W., He, H. S., & Zhu, Q. (2019). The spatiotemporal patterns and drivers of wildfire occurrence in California: from 1992 to 2015. *International Journal of Wildland Fire*, 28(0), 672-684.

PUSTAKA LAPORAN PENELITIAN


Nama peneliti, tahun, judul, jenis penelitian, nama lembaga, kota

- Kurniawan, M. P., 2011, Teknologi Motion Capture dengan Multi Kamera pada Pembuatan Animasi 3D, Tesis, S2 Teknik Informatika, STMIK AMIKOM, Yogyakarta

PUSTAKA ELEKTRONIK

- C. Brun Sorribas, "A comprehensive methodology to predict forest res behavior using complementary models," 2014, [Online]. Available: <https://widgets.cbseohost.com/prod/customerspecific/ns000545/customproxy.php?url=http://search.cbseohost.com/login.aspx?direct=true&db=cddstdx&AN=cddstdx.10803.283359&ump%0Alang=pt-pt&site=cdd-live&scope=site>
- D. Stojanova, A. Kobler, S. Džeroski, and K. Taskova, "<10.1.1.116.2555.Pdf>," pp. 3–6, [Online]. Available: [https://s3.amazonaws.com/academia.edu.documents/30570649/10.1.1.116.2555.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1556778911&Signature=INoK%2B2cjFfu4QgmFQA5tZMSP%2B7Q%3D&response-content-disposition=inline%3Bfilename%3DLEARNING TO PREDICT FOREST F F. Anwer, "Fireinform: An Approach to Predict Hourly Forest Fire Occurrences using Multivariate Time Series Classification," no. March, 2021, \[Online\]. Available: <https://ourspace.uregina.ca/handle/10294/14317>](https://s3.amazonaws.com/academia.edu.documents/30570649/10.1.1.116.2555.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1556778911&Signature=INoK%2B2cjFfu4QgmFQA5tZMSP%2B7Q%3D&response-content-disposition=inline%3Bfilename%3DLEARNING%20TO%20PREDICT%20FOREST%20F%20F%20Fireinform%3DAn%20Approach%20to%20Predict%20Hourly%20Forest%20Fire%20Occurrences%20using%20Multivariate%20Time%20Series%20Classification.pdf)
- J. O. Otieno, "A machine learning algorithm for predicting wild fire occurrence," 2020, [Online]. Available: <https://su-plus.strathmore.edu/handle/11071/12085>
- P. Cortez and A. Morais, "A Data Mining Approach to Predict Forest Fires using Meteorological Data," *Proc. 13th Part. Conf. Artif. Intell.*, no. January 2007, pp. 512–523, 2007, [Online]. Available: <http://www.dsi.uminho.pt/~pcortez/fires.pdf>
- S. Trivedi, Z. A. Pardos, and N. T. Heffernan, "The Utility of Clustering in Prediction Tasks," no. September, pp. 1–11, 2015, [Online]. Available: <http://arxiv.org/abs/1509.06163>

LAMPIRAN



```

...PROJECT\Script\worker-prakiraan-cuaca-menlhk\index.js 1
1 "use strict";
2 require('dotenv').config();
3 const dayjs = require('dayjs');
4 const { DB } = require('./service/postgres');
5 const axios = require('axios');
6
7 (async () => {
8   console.log(`${process.env.APP_NAME} Running @ ${dayjs().format('DD/  ↗
9   console.log(`${DB MODULE}[${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] =>  ↗
10   CHECKING DB CONNECTION');
11
12   try {
13     let db = new DB(1);
14     await db.init();
15     await db.query('SELECT 1');
16     console.log(`${DB MODULE}[${dayjs().format('DD/MM/YYYY H:mm:ss  ↗
17     Z')}] => DB CONNECTED');
18     db.end();
19   } catch (e) {
20     console.log(`${DB MODULE}[${dayjs().format('DD/MM/YYYY H:mm:ss  ↗
21     Z')}] => DB CONNECTION ERROR', e);
22     process.exit(1);
23   }
24
25   let data = await getData();
26   let db = new DB(20);
27   await db.init();
28
29   // INSERT TO prakiraancuaca_menlhk_history
30   let current_data = await db.query('SELECT * FROM  ↗
31   prakiraancuaca_menlhk');
32
33   if (current_data.rows.length > 0) {
34     current_data = current_data.rows;
35     // GET LAST OBJECTID FROM HISTORY
36     let history_objectid = 0;
37     let last_objectid = await db.query('SELECT objectid FROM  ↗
38     prakiraancuaca_menlhk_history ORDER BY objectid DESC LIMIT 1');
39     if (last_objectid.rows.length > 0) {
40       last_objectid = last_objectid.rows[0];
41       history_objectid = last_objectid.objectid;
42     }
43
44     let success_history = 0;
45     for (let cd of current_data) {
46       cd.objectid = history_objectid + 1;
47       try {
48         await db.query('INSERT INTO prakiraancuaca_menlhk_history  ↗

```

```

...PROJECT\Script\worker-prakiraan-cuaca-menlhk\index.js 2
    (${Object.keys(cd).join(', ')} VALUES (${Object.keys
    (cd).map((item, index) => `${index + 1}`).join(', ')}))
    ', Object.keys(cd).map((key) => cd[key]));
44    success_history++;
45    console.log('[DB PRAKIRAAN CUACA MENLHK HISTORY] => DATA
    INSERTED ${success_history}');
46    history_objectid++
47  } catch (e) {
48    console.error(e);
49  }
50  }
51
52  await db.query('DELETE FROM prakiraancuaca_menlhk');
53  }
54
55  let success = 0;
56  for (let item of data) {
57    let el = { ...item };
58    let coords = el.coords;
59    let str_coords = '';
60    for (let i = 0; i < coords.length; i++) {
61      let coord = coords[i];
62
63      str_coords += '('
64      for (let y = 0; y < coord.length; y++) {
65        str_coords += `${coord[y][0]} ${coord[y][1]},'
66      }
67      str_coords = str_coords.slice(0, -1);
68      str_coords += '),';
69    }
70    str_coords = str_coords.slice(0, -1);
71
72    let shape = 'st_multipolygon('multipolygon ((${str_coords})),
    4326)';
73
74    // INSERT TO prakiraancuaca_menlhk
75    delete el.coords;
76    el.objectid = success + 1;
77    try {
78      await db.query('INSERT INTO prakiraancuaca_menlhk
    (${Object.keys(el).join(', ')}, shape) VALUES (${Object.keys
    (el).map((item, index) => `${index + 1}`).join(', ')}),
    ${shape})', Object.keys(el).map((key) => el[key]));
79      success++;
80      console.log('[DB PRAKIRAAN CUACA MENLHK] => DATA INSERTED
    ${success}/${data.length}');
81    } catch (e) {
82      console.log(e);
83    }

```



```
84     }
85     db.end();
86   })();
87
88   const getData = async () => {
89     console.log('[APP] => GET DATA FROM API')
90     let data = await axios.get(process.env.URL_API);
91     console.log('[APP] => GET DATA COMPLETE');
92     data = data.data.data;
93     let rows = [];
94     for (let el of data) {
95       let publishedat = el.publishedAt;
96       let coords = el.area.geometry.coordinates;
97       if (!coords) {
98         console.log(el);
99       }
100       let event = el.event;
101       let category = el.area.properties.category;
102
103       let row = {
104         publishedat,
105         coords,
106         event,
107         category
108       }
109
110       let impacted = el.impacted;
111       for (let key in impacted) {
112         let provinsi = key;
113         for (let kabupaten in impacted[key]) {
114           for (let kecamatan of impacted[provinsi][kabupaten]) {
115             row.impacted = `${provinsi} | ${kabupaten} |  

116               ${kecamatan}`;
117             rows.push(row);
118           }
119         }
120       }
121     }
122     return rows;
123   }
```

```

...T\FIRE PREDICTION PROJECT\Script\worker-bmkg\index.js 1
1 "use strict";
2 require('dotenv').config();
3 const dayjs = require('dayjs');
4 const CUACA = require('./helper/cuaca');
5 const { DB } = require('./service/postgres');
6
7 (async () => {
8   console.log(`${process.env.APP_NAME} Running @ ${dayjs().format('DD/MM/
9     YYYY H:mm:ss Z')}`);
10   console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] =>
11     CHECKING DB CONNECTION`);
12
13   try {
14     let db = new DB(1);
15     await db.init();
16     await db.query('SELECT 1');
17     console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}]
18       => DB CONNECTED`);
19     db.end();
20   } catch (e) {
21     console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}]
22       => DB CONNECTION ERROR`, e);
23     process.exit(1);
24   }
25
26   CUACA.sync();
27 })();

```

```

... PROJECT\Script\worker-kualitas-udara-menlhk\index.js 1
1 "use strict";
2 require('dotenv').config();
3 const dayjs = require('dayjs');
4 const { DB } = require('./service/postgres');
5 const axios = require('axios');
6
7 (async () => {
8   console.log(`${process.env.APP_NAME} Running @ ${dayjs().format('DD/MM/
9     VVVV H:mm:ss Z')}`);
10   console.log(`[DB MODULE][${dayjs().format('DD/MM/VVVV H:mm:ss Z')}] =>
11     CHECKING DB CONNECTION`);
12
13   try {
14     let db = new DB(1);
15     await db.init();
16     await db.query('SELECT 1');
17     console.log(`[DB MODULE][${dayjs().format('DD/MM/VVVV H:mm:ss Z')}] =>
18       DB CONNECTED`);
19     db.end();
20   } catch (e) {
21     console.log(`[DB MODULE][${dayjs().format('DD/MM/VVVV H:mm:ss Z')}] =>
22       DB CONNECTION ERROR`, e);
23     process.exit(1);
24   }
25
26   let data = await getData();
27
28   let db = new DB(20);
29   await db.init();
30
31   // INSERT TO kualitasudara_menlhk_history
32   let current_data = await db.query('SELECT * FROM
33     kualitasudara_menlhk');
34
35   if (current_data.rows.length > 0) {
36     current_data = current_data.rows;
37     // GET LAST OBJECTID FROM HISTORY
38     let history_objectid = 0;
39     let last_objectid = await db.query('SELECT objectid FROM
40     kualitasudara_menlhk_history ORDER BY objectid DESC LIMIT 1');
41     if (last_objectid.rows.length > 0) {
42       last_objectid = last_objectid.rows[0];
43       history_objectid = last_objectid.objectid;
44     }
45
46     let success_history = 0;
47     for (let cd of current_data) {
48       cd.objectid = history_objectid + 1;
49       try {

```

```

... PROJECT\Script\worker-kualitas-udara-menlhk\index.js 2
44     await db.query('INSERT INTO kualitasudara_menlhk_history
    (${Object.keys(cd).join(', ')} VALUES (${Object.keys
    (cd).map((item, index) => `${index + 1}`).join(', ')}',
    Object.keys(cd).map((key) => cd[key]));
45     success_history++;
46     console.log('[DB TITIK API HISTORY] => DATA INSERTED
    ${success_history}');
47     history_objectid++
48   } catch (e) {
49     console.error(e);
50   }
51 }
52
53   await db.query('DELETE FROM kualitasudara_menlhk');
54 }
55
56 // INSERT TO kualitasudara_menlhk
57 let success = 0;
58 for (let el of data) {
59   let shape = 'ST_Point('point (${el.coords.join(' ')}', 4326)';
60   delete el.coords;
61   el.objectid = success + 1;
62   try {
63     await db.query('INSERT INTO kualitasudara_menlhk (${Object.keys
    (el).join(', ')}, shape) VALUES (${Object.keys(el).map((item,
    index) => `${index + 1}`).join(', ')}, ${shape})',
    Object.keys(el).map((key) => el[key]));
64     success++;
65     console.log('[DB KUALITAS UDARA MENLHK] => DATA INSERTED
    ${success}/${data.length}');
66   } catch (e) {
67     console.log(e);
68   }
69 }
70
71 db.end();
72 })());
73
74 const getData = async () => {
75   console.log('[APP] => GET DATA FROM API')
76   let data = await axios.get(process.env.URL_API);
77   // let data = await axios.get('http://103.51.131.166/getH5?
    $hashKey=object:34&class=hotspot&conf_lvl=low&enddate=2021-12-07T17:0
    0:00.000Z&id=0&loc=%7B%22stt%22:%22Indonesia%22,%22disp%22:%
    22Indonesia%22%
    7D&mode=cluster&name=Hotspot&startdate=2021-11-05T17:00:00.000Z&time=
    usedate&visibility=true');
78   console.log('[APP] => GET DATA COMPLETE')
79   let rows = [];

```



```
80   for (let el of data.data.features) {  
81     let coords = el.geometry.coordinates;  
82     let row = {  
83       coords,  
84       ...el.properties  
85     }  
86     rows.push(row);  
87   }  
88   return rows;  
89 }
```



```

... \ACTION PROJECT\Script\worker-lapan-titik-api\index.js 1
1  "use strict";
2  require('dotenv').config();
3  const dayjs = require('dayjs');
4  const { DB } = require('./service/postgres');
5  const axios = require('axios');
6
7  (async () => {
8    console.log(`${process.env.APP_NAME} Running @ ${dayjs().format('DD/  ↗
MM/YYYY H:mm:ss Z')}`);
9    console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] =>  ↗
CHECKING DB CONNECTION`);
10
11    try {
12      let db = new DB(1);
13      await db.init();
14      await db.query('SELECT 1');
15      console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss  ↗
Z')}] => DB CONNECTED`);
16      db.end();
17    } catch (e) {
18      console.log(`[DB MODULE][${dayjs().format('DD/MM/YYYY H:mm:ss  ↗
Z')}] => DB CONNECTION ERROR`, e);
19      process.exit(1);
20    }
21
22    sync();
23
24    console.log('[APP] => INTERVAL REGISTERED');
25    setInterval(async () => {
26      console.log(`[APP][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] =>  ↗
AUTO SYNC START`);
27      await sync();
28      console.log(`[APP][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] =>  ↗
AUTO SYNC END`);
29    }, 1000 * 60 * 5)
30  })();
31
32  const sync = async () => {
33    console.log(`[APP][${dayjs().format('DD/MM/YYYY H:mm:ss Z')}] => START  ↗
SYNC`);
34    let data = await getData();
35
36    let db = new DB(20);
37    await db.init();
38    // INSERT TO titik_api_history
39    let current_data = await db.query('SELECT * FROM titik_api');
40
41    if (current_data.rows.length > 0) {
42      current_data = current_data.rows;

```

```

43 // GET LAST OBJECTID FROM HISTORY
44 let history_objectid = 0;
45 let last_objectid = await db.query('SELECT objectid FROM
titik_api_history ORDER BY objectid DESC LIMIT 1');
46 if (last_objectid.rows.length > 0) {
47     last_objectid = last_objectid.rows[0];
48     history_objectid = last_objectid.objectid;
49 }
50
51 let success_history = 0;
52 for (let cd of current_data) {
53     cd.objectid = history_objectid + 1;
54     try {
55         await db.query('INSERT INTO titik_api_history
        (${Object.keys(cd).join(', ')} VALUES (${Object.keys
        (cd).map((item, index) => `${index + 1}`).join(', ')}
        ', Object.keys(cd).map((key) => cd[key]));
56         success_history++;
57         console.log('[DB TITIK API HISTORY] => DATA INSERTED
        ${success_history}');
58         history_objectid++;
59     } catch (e) {
60         console.error(e);
61     }
62 }
63
64 await db.query('DELETE FROM titik_api');
65 }
66
67 // INSERT TO titik_api
68 let success = 0;
69 for (let el of data) {
70     let shape = 'ST_Point('point (${el.coords.join(' ')}', 4326)';
71     delete el.coords;
72     el.objectid = success + 1;
73     try {
74         await db.query('INSERT INTO titik_api (${Object.keys(el).join
        ('', ')}, shape) VALUES (${Object.keys(el).map((item, index)
        => `${index + 1}`).join(', ')}, ${shape})', Object.keys
        (el).map((key) => el[key]));
75         success++;
76         console.log('[DB TITIK API] => DATA INSERTED ${success}/
        ${data.length}');
77     } catch (e) {
78         console.log(e);
79     }
80 }
81
82 db.end();

```

```


83 }
84
85 const getData = async () => {
86   console.log('[APP] => GET DATA FROM API')
87   let data = await axios.get(process.env.URL_API + '/getHS?$
    $hashKey=object:34&class=hotspot&conf_lvl=low&enddate=&id=0&loc=%7B%
    22stt%22:%22Indonesia%22,%22disp%22:%22Indonesia%22%
    7D&mode=cluster&name=Hotspot&startdate=&time=last24h&visibility=true
    ');
88   // let data = await axios.get('http://103.51.131.166/getHS?$
    $hashKey=object:34&class=hotspot&conf_lvl=low&enddate=2021-12-07T17:
    00:00.000Z&id=0&loc=%7B%22stt%22:%22Indonesia%22,%22disp%22:%
    22Indonesia%22%
    7D&mode=cluster&name=Hotspot&startdate=2021-11-05T17:00:00.000Z&time
    =usedate&visibility=true');
89   console.log('[APP] => GET DATA COMPLETE')
90   let rows = [];
91   let total_data = data.data.features.length;
92   let index = 0;
93   for (let el of data.data.features) {
94     let coords = el.geometry.coordinates;
95     let id = el.id;
96
97     // GET DETAIL DATA
98     console.log('[APP] => GET DETAIL DATA FROM API');
99     let detail_data = await axios.get(process.env.URL_API + '/
    getHSdetail?hsid=${id}&mode=cluster');
100    console.log('[APP] => GET DETAIL DATA COMPLETE ${index + 1}/
    ${total_data}');
101    detail_data = detail_data.data;
102
103    // FORMAT SATELIT NAME
104    let satelit = detail_data.sat;
105    let sensor = null;
106    let kanal = null;
107    let resolusi_spasial = null;
108    let kepercayaan = null;
109
110    if (satelit == 'Noaa20') {
111      satelit = 'NOAA-20';
112      sensor = 'VIIRS';
113      kanal = 'Kanal I4 ( 3550 - 3930 nm)';
114      resolusi_spasial = '375 meter';
115
116      if (detail_data.conf <= 7) {
117        kepercayaan = 'Rendah';
118      } else if (detail_data.conf <= 8) {
119        kepercayaan = 'Medium';
120      } else if (detail_data.conf <= 9) {

```



```
121         kepercayaan = 'Tinggi';
122     }
123
124     } else if (satelit == 'Snpp') {
125         satelit = 'S-NPP';
126         sensor = 'VIIRS';
127         kanal = 'Kanal I4 ( 3550 - 3930 nm)';
128         resolusi_spasial = '375 meter';
129
130         if (detail_data.conf <= 7) {
131             kepercayaan = 'Rendah';
132         } else if (detail_data.conf <= 8) {
133             kepercayaan = 'Medium';
134         } else if (detail_data.conf <= 9) {
135             kepercayaan = 'Tinggi';
136         }
137
138     } else if (satelit == 'Landsat8') {
139         satelit = 'Landsat-8';
140         sensor = 'OLI';
141         kanal = 'Kanal 7 (2100 - 2300 nm)';
142         resolusi_spasial = '30 meter';
143
144         if (detail_data.conf <= 7) {
145             kepercayaan = 'Rendah';
146         } else if (detail_data.conf <= 8) {
147             kepercayaan = 'Medium';
148         } else if (detail_data.conf <= 9) {
149             kepercayaan = 'Tinggi';
150         }
151
152     } else if (satelit == 'Terra') {
153         satelit = 'Terra';
154         sensor = 'MODIS';
155         kanal = 'Kanal 21 dan 22 ( 3020 - 3980 nm)';
156         resolusi_spasial = '1000 meter';
157
158         if (detail_data.conf <= 29) {
159             kepercayaan = 'Rendah';
160         } else if (detail_data.conf >= 30 && detail_data.conf <= 79) {
161             kepercayaan = 'Medium';
162         } else if (detail_data.conf >= 80 && detail_data.conf <= 100) {
163             kepercayaan = 'Tinggi';
164         }
165
166     } else if (satelit == 'Aqua') {
167         satelit = 'Aqua';
168         sensor = 'MODIS';
```

```
169     kanal = 'Kanal 21 dan 22 ( 3929 - 3989 nm)';
170     resolusi_spasial = '1000 meter';
171
172     if (detail_data.conf <= 29) {
173         kepercayaan = 'Rendah';
174     } else if (detail_data.conf >= 30 && detail_data.conf <= 79) {
175         kepercayaan = 'Medium';
176     } else if (detail_data.conf >= 80 && detail_data.conf <= 100) {
177         kepercayaan = 'Tinggi';
178     }
179 }
180
181 let row = {
182     hsid: id,
183     loc: detail_data.loc,
184     satelit: detail_data.sat,
185     date: dayjs(detail_data.time),
186     kepercayaan,
187     satelit,
188     sensor,
189     kanal,
190     res: resolusi_spasial,
191     conf: detail_data.conf,
192     coords
193 }
194
195 rows.push(row);
196 index++;
197 }
198
199 return rows;
200 }
```



Lampiran 5. Sampel data hasil join

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100	101	102	103	104	105	106	107	108	109	110	111	112	113	114	115	116	117	118	119	120	121	122	123	124	125	126	127	128	129	130	131	132	133	134	135	136	137	138	139	140	141	142	143	144	145	146	147	148	149	150	151	152	153	154	155	156	157	158	159	160	161	162	163	164	165	166	167	168	169	170	171	172	173	174	175	176	177	178	179	180	181	182	183	184	185	186	187	188	189	190	191	192	193	194	195	196	197	198	199	200	201	202	203	204	205	206	207	208	209	210	211	212	213	214	215	216	217	218	219	220	221	222	223	224	225	226	227	228	229	230	231	232	233	234	235	236	237	238	239	240	241	242	243	244	245	246	247	248	249	250	251	252	253	254	255	256	257	258	259	260	261	262	263	264	265	266	267	268	269	270	271	272	273	274	275	276	277	278	279	280	281	282	283	284	285	286	287	288	289	290	291	292	293	294	295	296	297	298	299	300	301	302	303	304	305	306	307	308	309	310	311	312	313	314	315	316	317	318	319	320	321	322	323	324	325	326	327	328	329	330	331	332	333	334	335	336	337	338	339	340	341	342	343	344	345	346	347	348	349	350	351	352	353	354	355	356	357	358	359	360	361	362	363	364	365	366	367	368	369	370	371	372	373	374	375	376	377	378	379	380	381	382	383	384	385	386	387	388	389	390	391	392	393	394	395	396	397	398	399	400	401	402	403	404	405	406	407	408	409	410	411	412	413	414	415	416	417	418	419	420	421	422	423	424	425	426	427	428	429	430	431	432	433	434	435	436	437	438	439	440	441	442	443	444	445	446	447	448	449	450	451	452	453	454	455	456	457	458	459	460	461	462	463	464	465	466	467	468	469	470	471	472	473	474	475	476	477	478	479	480	481	482	483	484	485	486	487	488	489	490	491	492	493	494	495	496	497	498	499	500	501	502	503	504	505	506	507	508	509	510	511	512	513	514	515	516	517	518	519	520	521	522	523	524	525	526	527	528	529	530	531	532	533	534	535	536	537	538	539	540	541	542	543	544	545	546	547	548	549	550	551	552	553	554	555	556	557	558	559	560	561	562	563	564	565	566	567	568	569	570	571	572	573	574	575	576	577	578	579	580	581	582	583	584	585	586	587	588	589	590	591	592	593	594	595	596	597	598	599	600	601	602	603	604	605	606	607	608	609	610	611	612	613	614	615	616	617	618	619	620	621	622	623	624	625	626	627	628	629	630	631	632	633	634	635	636	637	638	639	640	641	642	643	644	645	646	647	648	649	650	651	652	653	654	655	656	657	658	659	660	661	662	663	664	665	666	667	668	669	670	671	672	673	674	675	676	677	678	679	680	681	682	683	684	685	686	687	688	689	690	691	692	693	694	695	696	697	698	699	700	701	702	703	704	705	706	707	708	709	710	711	712	713	714	715	716	717	718	719	720	721	722	723	724	725	726	727	728	729	730	731	732	733	734	735	736	737	738	739	740	741	742	743	744	745	746	747	748	749	750	751	752	753	754	755	756	757	758	759	760	761	762	763	764	765	766	767	768	769	770	771	772	773	774	775	776	777	778	779	780	781	782	783	784	785	786	787	788	789	790	791	792	793	794	795	796	797	798	799	800	801	802	803	804	805	806	807	808	809	810	811	812	813	814	815	816	817	818	819	820	821	822	823	824	825	826	827	828	829	830	831	832	833	834	835	836	837	838	839	840	841	842	843	844	845	846	847	848	849	850	851	852	853	854	855	856	857	858	859	860	861	862	863	864	865	866	867	868	869	870	871	872	873	874	875	876	877	878	879	880	881	882	883	884	885	886	887	888	889	890	891	892	893	894	895	896	897	898	899	900	901	902	903	904	905	906	907	908	909	910	911	912	913	914	915	916	917	918	919	920	921	922	923	924	925	926	927	928	929	930	931	932	933	934	935	936	937	938	939	940	941	942	943	944	945	946	947	948	949	950	951	952	953	954	955	956	957	958	959	960	961	962	963	964	965	966	967	968	969	970	971	972	973	974	975	976	977	978	979	980	981	982	983	984	985	986	987	988	989	990	991	992	993	994	995	996	997	998	999	1000	1001	1002	1003	1004	1005	1006	1007	1008	1009	1010	1011	1012	1013	1014	1015	1016	1017	1018	1019	1020	1021	1022	1023	1024	1025	1026	1027	1028	1029	1030	1031	1032	1033	1034	1035	1036	1037	1038	1039	1040	1041	1042	1043	1044	1045	1046	1047	1048	1049	1050	1051	1052	1053	1054	1055	1056	1057	1058	1059	1060	1061	1062	1063	1064	1065	1066	1067	1068	1069	1070	1071	1072	1073	1074	1075	1076	1077	1078	1079	1080	1081	1082	1083	1084	1085	1086	1087	1088	1089	1090	1091	1092	1093	1094	1095	1096	1097	1098	1099	1100	1101	1102	1103	1104	1105	1106	1107	1108	1109	1110	1111	1112	1113	1114	1115	1116	1117	1118	1119	1120	1121	1122	1123	1124	1125	1126	1127	1128	1129	1130	1131	1132	1133	1134	1135	1136	1137	1138	1139	1140	1141	1142	1143	1144	1145	1146	1147	1148	1149	1150	1151	1152	1153	1154	1155	1156	1157	1158	1159	1160	1161	1162	1163	1164	1165	1166	1167	1168	1169	1170	1171	1172	1173	1174	1175	1176	1177	1178	1179	1180	1181	1182	1183	1184	1185	1186	1187	1188	1189	1190	1191	1192	1193	1194	1195	1196	1197	1198	1199	1200	1201	1202	1203	1204	1205	1206	1207	1208	1209	1210	1211	1212	1213	1214	1215	1216	1217	1218	1219	1220	1221	1222	1223	1224	1225	1226	1227	1228	1229	1230	1231	1232	1233	1234	1235	1236	1237	1238	1239	1240	1241	1242	1243	1244	1245	1246	1247	1248	1249	1250	1251	1252	1253	1254	1255	1256	1257	1258	1259	1260	1261	1262	1263	1264	1265	1266	1267	1268	1269	1270	1271	1272	1273	1274	1275	1276	1277	1278	1279	1280	1281	1282	1283	1284	1285	1286	1287	1288	1289	1290	1291	1292	1293	1294	1295	1296	1297	1298	1299	1300	1301	1302	1303	1304	1305	1306	1307	1308	1309	1310	1311	1312	1313	1314	1315	1316	1317	1318	1319	1320	1321	1322	1323	1324	1325	1326	1327	1328	1329	1330	1331	1332	1333	1334	1335	1336	1337	1338	1339	1340	1341	1342	1343	1344	1345	1346	1347	1348	1349	1350	1351	1352	1353	1354	1355	1356	1357	1358	1359	1360	1361	1362	1363	1364	1365	1366	1367	1368	1369	1370	1371	1372	1373	1374	1375	1376	1377	1378	1379	1380	1381	1382	1383	1384	1385	1386	1387	1388	1389	1390	1391	1392	1393	1394	1395	1396	1397	1398	1399	1400	1401	1402	1403	1404	1405	1406	1407	1408	1409	1410	1411	1412	1413	1414	1415	1416	1417	1418	1419	1420	1421	1422	1423	1424	1425	1426	1427	1428	1429	1430	1431	1432	1433	1434	1435	1436	1437	1438	1439	1440	1441	1442	1443	1444	1445	1446	1447	1448	1449	1450	1451	1452	1453	1454	1455	1456	1457	1458	1459	1460	1461	1462	1463	1464	1465	1466	1467	1468	1469	1470	1471	1472	1473	1474	1475	1476	1477	1478	1479	1480	1481	1482	1483	1484	1485	1486	1487	1488	1489	1490	1491
---	---	---	---	---	---	---	---	---	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------