PREDIKSI POTENSI AWAN CUMULONIMBUS (CB)

DI CILACAP TENGAH DENGAN METODE

K-NEAREST NEIGHBOR (KNN)

SKRIPSI

Diajukan untuk memenuhi sebagai persyaratan mendapatkan gelar Strata Satu

Program Studi Sistem Informasi

Disusn oleh :

GAIB PRAWOTO

23EP60002

PROGRAM STUDI SISTEM INFORMASI

FAKULTAS MATEMATIKA DAN ILMU KOMPUTER

UNIVERSITAS NAHDLATUL ULAMA AL GHAZALI

CILACAP

2025

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Dengan ini saya menyatakan bahwa penulisan skripsi dengan judul "Prediksi Potensi Awan *Cumulonimbus (CB)* di Cilacap Tengah dengan Metode *K-Nearest Neighbor (KNN)*" adalah hasil karya saya dengan arahan dari pembimbing dan belum diajukan kepada pihak manapun. Sumber informasi yang dikutip dalam skripsi ini telah dicantumkan dalam Daftar Pustaka

Demikian pernyataan ini dibuat dengan sebenarnya. Apabila pada kemudian hari terdapat ketidaksesuaian dalam pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku

Cilacap 9 Oktober 2025

Gab Prawoto

NIM 23EP60002

ii

LEMBAR PENGESAHAN

Skripsi Saudara

Nama	:	Gaib Prawoto
NIM	:	23EP60002
Fakultas/Prodi	:	Fakultas MIKOM/Sistem Informasi
Judul	:	Prediksi Potensi Awan *Cumulunimbus (CB)* di Cilacap Tengah dengan Metode *K-Nearest Neighbor (KNN)*

Telah disidangkan oleh Dewan Penguji Fakultas Matematika dan Ilmu Komputer Universitas Nadlatul Ulama Al Ghazali (UNUGHA) Cilacap pada hari/tanggal :

Rabu 27 November 2025

Dan dapat diterima sebagai pemenuhan tugas akhir mahasiswa Program Strata I (S.1) Sistem Informasi **(Kom)** Fakultas Matematika dan Ilmu Komputer (FMIKOM) pada Universitas Nadlatul Ulama Al Ghazali (UNUGHA) Cilacap

Cilacap, 27 November 2025

Dewan Sidang

Ketua	Sekretaris
Lasimin, M. Kom	M. Noviarsyah Dasaprawira, M.Pd
NIDN 0605048602	NIDN 060119301
Penguji 1	Penguji 2
Lasimin, M. Kom	Abdul Haq, SE, M.Cs
NIDN 0605048602	NIDN 0606067701
Pembimbing 1	Pembimbing 2
Agung Wibawa, M.Si	M. Noviarsyah Dasaprawira, M.Pd
NIDN 0603127903	NIDN 060119301

Mengetahui

Dekan Fakultas Matematika dan Ilmu Komputer

Mochamad Taufiqurrochman Abdul Aziz Zein, S. Si, M.Kom

NIDN 2125098601

Lasimin, M.Kom

Dosen Fakultas Matematika dan Ilmu Komputer
Universitas Nadlatul Ulama Al Ghazali Cilacap

NOTA KONSULTAN

Hal : Skripsi Saudara Gaib Prawoto

Lampiran :

Kepada

Yth. Dekan Fakultas Matematika dan Ilmu Komputer

Univeersitas Nadlatul Ulama Al Ghazali Cilacap

Di Cilacap

Assalamu`alaikum Wr,Wb

Setelah membaca, memeriksa dan melakukan perbaikan seperlunya maka skripsi saudara :

Nama : Gaib Prawoto
NIM : 23EP60002
Prodi : Sistem Informasi
Judul : Prediksi Potensi awan *Cumulonimbus (CB)* di Cilacap Tengah dengan metode *K-Nearest Neighbor (KNN)*

Dapat diajukan ke Fakultas Matematika dan Ilmu Komputer Universitas Nahdalatul Ulama Al Ghazali Cilacap untuk memenuhi syarat memperoleh gelar Strata Satu (SI)

Wassalamu`alaikum Wr.Wb

Cilacap 27 November 2025
Konsultan

Lasimin, M.Kom
NIDN 0605048602

iv

NOTA PEMBIMBING

Cilacap, 9 Oktober 2025

Kepada Yth

Fakultas Matematika dan Komputer (FMIKOM)

UNUGHA Cilacap

Di Cilacap

Assalamu'alaikum Wr,Wb

Setelah membaca, memeriksa dan melakukan perbaikan seperlunya maka skripsi saudara :

Nama : Gaib Prawoto
NIM : 23EP60002
Prodi : Sistem Informasi
Judul : Prediksi Potensi Awan *Cumulonimbus (CB)* di Cilacap Tengah dengan Metode *K-Nearest Neighbor (KNN)*

Kami berpendapat bahwa skripsi tersebut sudah dapat diajukan ke siding skripsi Bersamaan ini kami kirimkan skripsi tersebut, semoga dapat segera disidangkan

Atas perhaitianya kami ucapkan terima kasih
Wassalamu;alaikum Wr. Wb

Mengetahui,

Pembimbing 1	Pembimbing 2
Agung Wibawa, M.Si	M.Noviarsyah Dasaprawira, M.Pd
NIDN 0603127903	NIDN. 0610119301

MOTTO

Orang yang meraih kesuksesan tidak selalu orang yang pintar. Orang yang selalu meraih kesuksesan adalah orang yang gigih dan pantang menyerah. **(Susi Pudjiastuti)**

Kepercayaan akan diri sendiri adalah rahasia untuk sukses **(Carl Rogers)**

Semakin tinggi kedudukanmu, hendaklah kamu semakin rendah hati **(Paus Klemens 1)**

HALAMAN PERSEMBAHAN

Puji Syukur pada Tuhan Yang Maha Kasih. Tuhan penguasa bumi dan segala isinya..

Dengan rasa penuh syukur serta bangga, skripsi ini telah diselesaikan, dan ucapan terima kasih saya persembahkan kepada :

1. Keluarga besar penulis yang telah memberikan dukungan penuh, Ibu mertua tercinta dan tersayang yang doanya selalu menyertai, istri tercinta, Dwi Lestari selalu mendukung dalam suka dan duka serta dua anak kami Felicitas Clarinta Lituhayu dan Gabriel Andito Samba, penyemangat dalam setiap lelah.
2. Dosen pembimbing, Agung Wibawa, M.Si. dan M.Noviarsyah Prawira, M.Pd, atas bimbingan serta arahannya sehingga laporan skripsi ini dapat diselesaikan dengan baik dan tepat waktu.
3. Seluruh teman-teman angkatan SI23K yang saling membantu dan menyemangati, bersama-sama demi mewujudkan cita-cita masa depan yang lebih baik. Semoga pertemanan ini langgeng selamanya.
4. Rekan-rekan kerja di Stasiun Meteorologi Tunggul Wulung Cilacap yang telah memberikan dukungan dan masukan pada penelitian ini.

KATA PENGANTAR

Salam Sejahtera buat kita semua

Puji dan syukur atas kehadirat Allah Yang Maha Esa yang telah memberikan karuniaNya sehingga terselesaikannya skripsi ini dengan baik.

Skripsi ini disusun dalam rangka memenuhi syarat guna memperoleh gelar kesarjanaan strata satu (S1) Universitas Nahdlatul Ulama Al Ghazali Cilacap. Dalam penyusunan Skripsi ini, penulis cukup menghadapi kesulitan dan hambatan, namun berkat doa – doa, usaha dan bantuan dari dosen pembimbing dan pihak – pihak yang terlibat, baik secara langsung maupun tidak langsung dalam penyelesaian skripsi ini akhirnya dapat menghasilkan proposal skripsi seperti yang penulis harapkan. Maka penulis mengucapkan terima kasih kepada semua pihak yang telah mebantu dalam praktek kerja lapangan ini. Khususnya kami ucapkan kepada :

1. Bapak Dr. H Luthfi Hamidi, M.Ag selaku Rektor Universitas Nahdlatul Ulama Al Ghazali Cilacap
2. Bapak MTA. Aziz Zein, M.Kom selaku Dekan Fakultas Matematika dan Ilmu Komputer
3. Bapak Agung Wibawa, M.Si selaku pembimbing I yang telah memberikan bimbingan, arahan, dan saran dalam penyusunan skripsi ini
4. Bapak M. Noviarsyah Dasaprawira, M.Pd selaku pembimbing II yang telah memberikan bimbingan, arahan, dan saran dalam penulisan skripsi ini
5. Seluruh Dosen Program Studi Sistem Informasi yang telah memberikan ilmu kepada penulis sampai akhir masa studi.
6. Istri dan anak-anak, serta seluruh keluarga yang selalu memberikan motivasi serta dukungan moral maupun material.
7. Keluarga besar BMKG Cilacap yang telah memberikan saran dan membantu penulis dalam pengambilan data

Sahabat dan rekan-rekan (Adnan Dendy Mardika, Deas Achmad Rivai, Khamim Sodiq, dan Purwoanggoro) yang selalu mendukung, serta semua pihak yang tidak dapat disebutkan satu persatu.

Menyadari berbagai keterbatasan yang dimiliki penulis, maka penulis mengharapkan masukan, kritik dan saran dari semua pihak untuk menyempurnakan skripsi ini. Semoga dapat dijadikan pedoman sesuai dengan tujuan yang diharapkan.

Terima Kasih

Salam Sejahtera buat kita semua

Cilacap, 9 Oktober 2025

Penulis,

Gaib Prawoto

NIM.23EP60002

ABSTRAK

Cumulonimbus atau CB adalah jenis awan rendah berbentuk gumpalan berwarna hitam pekat dan menjulang tinggi yang dapat menibulkan dampak cuaca buruk sepert angin kencang, puting beliung, petir, hujan lebat tanpa atau disertai es. Cuaca buruk tersebut dapat mengakibatkan kerugian berbagai pihak.

Untuk mengetahui potensi pertumbuhan Cumulonimbus perlu adanya sebuah prediksi. Prediksi bertujuan untuk memperoleh informasi lebih dini atas cuaca kedepan. Makin dini informasi yang diberikan semakin cepat kebijakan diambil oleh pihak terkait.

Untuk mengatasi permasalahan diatas dibuatlah solusi berupa prediksi guna meprediksi potensi pertumbuhan awan CB menggunakan *machine learning*. Algortima *machine learning* yang digunakan untuk memprediksi awan CB di Cilacap adalah algortima KNN. Sementara itu dataset yang digunakan adalah nilai indeks labilitas udara atas yang diperoleh dari pengamatan *Rawindsonde* oleh Badan Meteorologi K;imatologi dan Geofisika Cilacap berupa Showalter Index (SI), Lifted Index (LI), Konvergence Index (KI), dan Total-Total Index (TT). Algoritma *machine learning* yang dibuat mampu berjalan dengan baik dan digunakan untuk memprediksi awan CB di Cilacap dengan akurasi yang dihasilkan menggunakan metode KNN akurasi yang dihasilkan adalah sebesar 75%,

Oleh karena itu dapat disimpulkan bahwa algortima KNN dapat digunakan untuk memprediksi awan CB di Cilacap dengan tingkat akurasi 75 %.

Kata kunci: Cumulonimbus, *machine learning*, KNN, Rawindsonde

ABSTRACT

Cumulonimbus clouds, or CB, are low-lying, dense, black clouds that can cause severe weather impacts such as strong winds, tornadoes, lightning, and heavy rain with or without hail. This severe weather can result in losses for various parties.

To determine the potential for cumulonimbus growth, a prediction is necessary. Predictions aim to obtain early information about future weather. The earlier the information is given, the sooner relevant parties can take necessary action.

To address the aforementioned issues, a solution was developed in the form of a prediction of potential for CB cloud growth using machine learning. The machine learning algorithm used to predict cumulonimbus clouds in Cilacap is the KNN algorithm. Meanwhile, the dataset used is the upper air lability index values obtained from Rawindsonde from observations made by the Cilacap Meteorology, Climatology, and Geophysics Agency (BMKG). These data include the Showalter Index (SI), Lifted Index (LI), Convergence Index (KI), and Total-Total Index (TT). The machine learning algorithm usedl performed well and was able to predict cloud formation (CB) in Cilacap with an accuracy of 75% using the KNN method.

Therefore it can be concluded that KNN algorithm can be use to predict CB cloud formation in Cilacap with an accuracy of 75%.

Keywords: cumulonimbus, machine learning, KNN, Rawindsonde.

DAFTAR ISI

ALAMAN SAMPUL ..... **i**
HALAMAN PERNYATAAN KEASLIAN SKRIPSI Error! Bookmark not defined.
PENGESAHAN ..... Error! Bookmark not defined.
NOTA KONSULTAN ..... Error! Bookmark not defined.
NOTA PEMBIMBING ..... **v**
MOTTO ..... **vi**
HALAMAN PERSEMBAHAN ..... **vii**
KATA PENGANTAR ..... **viii**
ABSTRAK ..... **x**
ABSTRACT ..... **xi**
DAFTAR ISI ..... **xii**
DAFTAR GAMBAR ..... **xiv**
BAB I PENDAHULUAN **2**
A.Latar Belakang **2**
B. Rumusan Masalah **4**
C. Batasan Masalah **4**
D. Tujuan Penelitian **5**
E. Manfaat Penelitian **5**
F. Penelitian Yang Relevan **6**
BAB II **9**
LANDASAN TEORI **9**
A. Klasifikasi Awan **9**
B. Metode KNN **11**
C. Rawindsonde (Radio Sonde) **12**
BAB III METODOLOGI PENELITIAN **19**
A. Jenis Penelitian **19**

B. Sumber dan Jenis Data 19

C. Prosedur Penelitian 19

BAB IV HASIL DAN PEMBAHASAN 27

A.Identifikasi Masalah 27

B. Data Collecting 27

C.Preprocessing 28

1. Persiapan Data 29
2. Penanganan Missing value 32

D. Membangun model Machine Learning 36

E.Implementasi 38

BAB V PENUTUP 46

A. Kesimpulan 46

B. Saran 46

DAFTAR PUSTAKA 47

DAFTAR GAMBAR

Gambar 1 Penampakan awan Cumulunimbus..... 10

Gambar 2 Aplikasi RAOB 12

Gambar 3 Aplikasi Excel 12

Gambar 4 Google Colab 13

Gambar 5 Nilai Indek RAOB Rawindsonde 13

Gambar 6 Data Pengamatan Synop 14

Gambar 7 Rawindsonde 14

Gambar 8 Transmitter Rawinsonde 15

Gambar 9 Data hasil RAOB 16

Gambar 10 Proses Alaur Penelitian 19

Gambar 11 Alur preprosessing data 21

Gambar 12 Bagan Alur penelitian dengan metode KNN 23

Gambar 13 Ilustrasi pengaruh nilai k..... 24

Gambar 14 Evaluasi menggunakan Confusion Matrix..... 25

Gambar 15 Hasil RAOB tanggal 1 Februari 2025 28

Gambar 16 Tampilan dataset..... 29

Gambar 17 Library 30

Gambar 18 Proses pemanggilan dataset 30

Gambar 19 Dataset lima baris 31

Gambar 20 Informasi dataset 32

Gambar 21 Data missing value..... 33

Gambar 22 Data yang mengalami missing value 33

Gambar 23 Perintah dropna untuk menghapus 34

Gambar 24 Variabel independen 35

Gambar 25 Variabel dependen 35

Gambar 26 Data training dan testing 36

Gambar 27 Metode KNN 37

Gambar 28 Hasil prediksi..... 38

Gambar 29 Hasil RAOB 38

Gambar 30 Hasil prediksi..... 39

Gambar 31 Confusion Matrix..... 39

Gambar 32 Evaluasi dengan Confunsion Matrix 40

Gambar 33 Confunsion Matriv KNN 41

Gambar 34 Skor prediksi dengan KNN 41

Gambar 35 Tampilan Pengamatan Synop..... 42

Gambar 36 Matrik Korelasi..... 44

DAFTAR TABEL

Tabel 1 Klasifikasi dan Ciri Visual Awan 9

Tabel 2 Threshold Showalter Index 16

Tabel 3 Threshold Lifted Index 17

Tabel 4 Threshold Konvergence Index 18

Tabel 5 Threshold Total-Total Index 18

Tabel 6 Hasil prediksi 42

BAB I
PENDAHULUAN

A.Latar Belakang

Cuaca merupakan faktor yang sangat diperhatikan pada zaman ini, perubahan cuaca dan dampaknya dapat mempengaruhi sektor ekonomi hingga keselamatan jiwa. Prediksi cuaca merupakan kegiatan yang penting dalam ilmu meteorologi untuk memberikan perkiraan tentang keadaan atmosfer di masa depan. Keterbatasan pengetahuan tentang fenomena cuaca yang kompleks sering kali menjadi hambatan dalam meramalkan cuaca secara tepat dan akurat. Namun, adanya kemajuan teknologi dan pengembangan model matematis, prediksi cuaca menjadi lebih dapat diandalkan.[1]

Cuaca telah dianggap penting oleh sebagian Masyarakat seperti nahkoda dan pilot terkait keselamatan perjalanan transportasi tersebut. Perubahan zaman mendorong semakin banyak masyarakat yang mulai peduli pada kondisi cuaca dan menjadikannya sebagai informasi pendukung aktivitas maupun dasar pengambilan keputusan seperti musim tanam hingga kebutuhan harian informasi cuaca terkait pengerjaan proyek konstruksi bangunan.

Indonesia termasuk negara beriklim tropis yang memiliki cuaca hujan dan panas. Perubahan musim sering berubah ubah sehingga sulit di prediksi. sebaiknya masyarakat mengetahui cuaca di daerah yang dituju dan daerah daerah yang akan dilewati selama perjalanan agar terhindar dari kendala perjalanan berupa banjir, angin ribut dan tanah longsor.[2]

Badan Meteorologi Klimatologi dan Geofisika merupakan institusi yang bertugas memberikan pelayanan informasi cuaca, kegempaan, iklim, dan kualitas udara. Di kabupaten Cilacap, unit pelaksana teknis BMKG bernama Stasiun Meteorologi Tunggul Wulung Cilacap akan memberikan informasi dini cuaca ekstrem pada area Kabupaten Cilacap guna mengurangi dampak ekonomi serta dampak korban jiwa karena cuaca ekstrem, salah satunya adalah informasi peringatan dini kejadian petir dengan berdasar pertumbuhan awan konvektif penyebab petir, yaitu awan Cumulonimbus, awan cumulonimbus terbentuk karena pertemuan massa udara di mana angin bergerak dari ketidakstabilan

lapisan udara sehingga daya angkat ke atas sangat kuat dan dapat berasal dari jenis awan yang lain. Pada lapisan troposfer atas awan konvektif dapat mengeluarkan panas laten, yang menyebabkan terjadinya gangguan terhadap atmosfer dan sekitarnya.[3]

Gesekan antar partikel ion didalam awan tersebut yang menjadikan fenomena lompatan listrik atau petir[4]. Kadang sambaran petir dapat terjadi di dalam awan, antar awan, dan tidak jarang terjadi sambaran dari awan ke daratan. Informasi peringatan dini cuaca ekstrem seperti prediksi kejadian sambaran petir sangat diperlukan. Hal ini dikarenakan tingginya hari terjadi sambaran petir di wilayah Kabupaten Cilacap. Tercatat berdasarkan data Badan Meteorologi Klimatologi dan Geofisika Cilacap, dimana pada tahun 2021 tercatat ada 119 hari terjadinya petir dalam satu tahun. Menunjukkan bahwa sambaran petir di wilayah Cilacap tergolong tinggi, sambaran petir bahkan pernah diduga menjadi penyebab terbakarnya Pabrik Pengolahan Karet di PTPN IX Wanareja pada tanggal 8 Desember 2021.

Sambaran petir hanya dapat terjadi dari awan jenis Cb, Gesekan antar partikel ion didalam awan tersebutlah yang menjadikan fenomena lompatan listrik yang kita sebut petir. Kadang sambaran petir dapat terjadi di dalam awan, antar awan, dan tidak jarang terjadi juga sambaran dari awan ke daratan sehingga sangat membahayakan. Begitu pula dengan kejadian angin kencang seperti microburst yang dihasilkan hanya oleh awan Cb, sangat berbahaya bagi dunia penerbangan dan pelayaran karena mengakibatkan ketidakstabilan moda transportasi tersebut.

Dengan tingginya hari terjadinya sambaran petir, maka perlu dilakukan kajian penentuan potensi pertumbuhan awan Cb dengan menggunakan data pengamatan labilitas atmosfer yang dilakukan oleh Stasiun Meteorologi Tunggul Wulung Cilacap, bernama pengamatan Radio Sonde.

Awan Cb banyak aktif di Wilayah Indonesia yang terletak di daerah tropis. Awan ini sangat berkaitan dengan keselamatan dan kenyamanan dalam dunia penerbangan. Data Radio sonde memiliki akurasi yang cukup baik dalam memprediksi Cb harian dengan indeks stabilitas, sedangkan prediksi Cb setiap jam dapat digunakan Model Skala Meso WRF. Dengan menggunakan indeks

stabilitas keluaran WRF (CAPE, SI, LI, KI, SWEAT dan ensemble dari ke lima indeks) dilakukan pengujian indeks terbaik yang menghasilkan prediksi awan Cb [5]

Pengamatan tersebut akan mencatat indeks atmosfer yang umum digunakan untuk melakukan prediksi cuaca kedepan, dan dengan menggunakan algoritma KNN yang berdasarkan ketetanggan terdekat, maka diharapkan adanya awan Cb di area Cilacap Tengah dapat diprediksi jauh sebelum waktu terjadi agar masyarakat dan instansi terkait dapat melakukan tindakan preventif guna mengurangi dampak yang diakibatkan.

Algoritma KNN merupakan salah satu algoritma yang digunakan untuk melakukan klasifikasi suatu data berdasarkan atribut dan sampel-sampel dari data training. Algoritma KNN ini menggunakan *neighborhood classification* sebagai nilai prediksi dari *instance* yang baru yang ditentukan berdasarkan mayoritas dari kategori k tetangga terdekat.[6]

Oleh karena itu peneliti akan melakukan penelitian yang berjudul "Prediksi Potensi awan *Culumonimbus (CB)* di Cilacap Tengah dengan metode *K-Nearest Neighbor (KNN)".*

B. Rumusan Masalah

Berdasarkan latar belakang masalah, rumusan masalah pada penelitian ini dapat di identifikasi sebagai berikut :

1. Bagaimana cara memprediksi awan cumulonimbus di Cilacap Tengah menggunakan machine learning ?
2. Seberapa akurat algortima KNN dalam meprediksi potensi awan Cb menggunakan nilai indek dari rawindsonde ?

C. Batasan Masalah

Agar penelitian lebih fokus untuk dilakukan, maka perlu adanya pembatasan ruang lingkup masalah sebagai berikut :

1. *Tool* yang digunakan untuk mengolah data potensi awan CB di Cilacap Tengah adalah *Google Colab*.

2. Dataset yang digunakan adlah data indek rawindsonde (SI, LI, KI, TT) BMKG Cilacap pukul 00.00 dan 12.00 UTC dari tahun 2020 sampai dengan 2024.
3. Algoritma yang digunakan adalah KNN (metode *K-Nearest Neighbor)*

D. Tujuan Penelitian

1. Memprediksi pertumbuhan awan Cb di Cilacap Tengah menggunakan machine learning.
2. Untuk mengetahui hasil akurasi menggunakan algortima dengan metode KNN (metode *K-Nearest Neighbor)*

E. Manfaat Penelitian

Manfaat dari penelitian ini antara lain :

1. Bagi Mahasiswa
   a. Sebagai sarana untuk mengembangkan dan menerapkan ilmu yang sudah dipelajari di kampus untuk diterapkan di masyarakat.
   b. Mengetahui dan mempelajari metode prediksi mana yang terbaik
   c. Dari hasil penelitian ini dapat digunakan sebagai referensi penelitian selanjutnya.
2. Bagi BMKG

   Memberikan informasi yang baik tentang potensi awan Cumulonimbus di Cilacap Tengah kepada pengguna jasa dan Masyarakat Cilacap.

F. Penelitian Yang Relevan

Penelitian ini yang berjudul "Prediksi Potensi awan *Cumulonimbus (CB)* di Cilacap Tengah dengan metode *K-Nearest Neighbor (KNN)"*, ada beberapa penelitian yang relevan sebagai referensi dari penulis. Berikut merupakan persamaan dan penelitian ini dengan penelitian yang lainnya.

No	Peneliti	Keterangan Penelitian
(1)	(2)	(3)
1.	Aisha Alfani W. P. R,	**Judul :** Penerapan Algoritma K-Nearest Neighbor (KNN) untuk Memprediksi Penyakit Stroke Stroke Desease Predict Using KNN [7] Berdasarkan hasil perhitungan data mining menggunakan teknik klasifikasi dan algoritma K-NN, didapatkan Metode: K-Nearest Neighbor (KNN) Software : - Hasil Penelitian : hasil prediksi penjualan produk berdasarkan nilai akurasi tertinggi dan terendah. Nilai akurasi tertinggi terhadap klasifikasi penjualan produk sebesar 86,66%. Sedangkan nilai akurasi terendah terhadap klasifikasi penjualan produk sebesar 40%. Dengan demikian metode data mining dan algoritma K-NN ini dapat diimplementasikan untuk memprediksi penjualan produk Unilever di Toko Rizky Barokah Nganjuk.

No	Peneliti	Keterangan Penelitian
(1)	(2)	(3)
2.	Muhammad Yusuf, Risqon Rangkuti,Muhammad Valensyah,Alfasyuri, Wawan Gunawan (2021)	Judul : Penerapan Algoritma KNN Dalam Meprediksi dan Menghitung Tingkat Akurasi Data Cuaca di Indoesia Metode : KNN Software : - Hasil Peneltian: Penggunaan Metode *KNN* untuk meprediksi dan menghitung akurasi cuaca di indonesia cukup baik dengan tingkat akurasi 89 %
3.	Tedi Permana, Amri Mutoi Siregar, Anis Fitri Nur Musruriyah, Ayu Ratna Juwita (2020)	Judul : Perbandingan Hasil Prediksi Kredit Macet pada Koperasi Menggunakan Algoritma KNN dan C5.0 Metode : KNN Software : - Hasil Penelitian Berdasarkan hasil perhitungan dengan KNN, dataset yang digunakan sebanyak 30 data transaksi simpan pinjam, dan lima atribut yang digunakan, nilai akuarasinya 83,33%,
4.	Relangi Manikanta S.Prem Kumar (2025)	Judul : Detection of ethanol uality using KNN in comparison with random forest classifier to measure accuracy Metode : KNN Software : -

No	Peneliti	Keterangan Penelitian
(1)	(2)	(3)
		Tujuan dari penelitian ini adalah untuk menilai kualitas etanol menggunakan K-Nearest Neighbor (KNN) dan membandingkan hasilnya menggunakan pendekatan Random Forest. Persediaan dan Prosedur: Pekerjaan yang diusulkan mengumpulkan kumpulan data melalui repositori UCI dan menggunakan seluruh ukuran sampel sebesar 1599. Sampel yang dikumpulkan dibagi menjadi dua kategori: data pengujian (n = 400 [25%) dan data pelatihan (n = sama dengan; 1199 [75%]). Saat menghitung sampel dengan Clincalc, yang memiliki dua kelompok berbeda untuk alfa (0,05), daya, dan rasio lingkungan, alat daya G digunakan. Skor akurasi dihitung untuk algoritma KNN untuk menilai kualitasnya. Hasil: KNN mengungguli metode Random Forest, yang memiliki akurasi 85,71%, dalam model yang disarankan, dengan akurasi superior sebesar 87,66%. Signifikansi model adalah 0,001 (< 0,05), dan daya G ditentukan menjadi 0,8. Dalam karya ini, KNN mengungguli algoritma Hutan Acak dengan selisih yang besar dalam kumpulan data deteksi kualitas etanol ketika lebih banyak fitur yang diperhitungkan.

BAB II

LANDASAN TEORI

A. Klasifikasi Awan

Awan adalah kumpulan butiran air dan kristal es yang sangat kecil atau campuran keduanya dengan konsentrasi berorde 100 per sentimeter kubik dan mempunyai radius sekitar 10 mikrometer. Awan terbentuk jika volume udara lembap mengalami pendinginan sampai di bawah temperatur titik embunnya. Pada keadaan lapisan atmosfer di atas benua maritim.[8]

Tabel 1 Klasifikasi dan Ciri Visual Awan

Klasifikasi Awan	**Ciri Visual**
Awan tinggi (6000-18000 m)	
Cirrocumulus	Kecil, bulat, biasanya muncul sendiri atau dalam barisan
Cirrostratus	Tipis seperti lembaran
Cirrus	Tipis berbentuk seperti buntut
Awan Menengah (2000-8000 m)	
Altocumulus	Berwarna abu-ab, menggumpal, dan menggulung
Altostratus	Berrwarna abu-abu atau abu kebiruan, menutup sebagian langit
Awan rendah (0-2000 m)	
Nimbustratus	Berwarna abu-abu, kehitaman, dan terlihat basah, berwarna lebih gelap dari altostratus
Stratocumulus	Rendah, awan terlihat tebal yang muncul dalam bentuk barisan, potongan kecil, atau massa yang membundar dengan langit biru yang terlihat diantara awan individunya
Stratus	Keabu-abuan, homogen, biasanya menutupi Sebagian besar langit.
Awan rendah dengan perkembangan vertical (1000 – 12000 m)	
Cumulus	Seperti kapas, dasar awan datar, bagian atas awan berbentuk membundar
Cumulunimbus	Bagian dasar datar, awan tebal, awan berbentuk vertical dengan bagian atas awan seperti berserabut

Awan cumulonimbus adalah awan tebal yang mengandung hujan batu es, hujan air, berangin kencang hingga berangin seperti tornado. Awan Cumulonimbus memiliki dasar antara 100-600 m dan memiliki puncak ketinggian 15 km bahkan lebih.[3]

Gambar 1 Penampakan awan Cumulonimbus.

Awan *CB* sebagaimana diperlihatlam pada Gambar 1, biasanya direkomendisikan untuk dihindari dalam penerbangan, karena dapat menghempaskan suatu pesawat terbang

Awan ini berpotensi menghasilkan hujan lebat, puting beliung, petir dan mungkin yang paling parah adalah microbust. Microburst merupakan angin berkecepatan tinggi yang turun (downdraft) dari bawah awan cumulus yang berpotensi hujan dan tak kasat mata [9]. Ketika pesawat melewati sebelah bawah microbust kemungkinan adanya aliran udara yang keluar dari bagian bawah awan dengan kecepatan mencapai 100 km/jam. Hal ini dapat menyebabkan pesawat mengalami gangguan dan kehilangan kendali.

.

B. Metode KNN

Machine learning adalah ilmu yang mempelajari algoritma komputer yang mampu mengenali pola dalam data dengan tujuan mengubah berbagai data menjadi tindakan nyata dengan intervensi manusia seminimal mungkin [10]. Bantuan *machine learning*, dapat membuat komputer belajar sendiri dari data yang ada, memungkinkan komputer mengambil keputusan sendiri tanpa harus diprogram ulang.

Algortima *machine learning* dibagi menjadi dua yaitu *supervised* dan *unsupervised. Supervised* adalah metode pembelajaran menggunakan himpunan data berlabel. Sedangkan *unsupervised* yaitu metode pembelajaran mempergunakan sejumlah data tanpa label [11].

a) *KNN* (K- Nearest Neighbors)

K-nearest neighbor adalah algoritma *machine learning* yang termasuk dalam supervised learning, *KNN* mengkelaskan data baru menggunakan kemiripan dengan sejumlah data (k) pada lokasi yang paling dekat dengan kumpulan data yang telah ada sebelumnya [12]

Beberapa kelebihan *KNN* dalam mengolah data diantaranya :

1) Pelatihan sangat cepat, sederhana dan mudah dipelajari.
2) Tahan terhadap data pelatihan yang memiliki derau.
3) Efektif meski data pelatihan besar.

b) Confusion Matrix

Confusion matrix adalah tabel yang digunakan untuk mengukur performa dari model klasifikasi *machine learning*. Tabel ini menggambarkan dengan detail tentang jumlah data yang dikelompokan dengan benar maupun salah. Confusion matrix menampilkan dan membandingkan nilai aktual atau sebenarnya dengan nilai hasil prediksi model yang digunakan untuk menghasilkan matrik evaluasi seperti *Accuracy*, *Precision*, *Recall*, dan F1-*Score.* Semakin tinggi matrik evaluasi, semakin baik performa *machine learning* yang dihasilkan. *Machine learning* dikatakan berhasil apabila diperoleh nilai akurasi sebesar 80% [13].

C. Rawindsonde (Radio Sonde)

Alat dan bahan yang digunakan dalam penelitian ini adalah :

1. Alat

   a. Beberapa perangkat lunak *(Software)* diperlukan untuk menunjang penelitian ini, diantaranya :

   1) RAOB

   Digunakan untuk mendapatkan data parameter cuaca yang diukur serta data labilitas atmosfer yang diamati oleh weather observer menggunakan *rawindsonde*. Data labilitas tersebut berupa indeks *LI, SI, KI dan TT* jam 00.00 UTC dari tahun 2020 sampai dengan 2024 berasal dari BMKG Cilacap.

Gambar 2 Aplikasi RAOB

   2) Microsoft Excel

   Digunakan untuk pengolahan dataset berupa nilai indeks *rawindsonde* dan data kejadian awan *Cumulonimbus* dari tahun 2020 sampai dengan 2024 di BMKG Cilacap.

Gambar 3 Aplikasi Excel

   3) Google Colab

   Digunakan untuk melakukan pengkodean program, analisis data, dan membuat model machine learning.

Colaboratory

Gambar 4 Google Colab

b. Perangkat Keras (Hardware)

1) Laptop : Asus TUF
2) Processor : Intel I 5
3) RAM : 16 GB DDR4 Memory
4) Harddisk : 512GB SSD
5) VGA : NVIDIA GeForce GTX 1650

2. Bahan

Bahan yang digunakan dalam penelitian ini adalah :

a. Data Rawinsonde yang dilepas jam 07.00 WIB atau 00.00 UTC yang menghasilkan data parameter cuaca di lapisan atas dan indeks labilitas atmosfer, salah satu contohnya seperti terlihat pada gambardibawah ini.

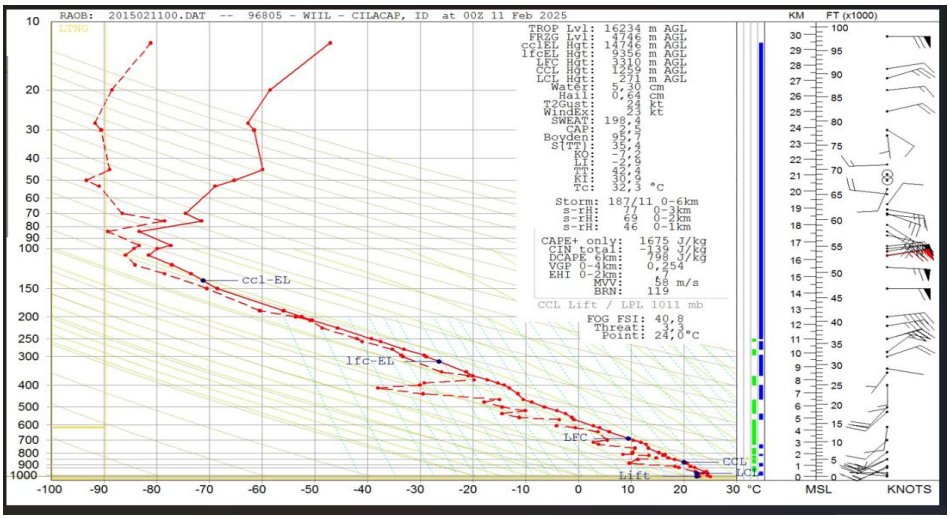

Gambar 5 Nilai Indek RAOB Rawindsonde

Gambar 5 memperlihatkan nilai indeks hasil aplikasi RAOB pada tanggal 11 Februari 2025 berupa nilai *SI, LI, KI* dan *TT*Berita Synop yang berisi informasi cuaca setiap jam pengamatan di Stasiun Tunggul Wulung Cilacap yang dikirim setiap jam selama 24 jam operasional yaitu pukul 00.00 UTC sampai 23.00 UTC

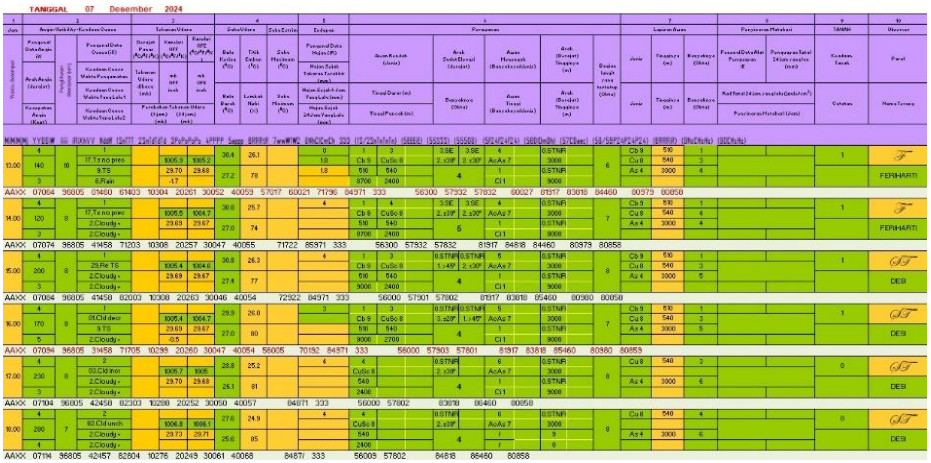

Gambar 6 Data Pengamatan Synop

Pada Gambar 6 memperlihatkan barita Synop tanggal 7 Desember 2024 pukul 06 UTC sampai dengan pukul 11.00 UTC. Pada pukul 06.00 dan 08,00 UCT terlihat adanya penampakan awan *CB*.

Radiosonde adalah alat untuk mengukur tekanan , suhu, arah dan kecepatan angin dan kelembaban udara diberbagai lapisan udara. alat tersebut berfungsi sebagai alat ukur untuk mengetahui karakteristik keadaan cuaca dari lapisan permukaan sampai lapisan tingkat atas. [14] Gambar 8 memperlihatkan rawindsonde yang terdiri dari balon cuaca dan transmiter siap diterbangkan.

Gambar 7 Rawindsonde

Gambar 8 Transmitter Rawinsonde

Gambar 8 adalah gambar transmiter yang berisi sensor diataranya sensor temperatur udara, sensor kelembaban udara, sensor arah dan kecepatan angin, serta sensor tekanan udara. Rawindsonde bekerja dengan cara diterbangkan dua kali dalam sehari yaitu pukul 00.00 UTC dan 12 UTC. Selama mengudara sensor cuaca pada rawindsonde merekam keadaan cuaca atmosfer di ketinggian yang dilaluinya dan mengirimkannya ke server setelah ditanyakan selesai. Pengamatan rawindsonde dinyatakan selesai manakala balon udara pecah diketinggian tertentu dikarenakan tekanan udara dalam balon lebih besar dari tekanan udara sekitar. Ketinggian pengamatan rawindsonde bisa mencapai hingga 28.000 meter. Sensor tersebut menunjang pengambilan data parameter cuaca seperti tekanan udara, suhu udara, arah dan kecepatan angin, serta kelembaban udara. Data cuaca tersebut kemudian diolah terlebih dahulu menggunakan aplikasi RAOB untuk menghasilkan nilai indeks labilitas udara atas berupa Showalter Index *(SI),* Lifted Index *(LI),* Konvergence Index *(KI), dan* Total-Total Index *(TT)* seperti tampak pada gambar 10.

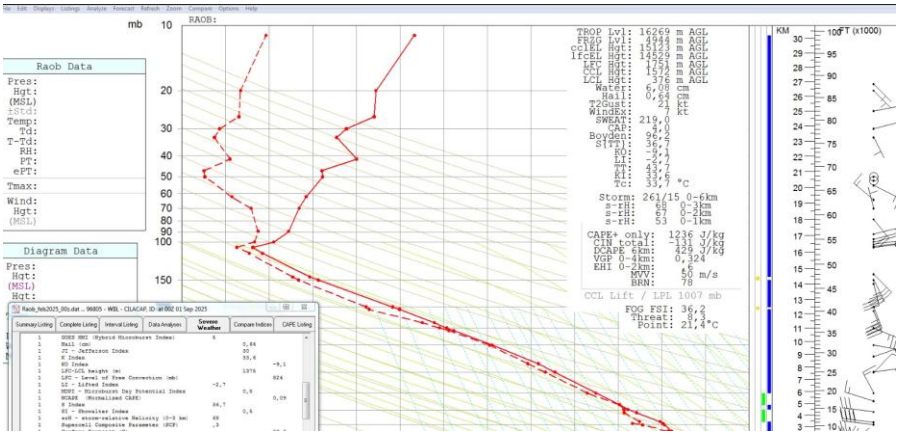

Gambar 9 Data hasil RAOB

Gambar 9 memperlihatkan data hasil pengolahan menggunakan aplikasi RAOB tanggal 1 Februari 2025 jam 00 UTC. Tidak semua nilai indeks di gunakan untuk melakukan prediksi terhadap *awan CB*. Dalam penelitian ini penulis hanya menggunakan nilai indeks berupa *Showalter Index (SI), Lifted Index (LI), Konvergence Index (KI), dan Total Total Index*. Hal itu dikarenakan keempat nilai indeks itulah yang sangat berpengaruh terhadap pertumbuhan awan *Cumulonimbus* [15].

a) Showalter Index

Indeks Stabilitas Showalter (SSI) mirip dengan indeks terangkat (LI), tetapi jika LI dimulai dengan rata-rata lapisan diatas permukaan tanah atau 100 hPa terendah, SSI menggunakan paket udara yang diangkat dari lapisan 850 hPa ke 500 hPa. SSI yang negatif menunjukkan ketidakstabilan yang makin besar [16].

Tabel 1 Threshold Showalter Index

Nilai SI	Potensi cuaca buruk
3 hingga 1	Kecil
1 hingga -2	Sedang
-3 hingga -6	Tinggi
Lebih kecil dari -6	Ekstrem

b) Lifted Index

Lifted Index (LI) atau Indeks terangkat, dihitung sebagai perbedaan antara suhu yang diamati pada 500 hPa dan suhu paket udara yang diangkat hingga 500 hPa dari dekat permukaan. Semakin tidak stabil lingkungan, maka semakin negatif nilai LI. Nilai LI didapat dengan melakukan perhitungan seperti yang dapat dilihat di bawah [16].

LI = T(500 mb envir) - T(500 mb parcel)

Tabel 2 Threshold Lifted Index

Nilai LI	Potensi Cuaca Buruk
Lebih besar dari -2	Lemah
Antara -3 hingga -5	Sedang
Lebih kecil dari -6	Kuat
Nilai LI	Potensi Cuaca Buruk

Nilai Lifted Index yang negatif menunjukkan udara yang lebih hangat, kurang stabil dan berpotensi terjadinya badai petir, sementara petir disebabkan oleh *awan CB*. Sedangkan nilai Lifted Index yang positif menunjukkan bahwa udara cenderung lebih dingin dan lebih stabil

c) Konvergence Index

Indeks K adalah ukuran potensi badai petir berdasarkan tingkat selang suhu vertikal, dengan jumlah dan tingkat vertikal kelembaban tingkat rendah di atmosfer. Dengan rumus seperti terlihat dibawah.

K = T(850 mb) + Td(850 mb) - T(500 mb) - DD(700 mb)

T mewakili suhu kering, Td mewakili suhu titik embun, dan DD mewakili penurunan titik embun pada tingkat yang dimaksud, seluruhnya diukur dalam derajat Celcius. [16].

Tabel 3 Threshold Konvergence Index

Nilai K	Potensi petir dan hujan
Dibawah 30	Sedang
Antara 30 dan 40	Kuat
Lebih sama dengan 40	Sangat Kuat

d) Total-Total Index

Indeks Total-Total (TT) dihitung menggunakan suhu dan titik embun pada lapisan 850 hPa dan suhu pada lapisan 500 hPa. Semakin tinggi titik embun dan suhu 850 hPa dan semakin rendah suhu 500 hPa maka semakin besar ketidakstabilan serta nilai TT yang dihasilkan [16]

TT = (T850 + Td850) - (2 * T500)

T mewakili suhu kering, Td mewakili suhu titik embun, semua dalam derajat Celcius.

Tabel 4 Threshold Total-Total Index

Nilai TT	Potensi petir
Lebih kecil dari 44	Lemah
44 hingga 55	Sedang
Diatas 55	Kuat

Semakin tinggi nilai Indeks Total Total, semakin tinggi potensi terjadinya badai petir.

BAB III
METODOLOGI PENELITIAN

A. Jenis Penelitian

Dalam hal ini penelitian yang akan digunakan adalah penelitian kuantitatif dengan analisis runtun waktu. Analisis didasarkan atas data yang relevan pada masa lampau, dengan menggunakan teknik-teknik dan metode- metode dalam penganalisaan data tersebut.

B. Sumber dan Jenis Data

Data yang digunakan merupakan data sekunder. Data sekunder adalah data yang mengacu pada informasi yang dikumpulkan dari sumber yang telah ada, sumber datanya yang diperoleh berupa data rawindsonde. Data tersebut diambil dari data periode Januari 2020 sampai dengan Desember 2024.

C. Prosedur Penelitian

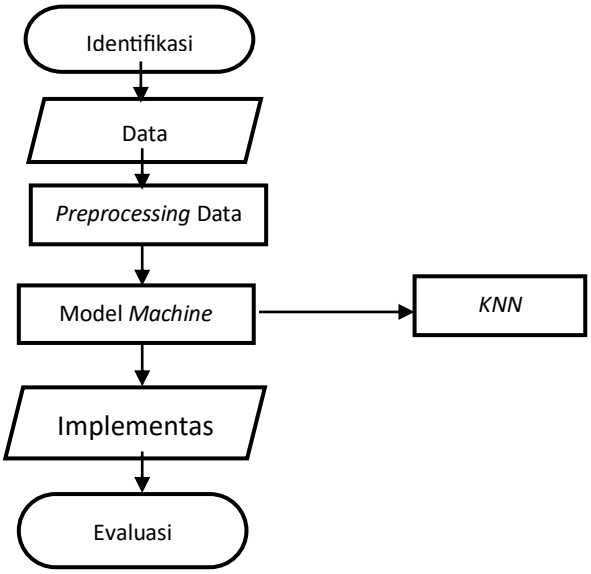

Gambar 10 Proses Alur Penelitian

1. Identifikasi Masalah

   Proses identifikasi masalah dilakukan untuk dapat memahami permasalahan yang dihadapi dan menentukan metode yang tepat agar didapat faktor-faktor utama dalam melakukan identifikasi potensi awan Cumulonimbus.

2. Data *Collecting*

   Pada tahap ini dilakukan pengumpulan data menjadi data set yang akan digunkana dalam proses machine learning. Pengumpulan data berupa nilai indeks labilitas udara atas Data labilitas udara atas berupa nilai Showalter Index *(SI),* Lifted Index *(LI),* Konvergence Index *(KI)*, Total Index *(TT)* dari data Rasond pukul 00.00 UTC dan 12.00 UTC dari tahun 2020 sampai dengan 2024.

3. *Preprocessing*

   Preprocessing adalah proses mengubah data mentah ke dalam bentuk yang lebih mudah dipahami. Proses ini diperlukan untuk memperbaiki kesalahan pada data mentah yang seringkali tidak lengkap dan memiliki format yang tidak teratur. Masalah yang paling sering ditemui dari suatu kumpulan data adalah missing value sebagian atau bahkan satu baris utuh informasi. Pada disiplin ilmu computer science, dikenal sebuah konsep garbage in garbage out, yang berarti jika data yang masuk untuk diproses dalam pemodelan adalah data yang tidak bermutu baik, maka hasil dari pemodelan pun merupakan hasil yang juga tidak bermutu baik. Menghilangkan data rusak atau data yang tidak berkualitas baik pada kumpulan data yang berjumlah banyak tidaklah mengurangi akurasi dari output pemodelan, namun sebaliknya justru meningkatkan kualitas output pemodelan tersebut. Oleh karenanya tahap preprocessing akan dilakukan agar mendapatkan kumpulan data yang bermutu baik serta mengubah kumpulan data tersebut sesuai keperluan. Tahap – tahap reprosesing data antara lain terlihat pada gambar 12

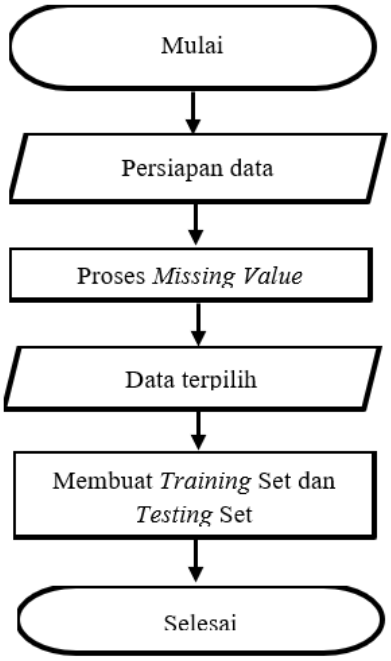

Gambar 11 Alur Preprocessing data

Gambar 11 menunjukkan bahwa tahap preprocessing dimulai dengan menyiapkan data terlebih dahulu, proses missing value, menyeleksi ulang data yang terpilih, mengecek ketidak seimbangan data dan menyeimbangkannya, kemudian data dibagi dua menjadi testing set dan training set. Secara detail tahapan preprocessing adalah sebagai berikut :

a. Persiapan data

   Tahapan pertama yang dilakukan adalah menyiapkan data yang dibutuhkan. Data hasil pemgamatan udara atas diolah terlebih dahulu menggunakan aplikasi RAOB untuk mendapatkan nilai indeks *(SI, LI, KI, TT)*. Data-data tersebut kemudian disandingkan dengan data pengamatan cuaca permukaaan (*SYNOPTIK*). Kumpulan data indeks dan data *SYNOPTIK* ditampung dalam format Microsoft Excel (.xlsx) menjadi sebuah dataset.

b. Proses *Missing Value*

   Pada proses ini dilakukan pengecekan data apakah ada data yang hilang atau rusak. hal ini bertujuan untuk memperoleh data dengan kualitas yang baik.

c. Seleksi fitur

Tidak semua data hasil dari pengolahan RAOB akan digunakan untuk penelitian ini, hanya indeks labilitas atmosfer seperti *TT Index, Konvergence Index, Showalter Index, dan Lifted Index* serta pengamatan *Synop* berupa kejadian awan *Cumulonimbus* saja yang digunakan, maka dari itulah seleksi fitur dilakukan.

d. Pembagian training set dan testing set

Pada tahap ini, data dibagi terlebih dahulu menjadi dua berupa data independen dan data dependen. Kemudian dilakukan pengecekan keseimbangan data. Apabila tidak seimbang maka dilakukan penyeimbangan. Kemudian data dibagi menjadi data training set dan testing set menggunakan fitur dari framework python.

4. Membangun Model Machine Learning

Machine learning adalah bidang ilmu komputer yang mempelajari bagaimana membuat komputer dapat belajar dari data tanpa diprogram secara eksplisit. Dalam arti lain, machine learning adalah kemampuan komputer untuk belajar dari data tanpa harus diberi tahu secara eksplisit apa yang harus dilakukan. Komputer dapat belajar dari data untuk membuat prediksi, klasifikasi, atau keputusan.

a. Apakah mesin hitung (komputer) dapat belajar? Mesin hitung (komputer) dapat belajar dengan cara mempelajari data. Data yang diberikan kepada computer
b. Machine learning adalah bidang ilmu yang mempelajari bagaimana komputer dapat belajar dari data tanpa diprogram secara eksplisit.
c. Proses machine learning terdiri dari dua tahap utama, yaitu fase pelatihan dan fase aplikasi.
d. Machine learning memiliki berbagai macam aplikasi dalam dunia nyata.
e. Machine learning memiliki keterkaitan dengan berbagai bidang lain.

f. *KNN* (K-nearest neighbor)

Dalam penelitian ini, penulis memaparkan bagan alur penelitian dari proses metode KNN yang dapat dilihat di gambar 12

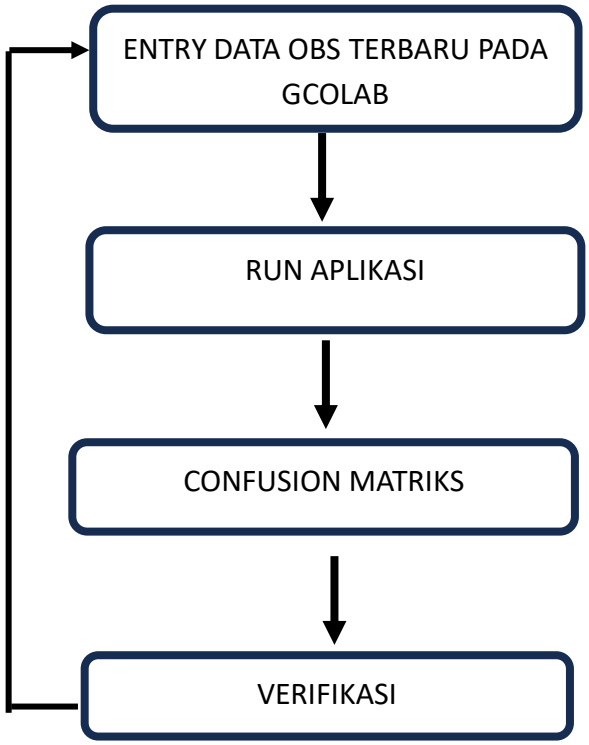

Gambar 12 Bagan alur penelitian dengan metode KNN

Secara umum, cara kerja algoritma *KNN* adalah sebagai berikut :

1) Menentukan jumlah tetangga (k) yang akan digunakan untuk pertimbangan penentuan kelas yang akan diprediksi.
2) Hitung jarak dari data baru ke masing-masing data point yang terdapat pada dataset.
3) Ambil sejumlah k data dengan jarak terdekat, kemudian kelas dari data baru tersebut dapat ditentukan.

Dalam menghitung jarak titik yang akan diprediksi atau belum berlabel dengan titik fitur lain di sekitarnya digunakan formula *euclidean distance,* yaitu dengan mengkuadratkan selisih untuk setiap fitur, kemudian menjumlahkannya, lalu menghitung akar kuadratnya.

$$Distance = \sqrt{\sum_{i=0}^{n} \quad (x_{1i} - x_{2i})^2 + (y_{1i} - y_{2i})^2 + \cdots} \qquad (12)$$

Dari nilai jarak antar titik yang didapat sejumlah K data, maka data yang diprediksi masuk ke dalam kelas dengan data kelas tertentu dengan jumlah data yang terbanyak. Penentuan nilai K tidak memiliki rumus pasti, namun sebagai pertimbangan, jika kelas berjumlah genap maka sebaiknya nilai K ganjil, dan sebaliknya jika kelas berjumlah ganjil maka sebaiknya nilai K genap. Hal itu bertujuan agar hasil perhitungan jarak terdekat tidak memiliki jumlah data tetangga yang sama.

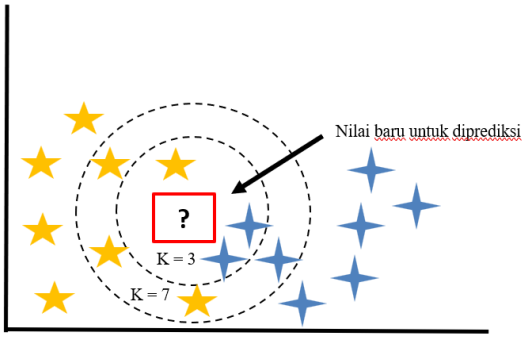

Gambar 13 Ilustrasi pengaruh nilai k

Gambar 13 memperlihatkan bahwa nilai K sebesar tiga dan nilai k sebesar tujuh akan berbeda hasilnya dalam penentuan masuk ke dalam kelas manakah nilai baru yang akan diprediksi. Jika k adalah tiga maka nilai baru tersebut akan dimasukkan pada kelas bintang berwarna biru. Sedangkan jika nilai k sebesar 7 maka nilai baru tersebut akan dimasukkan kedalam kelas bintang kuning. Sehingga percobaan menggunakan nilai k yang beragam perlu dilakukan untuk mendapatkan akurasi *output* prediksi yang lebih akurat.

5. Implementasi

Pada tahap ini *Prakirawan* cuaca yang bertugas melakukan input data empat nilai labilitas atmosfer yaitu *SI, LI, KI, dan TT* ke dalam model yang dibuat dalam google colab, kemudian hasil dari prediksi tersebut dijadikan acuan dalam memberikan informasi adanya awan Comulonimbus di Cilacap Tengah

6. Evaluasi

Evaluasi perlu dilakukan untuk mengetahui sejauh mana keberhasilan dalam penelitian kali ini. Pada tahapan evaluasi dilakukan dengan dua cara, yaitu :

a. Pengukuran akurasi dari output yang dihasilkan oleh ketiga model yang dibuat, berupa *precision*, *recall*, *F1-score* dan *Accuracy.* Untuk menghitung nilai tersebut digunakan Confusion matrix. Ada empat nilai yang dihasilkan di dalam tabel confusion matrix, di antaranya True Positive *(TP)*, False Positive *(FP)*, False Negative *(FN)*, dan True Negative *(TN)*. Ilustrasi tabel confusion matrix dapat dilihat pada gambar 15.

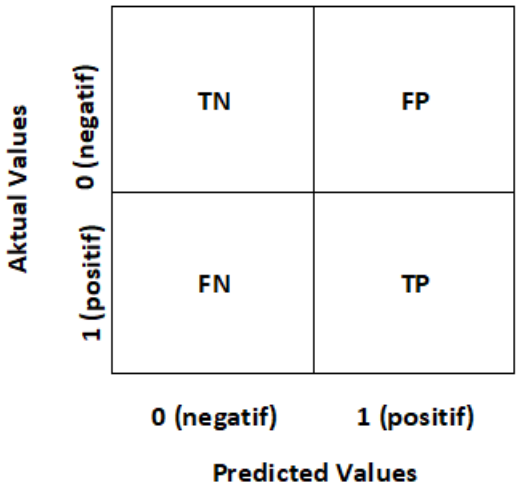

Gambar 14 Evaluasi menggunakan Confusion Matrix

Gambar 14 . memperlihatkan *confusion matrix* dimana terdapat 4 nilai yaitu *TP, FP, FN* dan *TN*. Dari keempat nilai tersebut digunakan untuk menghitung performa dari model machine learning yang dibuat. Antara lain *precision*, *recall*, *F1-score* dan *Accuracy* dengan rumus sebagai berikut :

$$precission = \frac{TP}{(TP + FP)}.$$

$$recall = \frac{TP}{(TP + FN)}.$$

$$f1\ score = \frac{2\ x\ (Recall\ x\ Precission\ )}{(Recall + Precission)}.$$

$$Accuracy = \frac{(TP + TN\ )}{(TP + FP + FN + TN)}.$$

b. Studi kasus sederhana, yaitu melakukan verifikasi dengan mencocokkan hasil prediksi pemodelan machine learning dengan kejadian nyata di lapangan berdasarkan validasi dokumen berupa pengamatan Synop

BAB IV
HASIL DAN PEMBAHASAN

A.Identifikasi Masalah

Dari identifikasi masalah diperolah hasil berupa informasi tentang pengaruh dan dampak buruk yang ditimbulkan oleh awan cumulonimbus (*CB*), Awan *CB* adalah awan rendah yang menyebabkan cuaca buruk sepert angin kencang, puting beliung, petir, hujan lebat tanpa atau disertai es.

Dari permasalahan diatas maka dibuatlah solusi berupa prediksi potensi awan *CB* menggunakan machine learning. Algortima machine learning yang digunakan untuk memprediksi awan cumulonimbus di Cilacap adalah algortima *KNN*. Dengan adanya prediksi diharapkan bisa meminimalisir dampak buruk yang diakibatkan oleh adanya awan *CB*.

B. Data Collecting

Yang dilakukan pada tahap ini adalah pengumpulan data mentah menjadi dataset yang akan digunakan dalam proses machine learning. Dataset adalah modal utama dalam membangun machine learning. Data mentah yang digunakan pada penelitian kali ini berupa data indeks labilitas udara atas hasil pengolahan RAOB dan data Synop. Data indeks labilitas udara terdiri dari nilai *SI, LI, KI dan TT*. Data indeks tersebut merupakan data yang berpotensi menyebabkan terjadinya pertumbuhan awan cumulonimbus. Sementara untuk data Synop berisi data ada tidanya awan *CB*. Data indeks labilitas berisi data indeks dari tahun 2020 hingga 2024 pada pukul 00.0 UTC dan 12.00 UTC, tahun tersebut terbilang paling lengkap dibanding tahun sebelum dan sesudahnya. Jumlah data yang digunakan sebanyak 1752 data, yang terdiri dari

8 fitur yaitu Tahun, Bulan, Tanggal, Jam, *Showalter Index, Lifted Index, Konvergence Index dan Total-Total Index.* Berikut penjelasan mengenai proses pengumpulan data mentah menjadi dataset. Tahap pertama kita mengamati hasil dari RAOB seperti pada gambar 15.

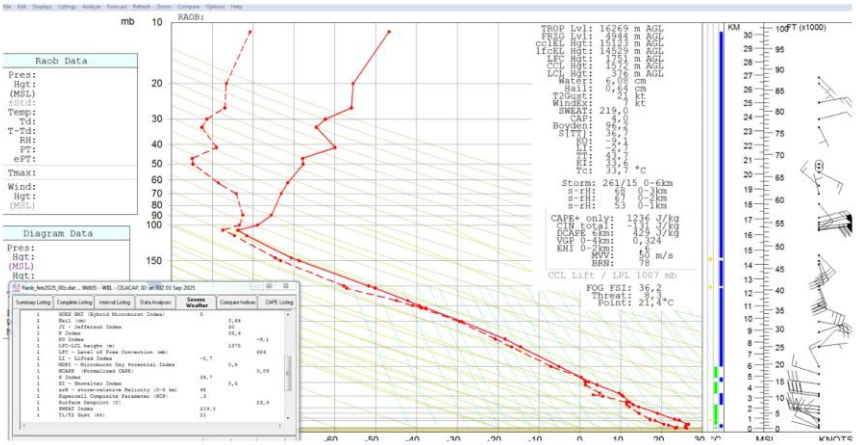

Gambar 15 Hasil RAOB tanggal 1 Feb 2025

Pada gambar 15 memperlihatkan hasil RAOB pada tanggal 1 Februari 2025 jam 00 UTC, didapat nilai indeks *SI, LI, KI dan TT.* Mengaju pada ketetapan yang ada nilai SI -1.6 masuk kategori berpotensi *CB* (sedang), LI -2.1 masuk kategori berpotensi *CB* (lemah), KI 39.4 masuk kategori berpotensi *CB* (kuat0 dan TT 45.0 masuk kategori berpotensi *CB* (sedang). Langkah selanjutnya pengecekan terhadap data pengamatan setiap jam (sinop) BMKG Cilacap pada tanggal 1 Februari 2025.

C.Preprocessing

Preprocessing adalah proses mengubah data mentah ke dalam bentuk yang lebih mudah dipahami. Proses ini diperlukan untuk memperbaiki kesalahan pada data mentah yang seringkali tidak lengkap dan memiliki format yang tidak teratur. Tahapan preprocessing antara lain:

1. Persiapan Data

Tahapan pertama dari preprocessing adalah menyiapkan dataset yang dibutuhkan. Dataset beruba kumpulan nilai indeks hasil RAOB dari tahun 2020 hingga 2024 yang telah ditransformasikan menjadi satu dataset dalam format excel dengan format xlsx bernama “dataset.xlsx”.

Tanggal	Waktu	CAPE	KI	LI	SWEAT	SI	TT	CB
1/1/2020	0	966.19	39.6	-3.66	261.6	-2.65	46.6	1
1/2/2020	0	661.72	34.6	-1.46	221.59	0.64	42	1
1/2/2020	1200	1723.37	39	-3.74	257.42	-0.14	43.7	1
1/3/2020	0	919.66	34.6	-0.68	269.4	0.43	41	0
1/3/2020	1200	2151.29	36.6	-4.73	271.63	-1.88	46.2	1
1/4/2020	0	2002.97	34.9	-4.25	252.99	-1.36	44.8	1
1/4/2020	1200	2258.55	36.5	-5.42	265.62	-3.42	48.2	1
1/5/2020	0	2658.25	37.5	-6.61	292.19	-4.68	49.8	1
1/6/2020	0	1310.4	38.6	-3.78	262.81	-1.43	45.6	0
1/6/2020	1200	2523.33	37	-3.66	287.4	-1.17	43.2	1
1/7/2020	0	1634.35	40.3	-4.06	269.81	-1.99	45.6	0
1/7/2020	1200	1450	36.3	-3.26	270.8	-1.98	45.1	0
1/8/2020	0	1553.46	36.3	-2.75	264.4	-0.4	42.6	0
1/8/2020	1200	1547.49	40.3	-3.35	248.39	-1.66	44.7	0
1/9/2020	0	1239.25	38.2	-1.62	231.78	0.14	41.4	0
1/9/2020	1200	1243.63	37.7	-2.74	235.59	-0.07	42.4	0
1/10/2020	0	812.17	35.9	-2.51	238.8	-0.28	43.2	1
1/10/2020	1200	627.36	39.1	-1.96	245.79	-0.9	43.4	0
1/11/2020	0	969.14	34.6	-2.16	232.4	1.13	41.6	1
1/11/2020	1200	820.9	39.2	-2.95	262.58	-1.29	44.8	1
1/12/2020	0	759.79	31.6	-2.25	246.39	0.82	42.7	0
1/12/2020	1200	2001.19	8	-3.77	235.39	1.04	42.3	0
1/13/2020	0	1081.39	3.3	-3.02	139.41	6.71	36.2	0
1/14/2020	0	2048.8	24	-4.08	234.59	-0.46	43.7	0
1/14/2020	1200	911.08	22.3	-2.99	234.41	0.34	41.2	0
1/15/2020	0	2184.16	31.8	-3.29	231.78	0.3	41.5	0
1/15/2020	1200	2361.25	34.3	-3.89	228.38	-1.69	44.2	1
1/16/2020	0	1883.57	40.8	-4.5	236.58	-2.58	46.4	0
1/16/2020	1200	2523.39	33.4	-4.44	198.98	1.53	41.5	0
1/17/2020	0	1984.5	33.2	-3.96	166.98	3.12	40.4	0
1/17/2020	1200	1516.51	0.7	-2.89	206.01	0.38	42.4	0
1/18/2020	0	1447.17	7.3	-2.28	178.58	2.58	40	0
1/18/2020	1200	990.05	37.8	-1.86	225.37	-1.63	44.2	0
1/19/2020	0	1448.26	36.2	-2.58	203.21	0.85	41.8	0
1/19/2020	1200	2240.78	5.2	-2.96	190.17	1.97	40.1	0
1/20/2020	1200	1981.5	16.7	-4.17	189.19	0.65	43.2	0
1/21/2020	0	2162.44	37.9	-4.38	208.79	-1.12	45	1

Gambar 16 Tampilan tabel dataset

Pada gambar 16 memperlihatkan dataset “data_indeks_*CB*.xlsx” berisi kolom Tahun, Jam, Nilai indeks *SI, LI, KI, TT* dan awan *CB*. Langkah selanjutnya adalah memanggil data tersebut kedalam halaman google colab seperti pada gambar 17

```
#impor library yang dibutuhkan
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
```

Gambar 17 Iibrary

Pada gambar 17 memperlihatkan library yang dibutuhkan untuk pengolahan data seperti Pandas, Numpy, matplotlib, dan seaborn. Pandas digunakan untuk melakukan pembacaan dan pengolahan pada data. Numpy adalah library untuk melakukan berbagai operasi numerik. Matplotlib digunakan untuk melakukan visualisasi data seperti membuat plot grafik untuk satu sumbu atau lebih. Sedangkan Seaborn digunakan untuk membuat grafik dan statistik.. Langkah selanjutnya memanggil dataset ke dalam google colab.

```
[ ] #impor excel ke dataset
    data = pd.read_excel('dataset.xlsx')
    data
```

Gambar 18 Proses pemanggilan dataset

Pada gambar 18 terlihat proses pemanggilan dataset kedalam halaman kerja google colab, yaitu dengan membaca ekstensi dari dataset yang sudah diunggah pada tahap sebelumnya bernama “dataset.xlsx”. Pada proses pembacaan dataset dengan format xlsx maka diperlukan fungsi “read_excel” dari library Pandas yang telah diimport sebelumnya. Tahap selanjutnya melihat isi dari dataset.

	Tanggal	Waktu	CAPE	KI	LI	SWEAT	SI	TT	CB	Cuaca Buruk
0	2020-01-01	0	966.19	39.6	-3.66	261.60	-2.65	46.6	1	1
1	2020-01-02	0	661.72	34.6	-1.46	221.59	0.64	42.0	1	0
2	2020-01-02	1200	1723.37	39.0	-3.74	257.42	-0.14	43.7	1	0
3	2020-01-03	0	919.66	34.6	-0.68	269.40	0.43	41.0	0	0
4	2020-01-03	1200	2151.29	36.6	-4.73	271.63	-1.88	46.2	1	0

Gambar 19 Dataset lima baris

Gambar 19 memperlihatkan perintah "data.head()" yang bertujuan untuk menampilkan lima baris teratas dari dataset tersebut. Terlihat bahwa terdapat 10 kolom yaitu "Tanggal", "waktu", keempat kolom tersebut menunjukkan waktu pencatatan data. Kolom *"SI"* yang menunjukkan nilai indeks dari *showlater index*. kolom *"LI"* yang menujukkan nilai indeks dari *iifted index*, kolom *"KI"* yang menunjukkan nilai indeks dari *konvergence index*, kolom *"TT"* yang menunjukkan nilai dari *total-total index*, dan kolom "*CB*" yang merupakan singkatan dari cumulonimbus yang menunjukkan ada tidaknya kejadian awan *CB* yang teramati pada jam 07.00 WIB hingga jam 18.00 WIB pada tanggal tersebut. Langkah selanjutnya melihat informasi tentang dataset.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1752 entries, 0 to 1751
Data columns (total 10 columns):
 #   Column       Non-Null Count  Dtype
---  ------       --------------  -----
 0   Tanggal      1752 non-null   datetime64[ns]
 1   Waktu        1752 non-null   int64
 2   CAPE         1752 non-null   float64
 3   KI           1746 non-null   float64
 4   LI           1752 non-null   float64
 5   SWEAT        1751 non-null   float64
 6   SI           1751 non-null   float64
 7   TT           1750 non-null   float64
 8   CB           1752 non-null   int64
 9   Cuaca Buruk  1752 non-null   int64
dtypes: datetime64[ns](1), float64(6), int64(3)
memory usage: 137.0 KB
```

Gambar 20 Informasi dataset

Gambar 20 memperlihatkan informasi dari *dataset* tersebut, seperti tipe data, jumlah data, dan sebagainya. Terlihat terdapat perbedaan jumlah data pada kolom yang ada, yang berarti terdapat missing value pada tadaset tersebut, sehingga perlu dilakukan penanganan lebih lanjut agar kualitas data menjadi baik.

2. Penanganan Missing value

Missing value adalah peristiwa hilang atau tidak terbacanya data. Missing value menyebabkan masalah pada algoritma yang akan dibangun dan bisa menimbulkan perubahan hasil analisis. Dalam machine learning, penggunaan dataset yang buruk akan menghasilkan output yang juga berkualitas buruk, sehingga permasalahan missing value perlu ditangani dengan serius. Langkah pertama dari misiing value adalah melihat data missing seperti tampak pada gambar 21 di bawah ini.

```
[ ] #melihat missing value)
    data_miss=data[data.isna().any(axis=1)]
    data_miss
```

	Tanggal	Waktu	CAPE	KI	LI	SWEAT	SI	TT	CB	Cuaca Buruk
89	2020-02-23	0	0.00	NaN	23.70	33.00	21.08	NaN	1	1
635	2021-10-07	0	199.98	NaN	-1.80	204.41	0.60	43.1	0	0
860	2022-06-28	0	187.49	NaN	3.06	192.81	7.06	31.9	0	0
862	2022-06-29	0	58.94	NaN	2.89	150.20	8.02	32.6	0	0
864	2022-06-30	0	1.67	NaN	2.70	156.40	7.01	34.8	0	0
1100	2022-11-07	1200	464.12	NaN	-2.13	NaN	NaN	NaN	1	1

Gambar 21 Data missing value

Pada gambar 21 terlihat beberapa data missing value yang ditandai dengan symbol “NaN” yang berarti bahwa terdapat data kosong atau missing value, seperti terlihat pada baris 89, 635, 860, 862, 864 dan 1100 dimana terdapat missing value pada variabel*, KI dan TT*. Pada baris 1100 mising value terlihat pada variabel KI, SI, dan TT. Selanjutnya kita menghitug secara detail jumlah variabel data yang mengalami missing value seperti terlihat pada gambar 23

```
[ ] # malihat jumlah data missing
    print(data.isnull().sum())

Tanggal        0
Waktu          0
CAPE           0
KI             6
LI             0
SWEAT          1
SI             1
TT             2
CB             0
Cuaca Buruk    0
dtype: int64
```

Gambar 22 Data yang mengalami missing value

Pada gambar 22 terdapat jumlah beberapa varibel data yang mengalami missing value antara lain data *SI* terdapat 1 data missing, *KI* terdapat 6 data

missing, dan *TT* terdapat 2 data missing. Langkah selanjutnya adalah menangani missing value.

Pada penelitian ini cara yang dilakukan dalam menangani missing value dengan menghapus data kosong, Seperti terlihat pada gambar 22

```
[ ] #menghapus baris yang kosong
    data=data.dropna()
    data.info()
```

```
<class 'pandas.core.frame.DataFrame'>
Index: 1746 entries, 0 to 1751
Data columns (total 10 columns):
 #   Column       Non-Null Count  Dtype
---  ------       --------------  -----
 0   Tanggal      1746 non-null   datetime64[ns]
 1   Waktu        1746 non-null   int64
 2   CAPE         1746 non-null   float64
 3   KI           1746 non-null   float64
 4   LI           1746 non-null   float64
 5   SWEAT        1746 non-null   float64
 6   SI           1746 non-null   float64
 7   TT           1746 non-null   float64
 8   CB           1746 non-null   int64
 9   Cuaca Buruk  1746 non-null   int64
dtypes: datetime64[ns](1), float64(6), int64(3)
memory usage: 150.0 KB
```

Gambar 23 Perintah "dropna" untuk menghapus

Gambar 23 memperlihatkan perintah “dropna()” untuk menghapus baris data yang kosong. Setelah dilakukan penanganan missing value, pastikan bahwa jumlah data yang ada pada setiap variable berjumlah sama. Dengan perintah “df.info” kita bisa melihat jumlah masing masing data tiap variable. Terlihat pada gambar 23 jumlah data tiap variable sama yaitu 1746 data, yang berarti proses penanganan missing value berhasil.

```
[ ]  # Variabel independen
     x = data[['KI','LI','SI','TT']]
     x.head()
```

	KI	LI	SI	TT
0	39.6	-3.66	-2.65	46.6
1	34.6	-1.46	0.64	42.0
2	39.0	-3.74	-0.14	43.7
3	34.6	-0.68	0.43	41.0
4	36.6	-4.73	-1.88	46.2

Gambar 24 Variabel independent

Pada gambar 24 memperlihatkan variabel x (features) yang berisi data independen antara lain berupa nilai labilitas atmosfer yaitu KI, LI, SI, dan TT. Sedangkan gambar 24 memperlihatkan variabel Y sebagai data dependen.

```
[ ]  # Variabel dependen
     y = data['CB']
     y.head()
```

	CB
0	1
1	1
2	1
3	0
4	1

dtype: int64

Gambar 25 Variabel dependen

Pada gambar 26 memperlihatkan proses training set dan testing set terlebih dahulu mengimpor fitur “train_test_split”dari library scikit-learn.

Pada bagian “test_size” tertulis 0.2 yang berarti digunakan data test sebesar 20% dari total keseluruhan data. Atau dapat dikatakan perbandingan antara data train dan data test adalah 80:20, artinya 80% dari total data digunakan untuk training, dan 20% dari total data digunakan untuk testing. Tidak ada proporsi yang mengikat dalam pembagian persentase data train dan test.

```
[ ] # Import train_test_split function
    from sklearn.model_selection import train_test_split
    x_train, x_test, y_train, y_test = train_test_split(x, y, test_size = 0.2, random_state=5

[ ] # jumlah data training dan testing
    print(x_train.shape)
    print(x_test.shape)

    (1396, 4)
    (350, 4)
```

Gambar 26 Data training dan testing

D. Membangun model Machine Learning

Proses selanjutnya adalah membangun machine learning. Model Machine learning bertujuan untuk melatih data dan melakukan prediksi menggunakan variabel yang ditentukan oleh machine learning. Metode Machine learning yang digunakan pada penelitian ini adalah KNN

K-Nearest Neighbor adalah algoritma machine learning yang mengkelaskan data baru menggunakan kemiripan antara data baru dengan sejumlah data (k) pada lokasi yang paling dekat dengan kumpulan data yang telah ada sebelumnya. Proses membangun machine learning menggunakan metode *KNN* seperti tampak pada gambar 27

Metode KNN

```
[ ] from sklearn.neighbors import KNeighborsClassifier
```

```
[ ] # knn model
    knn = KNeighborsClassifier(n_neighbors=17,
                               weights='uniform',
                               algorithm='auto',
                               metric='euclidean')

    knn.fit(x_train, y_train)
```

```
KNeighborsClassifier
KNeighborsClassifier(metric='euclidean', n_neighbors=17)
```

Gambar 27 Metode KNN

Untuk melakukan prediksi menggunakan *KNN* maka digunakan perintah *"KNeighboarsClassifier"* yang disimpan dalam variabel bernama "y_pred_*KNN*s". Pada *KNN* kita harus menentukan jumlah tetangga (k) yang akan digunakan untuk pertimbangan penentuan kelas yang akan diprediksi. Penentuan nilai k ini tidak ada rumus pastinya. Namun satu tips yang dapat dipertimbangkan, yakni jika kelas berjumlah genap maka sebaiknya nilai k-nya ganjil, sebaliknya jika kelas berjumlah ganjil maka sebaiknya nilai k-nya genap. Dikarenakan jumlah data latih adalah genap maka nilai K ditentukan sebagai nilai ganjil agar tidak terjadi jumlah yang sama dalam melakukan klasifikasi data baru yang akan diprediksi. Pada kasus ini digunakan jumlah tetangga (k) bernilai 17. Karena dari hasil ujicoba nilai tersebut mempunyai hasil skor paling baik dibanding nilai lainnya.

```
[ ]  # Menentukan hasil prediksi dari x_test
     y_pred_knns = knn.predict(x_test)
     y_pred_knns
```

```
array([0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0,
       0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 0,
       0, 1, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0,
       0, 1, 1, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0,
       0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 1, 1,
       0, 0, 1, 0, 0, 1, 1, 0, 0, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0,
       1, 1, 0, 1, 1, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1,
       0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1,
       0, 0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 1, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0,
       0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1, 0, 1, 0, 0, 0,
       0, 1, 0, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0,
       1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0,
       1, 1, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0, 1])
```

Gambar 28 Hasil Prediksi

E.Implementasi

Pada tahap implementasi hasil penelitian sudah siap digunakan untuk melakukan prediksi pertumbuhan awan di Cilacap. Prakirawan yang bertugas bisa mengakses permodelan tersebut melalui google colab kemudian menginputkan ke empat nilai indeks labilitas hasil Rawindsonde setelah telebih dahulu menggunakan aplikasi RAOB, seperti pada gambar 29

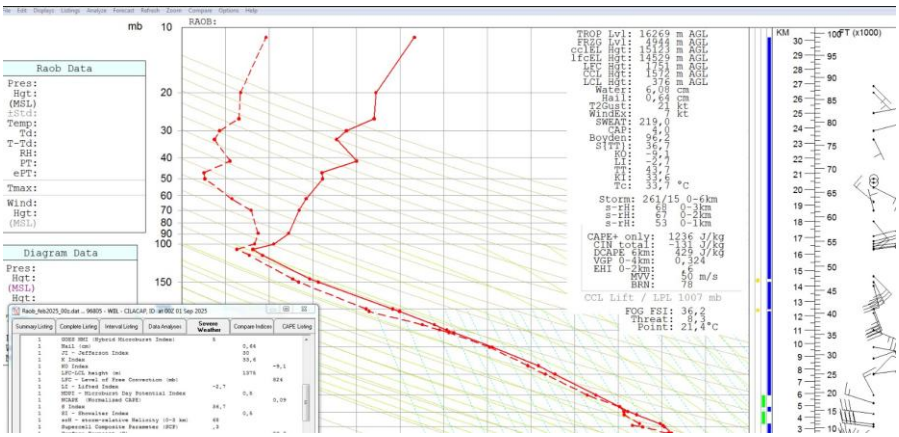

Gambar 29 Hasil RAOB 1 Februari 2025

Pada Gambar 29 terlihat hasil RAOB tanggal 1 Februari 2025, dengan nilai *SI sebesar 0.6, LI –2.7, KI 33.6, dan TT 43.7*. Langkah selanjutnya

membuka permodelan machine learning yang telah dibanggun menggunakan google colab, kemudian memasukan ke empat nilai indeks tersebut kedalam permodelan. Untuk permodelan machine learning yang pertama adalah metode KNN seperti terlihat pada gambar 28.

```
#melakukan prediksi KNN dengan memasukan data inputan
# KI, LI, SI, TT,
data=[(33.6,-2.6,0.6,43.7)]
prediksi=knn.predict(data)
print(prediksi)
```

```
[0]
/usr/local/lib/python3.12/dist-packages/sklearn/utils/validation.py:2739
  warnings.warn(
```

Gambar 30 Hasil Prediksi

Gambar 30 memperlihatkan nilai keempat indeks telah diinputkan kedalam permodelan machine leraning *KNN*, setelah di RUN hasinya bernilai "0". Yang artinya pada hari itu diprediksi tidak ada awan *CB*

```
# import confusion_matrix model
from sklearn.metrics import confusion_matrix
confusion_matrix(y_test, y_pred_knns)
```

```
array([[205,  31],
       [ 55,  59]])
```

Gambar 31 Confusion matrix

Evaluasi perlu dilakukan untuk mengetahui sejauh mana keberhasilan dalam penelitian kali ini. Evaluasi dilakukan dengan dua cara, yaitu pertama evaluasi menggunakan pengukuran skor prediksi dari output yang dihasilkan

oleh ketiga model yang dibuat, berupa *precision* , *recall*, *F1-score* dan accurasi. Evaluasi kedua menggunakan Studi kasus sederhana, yaitu melakukan verifikasi dengan mencocokkan hasil implemetasi dengan kejadian nyata di lapangan

1. Evaluasi menggunakan pengukuran skor prediksi dari output yang dihasilkan oleh ketiga model yang dibuat, berupa *precision* , *recall, F1-score* dan *Accuracy.* Semakin tinggi nilai skor prediksi semakin bagus performa machine learning yang dihasilkan, Untuk menghitung nilai tersebut digunakan Confusion matrix Seperti pada gambar 30

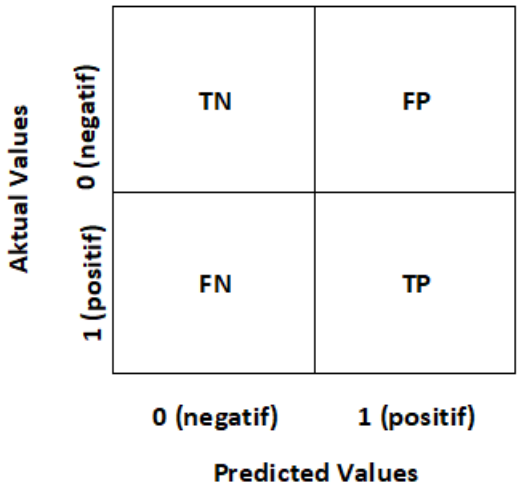

Gambar 32 Evaluasi dengan Confuison Matrix

Gambar 32 memperlihatkan confusion matrix yang akan digunakan untuk menghitung nilai, precission, *recall f1- score* dan *Accuracy* dengan menggunakan rumus dibawah ini

$$precission = \frac{TP}{(TP + FP)}.$$

$$recall = \frac{TP}{(TP + FN)}.$$

$$f1\ score = \frac{2\ x\ (Recall\ x\ Precission\ )}{(Recall + Precission)}.$$

$$Accuracy = \frac{(TP + TN\ )}{(TP + FP + FN + TN)}.$$

```
import seaborn as sns
import matplotlib.pyplot as plt
f, ax = plt.subplots(figsize=(7,5))
sns.heatmap(confusion_matrix(y_test, y_pred_knns), annot=True, fmt=".0f", ax=ax)
plt.xlabel('Predicted Label')
plt.ylabel('True Label')
plt.show()
```

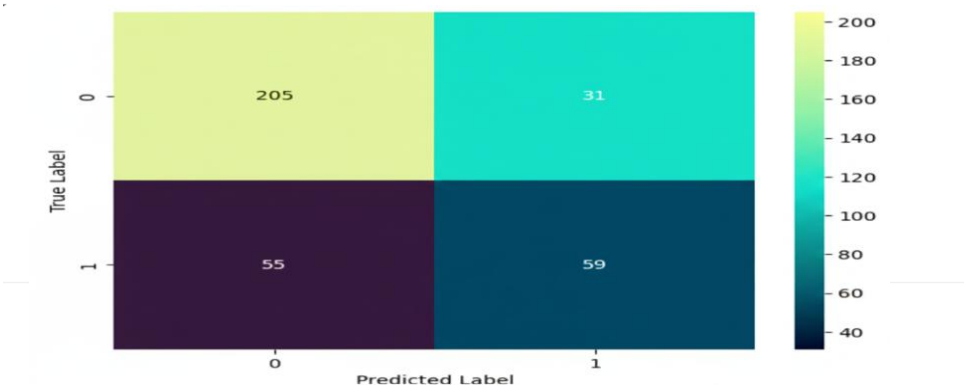

Gambar 33 Confusion Matrix KNN

Pada gambar 33 memperlihatkan Confusion matrix dengan nilai *TP* sebesar 59 , nilai *FP* 31, nilai *FN* 55 dan nilai *TN* 205. Dari nilai tersebut digunakan untuk menghitung pression, *recall* f1- score dan *Accuracy* dengan hasil seperti tehjrlihat pada gambar 34

```
# Menghitung nilai akurasi dari klasifikasi KNN
from sklearn.metrics import classification_report
print(classification_report(y_test,y_pred_knns))
from sklearn.metrics import precision_score,recall_score,f1_score,accuracy_score
print('accurasy_score: {}'.format(accuracy_score(y_test, y_pred_knns)))
print('Precision: {}'.format(precision_score(y_test, y_pred_knns)))
print('Recall: {}'.format(recall_score(y_test, y_pred_knns)))
print('F1-Score: {}'.format(f1_score(y_test, y_pred_knns)))
```

```
              precision    recall  f1-score   support

           0       0.79      0.87      0.83       236
           1       0.66      0.52      0.58       114

    accuracy                           0.75       350
   macro avg       0.72      0.69      0.70       350
weighted avg       0.75      0.75      0.75       350

accurasy_score: 0.7542857142857143
Precision: 0.6555555555555556
Recall: 0.5175438596491229
F1-Score: 0.5784313725490197
```

Gambar 34 Skor prediksi dengan KNN

Pada gambar 34 terlihat hasil skor prediksi menggunakn *KNN*, dimana diperoleh nilai *Accuracy* sebesar 75%, *precision* sebesar 65%, *recall* 52%, dan *F1-score* 58%. Nilai *Accuracy* tersebut tidak mencapai nilai ambang batas 80 %.

2. Evaluasi menggunakan Studi kasus sederhana

   yaitu melakukan verifikasi dengan mencocokkan hasil prediksi pemodelan machine learning dengan kejadian nyata di lapangan berdasarkan validasi dokumen berupa berita synop

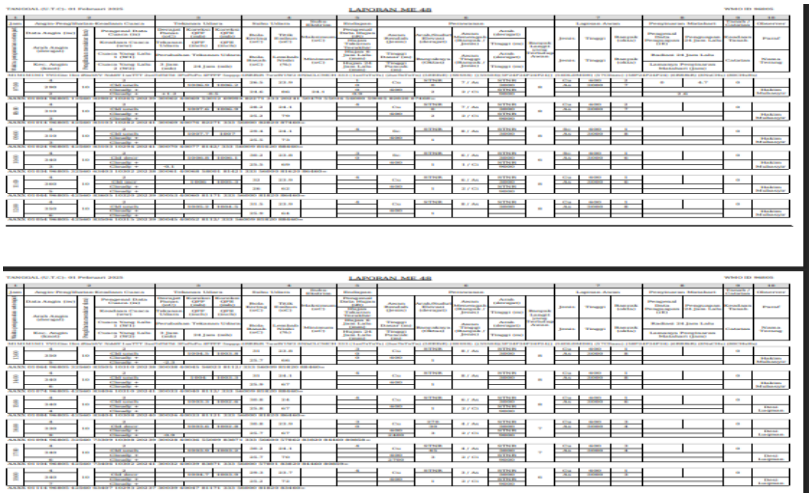

Ganbar 35 Tampilan pengamatan synop

Gambar 35 memperlihatkan synop tanggal 1 Februari 2025. Pada hari itu dilaporkan tidak ada kejadian awan *CB* pada jam 00 sampai dengan 11 UTC. Selanjutnya dibuatlah tabel perbandingan studi kasus antara prediski dengan kenyataan dilapangan, seperti pada table 5

Tabel 5 hasil Prediksi

Tanggal	Kenyataan (SYNOP)	Hasil Prediksi KNN
1 Januari 2025	0	0
1 Februari 2025	0	0

Tabel 5 memperlihatkan hasil antara prediksi dan kenyataan, pada angka 1 mewakili ada awan *CB* dan 0 tidak ada awan *CB*. Dari hasil evaluasi berupa studi kasus sebanyak 2 kali diperoleh hasil algortima KNN adalah 0

Berdasarkan evaluasi yang dilakukan menggunakan skor prediksi dan studi kasus, membuktikan bahwa metode machine learning yang digunakan berjalan dengan baik dan mampu memprediksi kejadian awan *CB*. *Accuracy* yang dihasilkan menggunakan metode *KNN Accuracy* yang dihasilkan adalah sebesar 75%, Akurasi tersebut tidak mencapai batas standar minimum suatu algoritma dikatakan berhasil yaitu 80%. Sedangkan. Untuk meningkatkan akurasi maka dirasa perlu penambahan jumlah dataset. Semakin banyak dataset semakin banyak data yang dilatih di dalam machine learning yang dibuat. Sehingga bisa digunakan untuk meningkatkan akurasi *KNN*

3. Analisa dari nilai indek terhadap pertumbuhan awan CB

Data yang digunakan pada prediksi awan cb yaitu data dari tahun 2020 sampai 2024 tahun dengan Matrik Korelasi.

```
import seaborn as sns

sns.heatmap(data.corr(), vmin=-1, vmax=1,
annot=True,cmap="rocket_r")
plt.show()
```

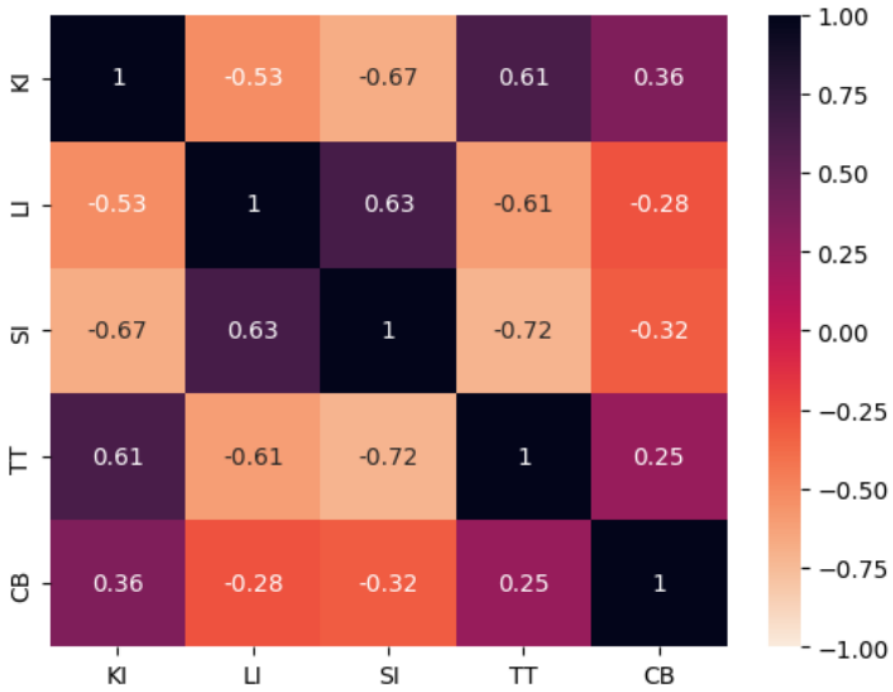

Gambar 36 Matriks Korelasi

Berdasarkan analisis korelasi antara beberapa parameter atmosferik terhadap pembentukan awan cumulonimbus (CB), diperoleh bahwa beberapa indeks atmosfer memiliki hubungan yang cukup signifikan dengan CB. Nilai KI memiliki korelasi positif sebesar 0.36 terhadap CB, yang mengindikasikan bahwa nilai KI yang lebih tinggi dapat mendukung kondisi atmosfer yang lebih labil. Sebaliknya, nilai LI memiliki korelasi negatif dengan CB sebesar -0.28, sesuai dengan konsep bahwa nilai LI yang lebih rendah (lebih negatif) menunjukkan

atmosfer yang lebih tidak stabil dan lebih mendukung pertumbuhan awan cumulonimbus. Sementara itu, SI dan TT memiliki korelasi masing-masing sebesar -0.32 dan 0.25 terhadap CB, yang juga menunjukkan adanya pengaruh terhadap pembentukan awan tersebut.

BAB V
PENUTUP

A. Kesimpulan

Berdasarkan dari hasil penelitian yang telah dilakukan tentang perbandingan metode *KNN* untuk memprediksi awan *CB* di Cilacap, maka dapat ditarik kesimpulan sebagai berikut:

1. Dalam penelitian ini penggunaan machine learning mampu memprediksi awan *CB* di Cilacap dengan *KNN*
2. Akurasi yang dihasilkan menggunakan metode KNN sebesar 75%. Akurasi tersebut sudah tidak mencapai standar minimum 80%, machine learning masih dikatakan baik

B. Saran

Dari penelitian yang telah dilakukan oleh penulis, tingkat akurasi dari perhitungan pada pemodelan tersebut memang termasuk baik, namun masih memiliki beberapa kekurangan, sehingga penelitian selanjutnya diharapkan mempertimbangkan beberapa hal sebagai berikut :

1. Menambahkan jumlah data *SI, KI, LI,* dan *TT* lebih banyak lagi agar model dengan algoritma machine learning dapat dilatih dengan jumlah data yang lebih banyak guna meningkatkan tingkat akurasinya.
2. Perlunya memperhatikan komposisi dataset agar tidak terjadi kasus imbalance data yang akan merusak nilai akhir machine learning yang dibangun tanpa disadari. Membagi dataset kedalam dua jenis sebelum dilakukan pengolahan, yaitu dataset pada saat musim kemarau dan saat musim penghujan, agar data lebih mudah diklasifikasikan karena data akan memiliki keragaman yang relatif lebih sedikit

DAFTAR PUSTAKA

[1] D. R. Rochmawati, "Prediksi Cuaca Dengan Jaringan Syaraf Tiruan Menggunakan Python," *J. Teknol. Komput. dan Inform.*, vol. 2, no. 2, pp. 162–171, 2024, doi: 10.59820/tekomin.v2i2.228.

[2] Junadhi and Mardainis, "LINE Chatbot Informasi Cuaca Wilayah Indonesia," *Digit. Zo. J. Teknol. Inf. dan Komun.*, vol. 10, no. 1, pp. 101–109, 2019, doi: 10.31849/digitalzone.v10i1.2467.

[3] P. A. Kholiviana, Y. Ruhiat, and A. Saefullah, "Analisis Vertical Wind Shear Pada Pertumbuhan Awan Cumulonimbus Di Wilayah Kabupaten Tangerang," *Newton-Maxwell J. Phys.*, vol. 3, no. 1, pp. 17–23, 2022, doi: 10.33369/nmj.v3i1.21080.

[4] K. B. Damanik, Y. Fitri, and S. Gautami, "Analisis Perubahan Suhu Dan Tekanan Udara Permukaan Terhadap Pertumbuhan Awan Cumulonimbus (Cb) DI Bandar Udara (Bandara) Sultan Syarif Kasim Ii Pekanbaru," *Phot. J. Sain dan Kesehat.*, vol. 6, no. 02, pp. 131–138, 1930, doi: 10.37859/jp.v6i02.492.

[5] P. P. Sani and H. Ismanto, "Prediksi Awan Cumulonimbus Menggunakan Indeks Stabilitas Keluaran Model Wrf – Arw Di Bima," vol. 1, pp. 1–8, 2015.

[6] T. Wahyono, *Fundamental Of Python For Machine Learning*, Pertama. Yogyakarta: GAVA MEDIA, 2021.

[7] M. N. Maskuri, K. Sukerti, and R. M. Herdian Bhakti, "Penerapan Algoritma K-Nearest Neighbor (KNN) untuk Memprediksi Penyakit Stroke Stroke Desease Predict Using KNN Algorithm," *J. Ilm. Intech Inf. Technol. J. UMUS*, vol. 4, no. 1, pp. 130–140, 2022.

[8] Y. Kristanto, T. Agustin, and F. R. Muhammad, "Spektral Citra Satelit Resolusi Spasial Menengah Landsat 8 Oli / Tirs (Studi Kasus : Provinsi Dki Jakarta)," *Meteorol. Klimatologi dan Geofis. Vol. 4 No. 2, Juli 2017*,

vol. 4, no. 2, pp. 42–51, 2017, [Online]. Available: https://share.google/wIdgi9as9Z9bx4rCz

[9] kumparanNews, “Apa itu awan cumulonimbus dan bahayanya bagi dunia penerbangan.”

[10] D. Kurniawan, *Pengenalan machine learning dengan python*. Jakarta: PT. Elekmedia Komputindo, 2021.

[11] Y. Heryadi and T. Wahyono, *Machine learning konsep dan implemetasi*. Yogyakarta: Penerbit Gava Media, 2020.

[12] Rina, “Mengenal K-Nearest Neighbor: Algoritma Populer untuk Machine Learning,” 2021, [Online]. Available: hhttps://esairina.medium.com/algoritma-k-nearest-neighbor-knn-penjelasan-dan-implementasi-untuk-klasifikasi-kanker-ff9b7fbe0a4

[13] baktikominfo, “Informasi Tentang Pengertian, Karakteristik, Dan Dampak Dari Machine Learning.”

[14] D. E. Doloksaribu, “Analisa Hubungan Indeks Keluaran Raob Berdasarkan Pengamatan Radiosonde Dengan Kejadian Hujan Dan Guntur Di Polonia,” *Over Rim*, pp. 191–199, 2017.

[15] faqih Nurrohman and B. Tjasyono, “Kajian Indeks Stabilitas Atmosfer Terhadap Kejadian Hujan Lebat Di Wilayah Makassar (Studi Kasus Bulan Desember 2013 – 2014),” *J. Meteorol. Klimatologi dan Geofis.*, vol. 3, no. 2, pp. 18–24, 2016.

[16] National Weather Service, “Convective season environmental parameters and indices.”

LAMPIRAN

```
#impor library yang dibutuhkan
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
```

```
#impor excel ke dataset
data = pd.read_excel('dataset.xlsx')
data
```

	KI	LI	SI	TT	CB
0	39.6	-3.66	-2.65	46.6	1
1	34.6	-1.46	0.64	42.0	1
2	39.0	-3.74	-0.14	43.7	1
3	34.6	-0.68	0.43	41.0	0
4	36.6	-4.73	-1.88	46.2	1
...	...	...	...	...	...
1747	37.2	-4.71	-0.50	42.2	1
1748	39.8	-4.58	-1.59	44.2	1
1749	37.2	-4.42	-1.82	45.0	1
1750	36.2	-3.23	-1.38	43.4	1
1751	37.6	-4.23	-1.28	43.9	1

1752 rows × 5 columns

Langkah berikutnya: Buat kode dengan data New interactive sheet

```
data.corr()
```

	KI	LI	SI	TT	CB
KI	1.000000	-0.525642	-0.673139	0.611822	0.355262
LI	-0.525642	1.000000	0.627728	-0.608243	-0.277486
SI	-0.673139	0.627728	1.000000	-0.717266	-0.318089
TT	0.611822	-0.608243	-0.717266	1.000000	0.245986
CB	0.355262	-0.277486	-0.318089	0.245986	1.000000

```
import seaborn as sns

sns.heatmap(data.corr(), vmin=-1, vmax=1,
annot=True,cmap="rocket_r")
plt.show()
```

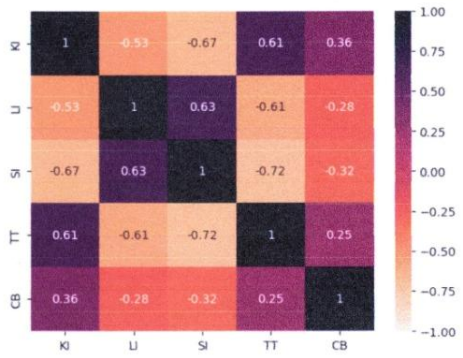


```
#memanggil data 5 teratas
data.head()
```

	KI	LI	SI	TT	CB
0	39.6	-3.66	-2.65	46.6	1
1	34.6	-1.46	0.64	42.0	1
2	39.0	-3.74	-0.14	43.7	1
3	34.6	-0.68	0.43	41.0	0
4	36.6	-4.73	-1.88	46.2	1

Langkah berikutnya: Buat kode dengan data New interactive sheet

```
# menampilkan informasi data
data.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1752 entries, 0 to 1751
Data columns (total 5 columns):
 #   Column  Non-Null Count  Dtype
---  ------  --------------  -----
 0   KI      1746 non-null   float64
 1   LI      1752 non-null   float64
 2   SI      1751 non-null   float64
 3   TT      1750 non-null   float64
 4   CB      1752 non-null   int64
dtypes: float64(4), int64(1)
memory usage: 68.6 KB
```

```
#melihat missing value)
data_miss=data[data.isna().any(axis=1)]
data_miss
```

	KI	LI	SI	TT	CB
89	NaN	23.70	21.08	NaN	1
635	NaN	-1.80	0.60	43.1	0
860	NaN	3.06	7.06	31.9	0
862	NaN	2.89	8.02	32.6	0
864	NaN	2.70	7.01	34.8	0
1100	NaN	-2.13	NaN	NaN	1

Langkah berikutnya: Buat kode dengan data_miss New interactive sheet

```
# malihat jumlah data missing
print(data.isnull().sum())
```

```
KI    6
LI    0
SI    1
TT    2
CB    0
dtype: int64
```

```
#menghapus baris yang kosong
data=data.dropna()
data.info()
```

```
<class 'pandas.core.frame.DataFrame'>
Index: 1746 entries, 0 to 1751
Data columns (total 5 columns):
 #   Column  Non-Null Count  Dtype
---  ------  --------------  -----
 0   KI      1746 non-null   float64
 1   LI      1746 non-null   float64
 2   SI      1746 non-null   float64
 3   TT      1746 non-null   float64
 4   CB      1746 non-null   int64
dtypes: float64(4), int64(1)
memory usage: 81.8 KB
```

```
# malihat jumlah data missing
print(data.isnull().sum())
```

```
KI    0
LI    0
SI    0
TT    0
CB    0
dtype: int64
```

```
#memanggil data 5 teratas
data.head()
```

	KI	LI	SI	TT	CB
0	39.6	-3.66	-2.65	46.6	1
1	34.6	-1.46	0.64	42.0	1
2	39.0	-3.74	-0.14	43.7	1
3	34.6	-0.68	0.43	41.0	0
4	36.6	-4.73	-1.88	46.2	1

Langkah berikutnya: Buat kode dengan data New interactive sheet

```
# Variabel independen
x = data[['KI','LI','SI','TT']]
x.head()
```

	KI	LI	SI	TT
0	39.6	-3.66	-2.65	46.6
1	34.6	-1.46	0.64	42.0
2	39.0	-3.74	-0.14	43.7
3	34.6	-0.68	0.43	41.0
4	36.6	-4.73	-1.88	46.2

Langkah berikutnya: Buat kode dengan x New interactive sheet

```
# Variabel dependen
y = data['CB']
y.head()
```

```
   CB
0   1
1   1
2   1
3   0
4   1
dtype: int64
```

```
# Import train_test_split function
from sklearn.model_selection import train_test_split
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size = 0.2, random_state=5)
```

```
# jumlah data training dan testing
print(x_train)
print(x_test)
```

```
        KI    LI    SI    TT
755   30.1 -0.62  3.10  38.2
579   39.7 -3.35 -2.21  47.4
7     37.5 -6.61 -4.68  49.8
691   20.7 -1.99  8.01  33.6
420   37.6 -2.37 -1.87  46.0
...    ...   ...   ...   ...
1148  35.8 -3.81 -0.39  43.9
1003  36.9 -2.31  0.49  42.2
1731  16.7 -1.17 -0.28  42.2
207   38.7 -3.25 -0.07  41.6
872   34.5 -4.01 -0.42  44.0

[1396 rows x 4 columns]
        KI    LI    SI    TT
177   35.3 -4.74 -1.05  46.2
1196  35.0 -2.15  0.72  42.7
1316  33.8 -1.48  1.82  40.8
140   41.7 -3.74 -2.44  44.6
1044  33.4 -4.51  0.92  45.2
...    ...   ...   ...   ...
668   36.6 -2.48 -1.68  45.8
1112  39.5 -2.96 -1.30  44.2
985   13.9 -1.13  7.83  34.2
1421  28.1 -1.23  2.82  40.2
1296  37.9 -1.77 -0.21  43.0

[350 rows x 4 columns]
```

Metode KNN

```
from sklearn.neighbors import KNeighborsClassifier
```

```
# knn model
knn = KNeighborsClassifier(n_neighbors=17,
                           weights='uniform',
                           algorithm='auto',
                           metric='euclidean')

knn.fit(x_train, y_train)
```

```
KNeighborsClassifier
KNeighborsClassifier(metric='euclidean', n_neighbors=17)
```

```
# Menentukan hasil prediksi dari x_test
y_pred_knns = knn.predict(x_test)
y_pred_knns
```

```
array([0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0,
       0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 0,
       0, 1, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0,
       0, 1, 1, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0,
```

```
       0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 1, 1,
       0, 0, 1, 0, 0, 1, 1, 0, 0, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0,
       1, 1, 0, 1, 1, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1,
       0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1,
       0, 0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 1, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0,
       0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1, 0, 1, 0, 0, 0,
       0, 1, 0, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0,
       1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0,
       1, 1, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0, 1])
```

```
#melakukan prediksi KNN dengan memasukan data inputan
#   KI, LI, SI, TT,
data=[(39.1,-2.4,-0.6,44.0)]
prediksi=knn.predict(data)
print("Apakah akan terjadi CB (1=Ya,0=Tidak)?:",prediksi)
```

```
Apakah akan terjadi CB (1=Ya,0=Tidak)?: [0]
/usr/local/lib/python3.12/dist-packages/sklearn/utils/validation.py:2739: UserWarning: X does not have valid feature names, but
  warnings.warn(
```

```
# import confusion_matrix model
from sklearn.metrics import confusion_matrix
confusion_matrix(y_test, y_pred_knns)
```

```
array([[205,  31],
       [ 55,  59]])
```

```
import seaborn as sns
import matplotlib.pyplot as plt
f, ax = plt.subplots(figsize=(7,5))
sns.heatmap(confusion_matrix(y_test, y_pred_knns), annot=True, fmt=".0f",  ax=ax)
plt.xlabel('Predicted Label')
plt.ylabel('True Label')
plt.show()
```

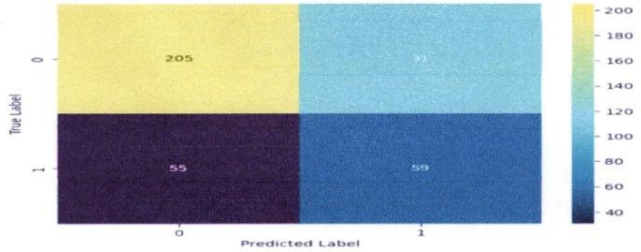


```
# Menghitung nilai akurasi dari klasifikasi KNN
from sklearn.metrics import classification_report
print(classification_report(y_test,y_pred_knns))
from sklearn.metrics import precision_score,recall_score,f1_score,accuracy_score
print('accurasy_score: {}'.format(accuracy_score(y_test, y_pred_knns)))
print('Precision: {}'.format(precision_score(y_test, y_pred_knns)))
print('Recall: {}'.format(recall_score(y_test, y_pred_knns)))
print('F1-Score: {}'.format(f1_score(y_test, y_pred_knns)))
```

```
              precision    recall  f1-score   support

           0       0.79      0.87      0.83       236
           1       0.66      0.52      0.58       114

    accuracy                           0.75       350
```

```
   macro avg       0.72      0.69      0.70       350
weighted avg       0.75      0.75      0.75       350

accurasy_score: 0.7542857142857143
Precision: 0.6555555555555556
Recall: 0.5175438596491229
F1-Score: 0.5784313725490197
```

```
#menentukan nilai k terbaik
import matplotlib.pyplot as plt

error = []

# Calculating error for K values between 1 and 80
for i in range(1, 80):
    knn = KNeighborsClassifier(n_neighbors=i)
    knn.fit(x_train, y_train)
    pred_i = knn.predict(x_test)
    error.append(np.mean(pred_i != y_test))
plt.figure(figsize=(12, 6))
plt.plot(range(1, 80), error, color='black', linestyle='dashed', marker='o',
         markerfacecolor='red', markersize=10)
plt.title('Error Rate Nilai K')
plt.xlabel('Nilai K')
plt.ylabel('Error rata-rata')
```

```
Text(0, 0.5, 'Error rata-rata')
```

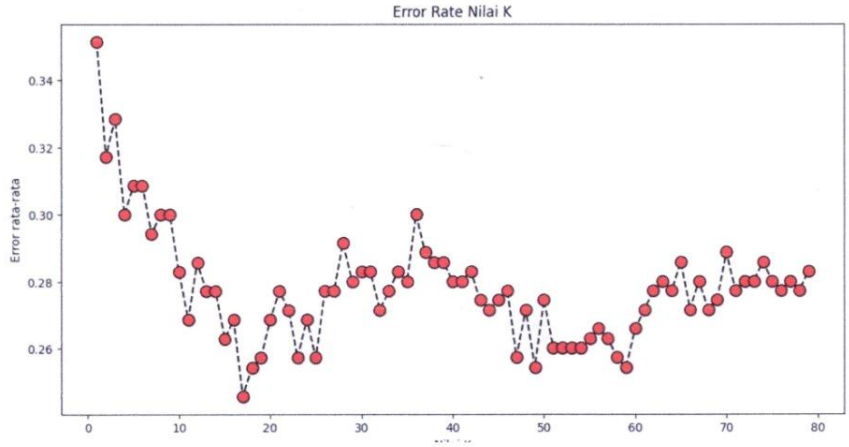

TANGGAL 01 Februari 2025

-12

1	2			3			4			5	6						7			8		9	10
Jam	Angin-Visibility-Kondisi Cuaca			Tekanan Udara			Suhu Udara		Suhu Extrim	Evaporasi	Perawan						Lapisan Awan			Penjelasan Matahari		TANAH	Observer
Waktu Data Hujat	Pengamat Data Angin /v	Pengamat Data Cuaca (ii)		Derajat Panas (°C/°F/°K)	Koreksi QFF (°C/°F/°K)	Koreksi QFE (°C/°F/°K)	Bola Kering (°C)	Titik Embun (°C)	Suhu Minimum (°C)	Pengamat Data Hujan (IR)	Awan Rendah (Jenis)	Arah Sudut Elevasi (derajat)	Awan Menengah (Banyaknya/Jenis)	Arah (Derajat) Tingginya (m)	Bagian langit yang tertutup (Okta)	Jenis	Tingginya (m)	Banyaknya (Okta)	Personal Data Alat Pengangan /E	Pengangan Total 24 jam yang lalu (mm)	Kondisi Tanah	Pural
	Arah Angin (derajat)	Kondisi Cuaca Waktu Pengamatan	Pengamatan Menentukan (Jam)	Tekanan Udara dibaca (mb)	mb QFF inch	mb QFE inch				Hujan Sejak Tekanan Terakhir									Rad Total 24 jam yang lalu (joule/cm²)				
		Kondisi Cuaca Waktu Yang Lalu 1					Bola Basah (°C)	Lembab Nisbi (%)	Suhu Minimum (°C)	Hujan Sejak 6 Jam Yang Lalu (mm)	Tinggi Dasar (m)	Banyaknya (Okta)	Awan Tinggi (Banyaknya/Jenis)	Arah (Derajat) Tingginya (m)		Jenis	Tingginya (m)	Banyaknya (Okta)	Penyinaran Matahari (Jam)		Cuaca	Nama Tanang
	Kecepatan Angin (Knot)	Kondisi Cuaca Waktu Yang Lalu 2		Pembaca Tekanan Udara (0 jam) (mb)		(24 jam) (mb)				Hujan Sejak 24 Jam Yang Lalu (mm)	Tinggi Puncak (m)												
MMMM	YYGGiW	IIii	iRiXhVV	Nddff	1SnTTT	2SnTdTdTd	3PoPoPoPo	4PPPP	5appp	6RRRtr	7wwW1W2	8NhCLCmCh	333	(0S/1SnTxTxTxTn)	(5EEEE)	(5333S)	(55SSS)	(5FLF4F24F24)	(560Dr=Dr)	(57CDaac)	(58/59P24P24P24)	(6RRRR)	(3Ejj/Hxfxfx)	(90CHxfxfx)	
07.00	4	10	2				26.5	23.9		3	2		0.STNR	7	0.STNR	8	Cu 8	600	2	0	4.7	0	H	
	290		02.Cld unch		1006.9	1006.2					Cu 2		0	AcAs 7	3000									
			2.Cloudy +		29.73	29.71	24.6	86	24.1		600		2	2	0.STNR		As 4	3000	7				HAKIM	
	2		2.Cloudy +		1.2	-0.5				0.9				Ci 1	9000					02.36				
AAXX	01004	96805	32560	82902	10265	20239	30062	40069	50012	69994	82271	333	20241	50470	55026	56000	57800	59005	82820	87460					
08.00	4	10	2				28.2	24.1		4	2		0.STNR	7	0.STNR	8	Cu 8	600	2			0	H	
	310		02.Cld unch		1007.6	1006.9					Cu 2		0	AcAs 7	3000									
			2.Cloudy +		29.75	29.73	25.2	78			600		2	2	0.STNR		As 4	3000	7				HAKIM	
	3		2.Cloudy +											Ci 1	9000									
AAXX	01014	96805	42560	83103	10282	20241	30069	40076		82271	333	56000	57800	82820	87460									
09.00	4	10	2				29.4	24.1		4	1		0.STNR	8	0.STNR	8	Sc 6	600	1			0	H	
	310		02.Cld unch		1007.7	1007					Sc 4			As 2	3000									
			2.Cloudy +		29.76	29.74	25.5	73			600		1	/	0		As 4	3000	8				HAKIM	
	3		2.Cloudy +											/										
AAXX	01024	96805	42560	83103	10294	20241	30070	40077		8142/	333	56000		81620	88460									
10.00	4	10	2				30.2	23.8		3	1		0.STNR	6	0.STNR	6	Sc 6	600	1			0	H	
	340		01.Cld decr		1006.8	1006.1					Sc 4			As 2	3000									
			2.Cloudy +		29.73	29.71	25.5	69			600		1	1	0.STNR		As 4	3000	6				HAKIM	
	3		2.Cloudy +		-0.1									Ci 1	9000									
AAXX	01034	96805	32560	63403	10302	20238	30061	40068	58001	81421	333	56000		81620	86460									
11.00	4	10	2				32.0	23.8		4	1		0.STNR	6	0.STNR	8	Cu 8	600	1			0	H	
	360		03.Cld incr		1006	1005.3					Cu 1			AcAs 7	3000									
			2.Cloudy +		29.71	29.69	26.0	62			600		1	2	0.STNR		As 4	3000	6				HAKIM	
	5		2.Cloudy +											Ci 1	9000									
AAXX	01044	96805	42560	83605	10320	20238	30053	40060		81171	333	56000		81820	86460									
12.00	4	10	2				31.5	23.9		4	1		0.STNR	8	0.STNR	8	Cu 8	600	1			0	H	
	350		02.Cld unch		1005.2	1004.5					Cu 1			As 2	3000									
			2.Cloudy +		29.68	29.66	25.9	64			600		1	/	0		As 4	3000	8				HAKIM	
	6		2.Cloudy +											/										
AAXX	01054	96805	42560	83506	10315	20239	30045	40052		8112/	333	56000		81620	88460									

SPED CCCC YYGggi dddffffdwdwKT dndndnVdxdxdx VVVV 3v VxVxVxVx 3v RDrDrDrDrDrDrDrDr ww TT/TdTd 3PAPAPA RERMK=

TANGGAL 01 Februari 2025

1	2			3			4			5	6					7			8		9	10
Jam	Angin-Visibility-Keadaan Cuaca			Tekanan Udara			Suhu Udara		Suhu Extrim	Endapan	Penyinaran					Lapisan Awan			Penghisaran Matahari		TANAH	Observer
Waktu Setempat	Pengamat Data Angin /kr	Jarak dari Stasiun (km)	Pengamat Data Cuaca (01)	Derajat Panas (°C/°F/°K)	Koreksi OFF (°C/°F/°K)	Koreksi OFE (°C/°F/°K)	Bola Kering (°C)	Titik Embun (°C)	Suhu Maximum (°C)	Pengamat Data Hujan (01)	Arah Rendah (Jenis)	Arah Sudut Elevasi (derajat)	Arah Menengah (Banyaknya/Jenis)	Arah (Derajat) Tingginya (m)	Bagian langit yang tertutup (Okta)	Jenis	Tingginya (m)	Banyaknya (Okta)	Pancar Data Alat Pengapian (E	Pengapian Total 24 jam yang lalu (mm)	Keadaan Tanah	Paraf
	Arah Angin (derajat)		Keadaan Cuaca Waktu Pengamatan	Tekanan Udara dibawa (mb)	mb OFF inch	mb OFE inch				Hujan Sejak Takaran Terakhir (mm)									Rad Total 24 jam yang lalu (jouls/cm²)			
	Kecepatan Angin (Knot)		Keadaan Cuaca Waktu Yang Lalu 1	Perubahan Tekanan Udara (3 jam) (mb)		(24 jam) (mb)	Bola Basah (°C)	Lembab Nisbi (%)	Suhu Minimum (°C)	Hujan Sejak 6 Jam Yang Lalu (mm)	Tinggi Dasar (m)	Banyaknya (Okta)	Arah Tinggi (Banyaknya/Jenis)	Arah (Derajat) Tingginya (m)		Jenis	Tingginya (m)	Banyaknya (Okta)	Penghisaran Matahari (Jam)		Catatan	Nama Terang
			Keadaan Cuaca Waktu Yang Lalu 2							Hujan Sejak 24 Jam Yang Lalu (mm)	Tinggi Puncak (m)											

4KMMM YYGGW iii iRXHVV Nddff 1SnTTT 2SnTdTdTd 3PoPoPoPo 4PPPP 5appp 6RRRtR 7wwW'W'2 8NhCLCmCh 333 (15/25nTxTnTn) (55EEE) (55333) (55508) (5F24F24F24) (5E00nDk) (5700aac) (53/55P24P24P24) (5RRRtR) (3NsCHsHs) (3DCNsHs)

13.00	4	10	2				31.0	23.8		3	1	0.STNR	8	0.STNR	8	Cu 8	600	1			0	𝒥
	350		02.Cld unch		1004.5	1003.8					Cu 1		As 2	3000								
			2.Cloudy +		29.66	29.64	25.7	65			600	1	/	9		As 4	3000	8				HAKIM
	5		2.Cloudy +		-2.3								/									
4AXX	01064	96805	32560	83505	10310	20238	30038	40045	57023	8112/	333	56009	81820	86460								
14.00	4	10	2				31.0	24.1		4	1	0.STNR	8	0.STNR	8	Cu 8	600	1			0	𝒥
	340		02.Cld unch		1004	1003.3					Cu 1		As 2	3000								
			2.Cloudy +		29.65	29.63	25.9	67			600	1	/	9		As 4	3000	8				HAKIM
	6		2.Cloudy +										/									
4AXX	01074	96805	42560	83406	10310	20241	30033	40040		8112/	333	56009	81820	86460								
15.00	4	10	2				30.8	24.0		4	1	0.STNR	8	0.STNR	8	Cu 8	600	1			0	𝒮𝒯
	340		02.Cld unch		1003.3	1002.6					Cu 1		As 2	3000								
			2.Cloudy +		29.63	29.61	25.8	67			600	1	2	0.STNR		As 4	3000	6				DESI
	4		2.Cloudy +										Ci 1	3000								
4AXX	01084	96805	42560	83404	10308	20240	30026	40033		81121	333	56000	81820	86460								
16.00	4	10	2				30.8	23.8		3	3	6.W	4	0.STNR	7	Cu 8	600	3			0	𝒮𝒯
	330		01.Cld decr		1003.6	1002.8					CuSc 8	2. ±30°	AcAs 7	3000								
			2.Cloudy +		29.64	29.61	25.7	66			600	3	1	0.STNR		As 4	3000	4				DESI
	9		2.Cloudy +		-0.9						2400		Ci 1	9000								
4AXX	01094	96805	32560	73309	10308	20238	30028	40036	55009	83871	333	56000	57862	83820	84460	80858						
17.00	4	10	2				30.2	24.1		4	3	0.STNR	4	0.STNR	7	Cu 8	600	3			0	𝒮𝒯
	340		02.Cld unch		1003.9	1003.2					CuSc 8	2. ±30°	AcAs 7	3000								
			2.Cloudy +		29.65	29.62	25.7	70			600	3	2	0.STNR		As 4	3000	4				DESI
	6		2.Cloudy +								2400		Ci 1	9000								
4AXX	01104	96805	42560	73406	10302	20241	30032	40039		83871	333	56000	57862	83820	84460	80858						
18.00	4	10	2				29.3	23.7		4	1	0.STNR	3	0.STNR	6	Cu 8	600	2			0	𝒮𝒯
	340		01.Cld decr		1004.7	1003.9					Cu 1		AcAs 7	3000								
			2.Cloudy +		29.67	29.65	25.2	72			600	1	2	0.STNR		As 4	3000	3				DESI
	7		2.Cloudy +										Ci 1	9000								
4AXX	01114	96805	42560	83407	10293	20237	30039	40047		81171	333	56000	82820	83460								

SPECI CCCC YYGggZ dddffffGfmfmKT dndndnVdxdxdx VVVVDv VxVxVxVxDv RDxDxVxVxVxi vvv TT/TdTd QPhPhPh RERMKx

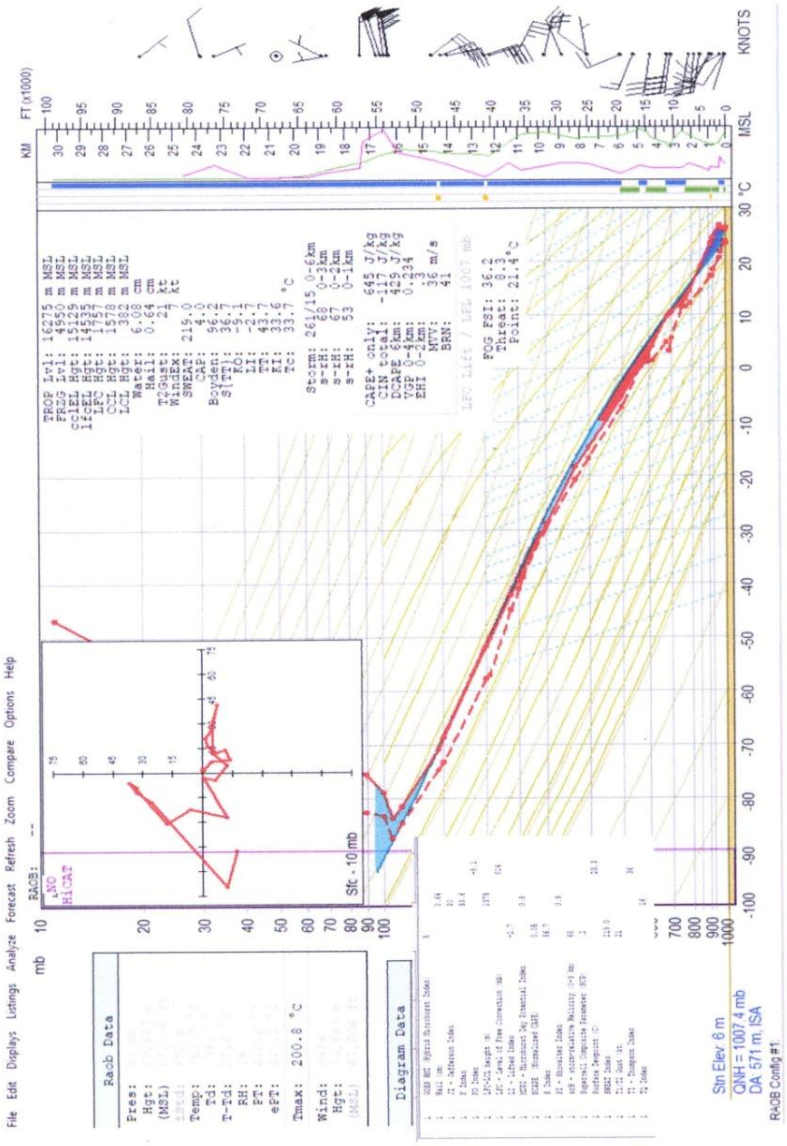
File Edit Displays Listings Analyze Forecast Refresh Zoom Compare Options Help
RAOB:
Raob Data
Diagram Data
Stn Elev 6 m
QNH = 1007.4 mb
DA 571 m, ISA
RAOB Config #1
KNOTS
MSL
FT (x1000)
KM