

BAB 2

TINJAUAN PUSTAKA

2.1 Landasar Teori

2.1.1 Konsep Pertahanan Negara

Konsep pertahanan negara, sebagaimana tercantum dalam Kebijakan Pertahanan Negara yang dikeluarkan oleh Kementerian Pertahanan Republik Indonesia, menegaskan bahwa penyelenggaraan Pertahanan Negara bertujuan untuk menjaga kedaulatan negara, integritas wilayah Negara Kesatuan Republik Indonesia, dan keselamatan seluruh rakyat dari potensi ancaman dan gangguan yang dapat mengancam integritas bangsa dan negara dalam berbagai bentuk ancaman.

Penyelenggaraan pertahanan negara yang bersifat semesta (holistik) didasarkan pada kesadaran akan hak dan tanggung jawab warga negara, serta keyakinan terhadap potensi internal negara. Dalam menghadapi ancaman militer, sistem pertahanan negara menetapkan Tentara Nasional Indonesia (TNI) sebagai komponen utama, didukung oleh komponen cadangan dan komponen pendukung. Sementara itu, dalam menghadapi ancaman nonmiliter, lembaga pemerintah di luar sektor pertahanan menjadi unsur utama, sesuai dengan karakteristik dan jenis ancaman yang dihadapi, dengan dukungan dari elemen-elemen lain dalam kekuatan nasional.

Sistem pertahanan negara dalam menghadapi ancaman militer disebut pertahanan militer, dan untuk menghadapi ancaman nonmiliter disebut pertahanan nirmiliter. Implementasi dari sistem pertahanan negara yang bersifat semesta melibatkan seluruh warga negara, wilayah, dan sumber daya nasional lainnya, serta dipersiapkan secara dini oleh pemerintah dan diselenggarakan secara total, terpadu, terarah, dan berlanjut untuk menegakkan kedaulatan negara, keutuhan wilayah, dan keselamatan segenap bangsa dari segala ancaman (Biro Peraturan dan Perundangan Kemhan RI, 2022).

2.1.2 Infrastruktur Informasi Vital dan Meteorologi

Infrastruktur Informasi Vital (IIV) merupakan suatu sistem elektronik yang beroperasi di sektor-sektor strategis yang menggunakan teknologi informasi. Berdasarkan ketentuan yang diatur dalam Peraturan Presiden No. 82 tahun 2022, terdapat delapan sektor yang termasuk dalam kategori strategis, yaitu: Administrasi Pemerintahan, Energi dan Sumber Daya Mineral, Transportasi, Keuangan, Kesehatan, Teknologi Informasi dan Komunikasi, Pangan, serta Pertahanan.

Kerusakan dan gangguan yang terjadi pada sistem ini dapat berdampak serius terhadap kepentingan umum, pelayanan publik, pertahanan, keamanan, dan perekonomian nasional. Peraturan Presiden ini diterbitkan untuk memberikan landasan hukum yang jelas dan panduan dalam melindungi layanan yang bersifat kritis untuk kelangsungan hidup masyarakat dan negara secara keseluruhan.

Perpres tersebut juga menekankan perlunya pemetaan informasi teknis terkait risiko di setiap sektor strategis, dengan tujuan untuk mengevaluasi kapasitas dan kapabilitas masing-masing sektor dalam upaya melindungi Infrastruktur Informasi Vital. Pemetaan ini juga bermanfaat untuk mengidentifikasi potensi insiden siber yang mungkin terjadi di setiap sektor IIV, dengan harapan dapat meminimalkan kemungkinan meluasnya dampak insiden tersebut.

Dalam konteks pemangku kepentingan, Peraturan Presiden mengenai IIV mendorong para stakeholder di sektor IIV untuk terlibat aktif dalam peningkatan kapasitas dan kapabilitas melalui kolaborasi, termasuk berbagi informasi terkait keamanan siber dan memberikan dukungan dalam penanganan insiden siber (Biro Hukum dan Komunikasi Publik BSSN, 2023).

2.1.2.1 Cuaca

Cuaca dapat diartikan sebagai kondisi atmosfer yang terjadi pada waktu dan tempat tertentu. Periode waktunya berlangsung selama

beberapa jam atau hari. Parameter atau unsur-unsur cuaca terdiri dari : temperatur, curah hujan, kelembapan udara, tekanan udara dan angin permukaan. Kondisi cuaca pada suatu tempat dan waktu dapat direfleksikan oleh nilai-nilai dari unsur cuaca tersebut (Perka BMKG Nomor 9 Tahun 2010, n.d.).

Pengertian ini sejalan dengan apa yang diungkapkan oleh Gibbs dalam Buletin WMO no.4 Vol.36 penerbitan Oktober 1987 yang mengatakan bahwa cuaca adalah keadaan atmosfer di suatu tempat atau wilayah selama kurun waktu yang pendek, yang dinyatakan dengan nilai berbagai parameter antara lain suhu, tekanan udara, angin, kelembapan, dan berbagai fenomena lainnya seperti hujan, kabut, badai guntur. Fenomena cuaca terjadi dilapisan atmosfer bagian troposfer. Lapisan ini adalah lapisan yang paling dekat dengan permukaan bumi, dengan ketinggian antara 0 sampai 12 km (Soerjadi Wirjohamidjojo, 2006).

2.1.2.2 Pembentukan Awan dan Hujan


Ada tiga proses utama dalam pembentukan awan dan hujan, yaitu proses konvektif, orografik, dan frontal. Ketiganya berpengaruh terhadap karakteristik hujan yang terbentuk (Soerjadi Wirjohamidjojo, 2006).

Pada proses konvektif, akibat dari pemanasan radiasi matahari, udara permukaan akan memuai dan bergerak naik lalu mengembun. Gerakan vertikal udara lembap yang mengalami pendinginan dengan cepat akan menghasilkan awan dan hujan yang deras. Pertumbuhan awan ini cenderung vertikal. Hujan yang terjadi biasanya lebat namun tidak lama.

Adapun pada proses orografik, bila gerakan udara melalui pegunungan atau bukit yang tinggi, maka udara akan dipaksa naik. Setelah terjadi kondensasi, tumbuhlah awan dan hujan pada lereng dibagian atas angin. Sebaliknya pada lereng dibagian bawah angin, udara yang turun akan mengalami pemanasan dengan sifat kering, dan daerah ini lazim disebut sebagai daerah bayangan hujan.


Untuk proses frontal, jika dua massa udara yang konvergen horizontal mempunyai suhu dan massa jenis yang berbeda bertemu, maka massa udara yang lebih panas akan dipaksa naik diatas massa udara dingin. Pada bidang batas antara kedua massa udara ini akan terjadi kondensasi dan akhirnya akan tumbuh awan dan hujan. Hujan yang terjadi biasanya tidak lebat, namun berlangsung lama.

Berikut ilustrasi dari ketiga proses tersebut.




Gambar 2.1 Proses Pembentukan Awan/Hujan Konvektif

Sumber : www.masnutnut.com,2023



Gambar 2.2 Proses Pembentukan Awan/Hujan Orografik

Sumber : portalgeograf.com, 2022




Gambar 2.3 Proses Pembentukan Awan/Hujan Frontal

Sumber : portalgeograf.com, 2022

2.1.2.3 Awan Cumulonimbus

Awan Cumulonimbus merupakan jenis awan konvektif yang berbentuk gundukan besar dengan bagian bawahnya lebih kecil dibandingkan dengan bagian atasnya. Dasar awan berwarna abu-abu sampai kehitam-hitaman. Pada bagian puncak awan ada yang berserabut dan nampak seperti jambul, ada pula yang berbentuk seperti landasan tempa. Tinggi dasar awan sampai ke puncak awan dapat mencapai 20 km, dari awan Cumulonimbus dapat terjadi *lightning* dan *thunderstorm*. Cumulonimbus dapat menimbulkan hujan yang deras dan kadang-kadang disertai dengan angin kencang, tetapi dalam waktu yang singkat, kurang lebih sampai sekitar 30 menit (Soerjadi Wirjohamidjojo, 2006).

Berikut ini visualisasi dari bentuk awan Cumulonimbus.



Gambar 2.4 Bentuk Awan Cumulonimbus

Sumber : enjiner.com/jenis-jenis-awan/amp/

2.1.2.4 Hujan

Dalam meteorologi, hujan dikelompokkan kedalam fenomena yang disebut sebagai presipitasi. Presipitasi merupakan butiran air atau kristal es yang keluar dari awan. Bila butiran ini dapat mencapai bumi maka disebut sebagai hujan, apabila setelah keluar dari dasar awan tetapi tidak sampai ke bumi karena habis menguap di udara disebut sebagai virga. Ukuran butir air yang dapat keluar dari awan dan mencapai bumi sekurang-kurangnya mempunyai diameter 200 mikrometer, jika kurang dari 200 mikrometer, maka butir-butir tersebut sudah habis menguap sebelum mencapai bumi (Soerjadi Wirjohamidjojo, 2006).

2.1.2.5 *Thunderstorm*

Terminologi *thunderstorm* dalam padanan Bahasa Indonesianya disebut sebagai badai guntur. Dalam buku Meteorologi Praktik yang

dikeluarkan oleh BMKG dinyatakan bahwa badai guntur adalah fenomena atmosfer yang berkaitan dengan awan, angin, hujan, kilat, petir, dan guntur yang timbul bersama-sama dalam awan jenis cumulonimbus. Di Kawasan luar tropis badai guntur sering terjadi pada akhir musim dingin sampai awal musim panas, sedangkan di Indonesia dapat terjadi di sembarang waktu, tetapi lebih sering terjadi pada awal musim hujan dan menjelang akhir musim hujan. Badai guntur dapat terbentuk apabila udara dalam keadaan tidak stabil dan kelembapan tinggi yang terdorong karena adanya suatu gaya sehingga mudah bergerak ke atas. (Soerjadi Wirjohamidjojo, 2006)

2.1.2.6 Aerodrome Forecast

Aerodrome Forecast yang kemudian disingkat dengan TAF adalah nama sandi untuk prakiraan cuaca di bandar udara, yang dibuat oleh Stasiun Meteorologi Penerbangan tertentu pada setiap waktu secara berkala atau atas dasar permintaan. Informasi prakiraan cuaca yang termuat dalam *Aerodrome Forecast* meliputi prakiraan dari beberapa unsur cuaca tertentu, yaitu : arah dan kecepatan angin, visibility, kondisi cuaca, jumlah awan dan tinggi dasar awannya. Adapun yang dimaksud dengan *aerodrome* adalah kawasan di daratan dan/atau perairan dengan batas-batas tertentu yang hanya digunakan sebagai tempat pesawat udara mendarat dan lepas landas. (CASR 174 _ PM No.95 TAHUN 2018,n.d.)

Format dari *Aerodrome Forecast* disajikan dalam bahasa sandi mengikuti ketentuan yang telah ditetapkan oleh ICAO dan WMO, sehingga bersifat baku dan universal bagi setiap entitas yang terlibat dalam operasional penerbangan baik domestik maupun internasional.

Berikut format sandi TAF selengkapnya dikutip dari SOP Pembuatan *Aerodrome Forecast* di Stasiun Meteorologi Soekarno-Hatta, Tangerang, Banten (Stasiun Meteorologi Kelas I Soekarno-Hatta, n.d.).

Adapun penjelasannya adalah sebagai berikut :

Data mentah: TAF WIII 092300Z 1000/1106 VRB02KT 5000 HZ FEW020

Jenis prakiraan: prakiraan standar

Waktu diterbitkan: 09 September 2023 23:00 UTC

Waktu prakiraan: 10 September 2023 00:00 - 11 September 2023 06:00 UTC

Angin: variabel, 2.0 knot (1.0 m/s)

Jarak pandang: 5.0 km

Cuaca: HZ (Udara kabur)

Awan: few (1-2 oktas) di ketinggian 2000 kaki

Data mentah: BECMG 1001/1003 02010KT 9000 NSW

Jenis perubahan: BECMG (proses perubahan)

Periode: 10 September 2023 01:00 - 10 September 2023 03:00 UTC

Angin: dari Utara (20°), 10.0 knot (5.1 m/s)

Jarak pandang: 9.0 km

Cuaca: NSW (tidak ada cuaca signifikan)

Data mentah: TEMPO 1008/1011 5000 SHRA BKN014

Jenis perubahan: TEMPO (temporer)

Periode: 10 September 2023 08:00 - 10 September 2023 11:00 UTC

Jarak pandang: 5.0 km

Cuaca: SHRA (Hujan tiba-tiba)

Awan: broken (5-7 oktas) di ketinggian 1400 kaki

Data mentah: BECMG 1015/1017 21003KT 5000 HZ=

Jenis perubahan: BECMG (proses perubahan)

Periode: 10 September 2023 15:00 - 10 September 2023 17:00 UTC

Angin: dari Barat Daya (210°), 3.0 knot (1.5 m/s)

Jarak pandang: 5.0 km

Cuaca: HZ (Udara kabur)

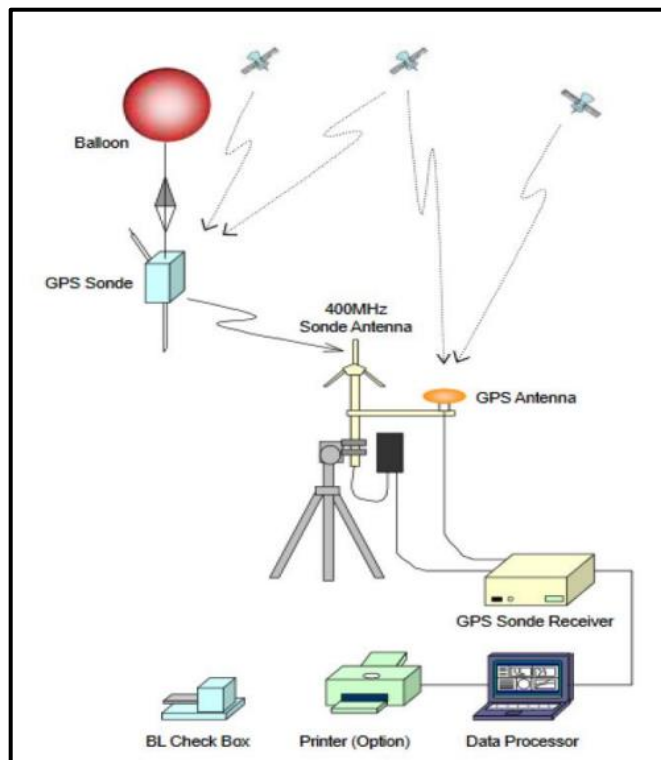
Sumber : aviation.bmkg.go.id

2.1.2.7 Radiosonde

Menurut *Glossary of Meteorology* yang dipublish oleh AMS, Radiosonde adalah sebuah instrumen meteorologi yang diterbangkan dengan balon udara untuk mengukur suhu, kelembapan, dan tekanan, serta mengirimkan data kembali ke sistem penerima di darat. Instrumen Radiosonde yang digunakan saat ini dilengkapi sistem navigasi otomatis berupa GPS untuk mendapatkan data kecepatan dan arah angin serta ketinggian geopotensialnya. Sensor suhu Radiosonde adalah termistor, sensor kelembapan adalah hygistor, dan sensor tekanan adalah kapsul aneroid. Data yang dikumpulkan dari sistem pengamatan Radiosonde menghasilkan profil suhu, kelembapan, dan kecepatan serta arah angin


sebagai fungsi dari ketinggian, tekanan, dan lokasi (American Meteorological Society, 2021).

Radiosonde bekerja dengan mengukur berbagai parameter atmosfer selama naik ke atmosfer atas (mencapai ketinggian sekitar 18 – 30km). Berikut adalah tahapan dalam observasi Radiosonde : diawali dengan peluncuran, Radiosonde diluncurkan ke udara bersama dengan balon cuaca. Kemudian, saat terbang ke atas Radiosonde akan mengukur kondisi atmosfer saat naik. Selama penerbangan, Radiosonde akan terus mengukur temperatur, kelembaban udara, tekanan udara, dan arah serta kecepatan angin. Data ini dikirim kembali ke stasiun darat melalui transmisi radio. Tahapan berikutnya adalah pengambilan data, stasiun di darat akan menerima data dari Radiosonde dan menganalisisnya untuk membuat profil vertikal dari parameter-parameter cuaca di lapisan atas atmosfer.



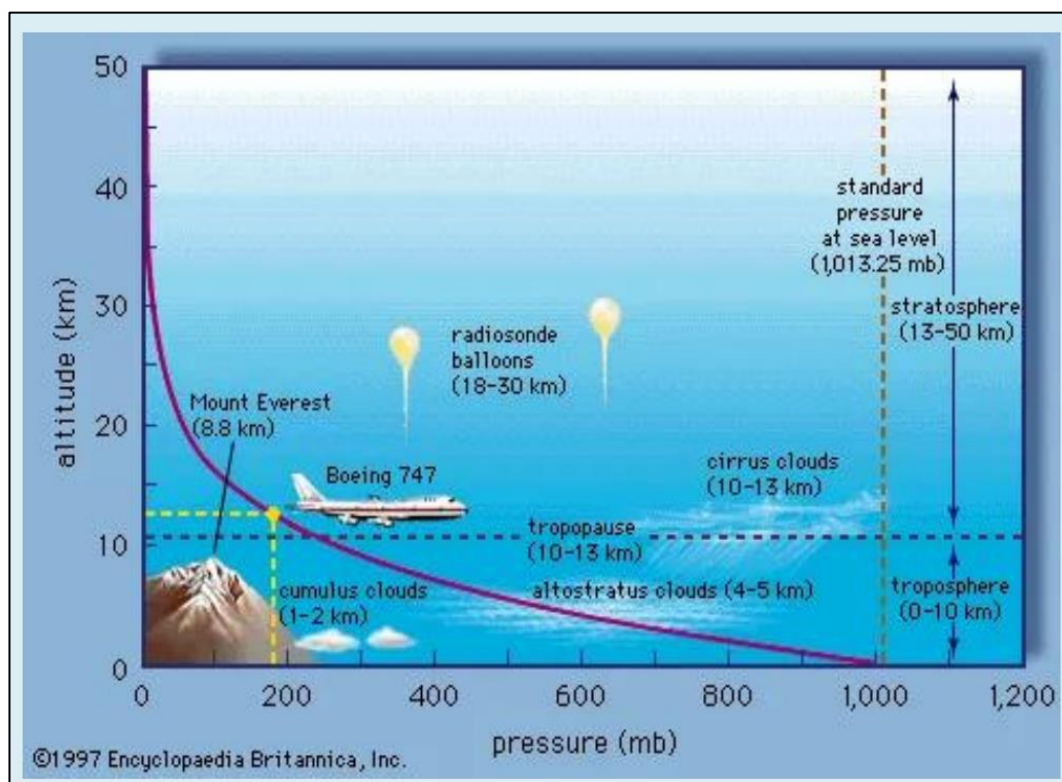
Gambar 2.6 Sistem Pengamatan Radiosonde

Sumber : Farhan Arkan.2017 Journal of Electrical Technology



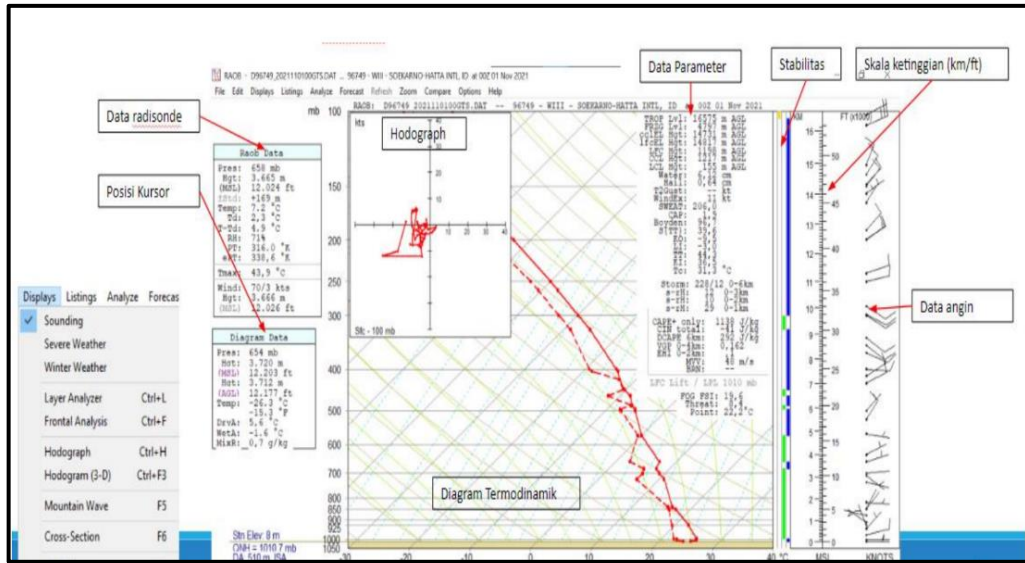
Gambar 2.7 Sensor dan Transmitter Radiosonde

Sumber : Pusmetbang BMKG



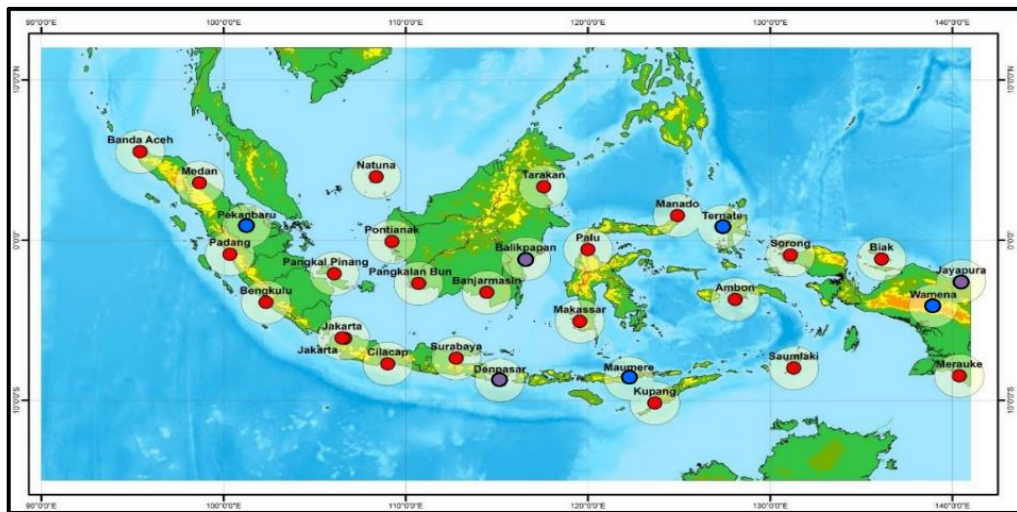
Gambar 2.8 Level Ketinggian Radiosonde

Sumber : Pusmetbang BMKG



Gambar 2.9 Tampilan Hasil Pengolahan Data Radiosonde dengan RAOB

Sumber : Pusmetbang BMKG



Gambar 2.10 Jaringan Pengamatan Radiosonde di Indonesia

Sumber : Pusmetbang BMKG

2.1.2.8 Teknik Analisis Data Radiosonde

Dalam observasi Radiosonde balon yang di *release* tidak akan bergerak tegak lurus, makin keatas dapat memungkinkan terjadi balon berada jauh dari arah tegak lurus sehingga daerah pengamatan akan berupa kerucut terbalik. Dengan demikian radiusnya menjadi lebih melebar.

Berdasarkan hal inilah maka observasi Radiosonde datanya masih relevan untuk radius sekitar 250 km dari titik pengamatan (Soerjadi Wirjohamidjojo & Yunus Swarinoto, 2013).

Hujan dan *thunderstorm* merupakan fenomena cuaca yang dihasilkan dari proses konvektif dalam kondisi atmosfer yang labil. Untuk menandai sifat labilitas atmosfer yang berkaitan dengan fenomena tertentu secara kuantitatif digunakan nilai indeks. Umumnya nilai indeks dibentuk dari nilai temperatur dan kelembapan udara hasil observasi Radiosonde. Berbagai indeks yang sering digunakan antara lain : *Convective Available Potential Energy* (CAPE), *Convective Inhibition* (CIN), *Showalter Index* (SI), *Lifted Index* (LI), *SWEAT Index*, *K Index* (KI), dan *Total Totals Index* (TT) (Mayangwulan et al., n.d.).

Dengan menggunakan aplikasi RAOB nilai indeks-indeks tersebut dapat secara langsung diperoleh setelah pengamatan berakhir. Berikut penjelasan lebih lanjut mengenai indeks labilitas atmosfer.

2.1.2.9 CAPE

CAPE merepresentasikan *buoyancy* positif dari integrasi vertikal parcel udara yang naik secara adiabatik. Nilai CAPE menunjukkan potensi tingkat konvektif yang terjadi.

Tabel 2.1 Klasifikasi nilai CAPE

Nilai CAPE (J/kg)	Keterangan
< 1000	Konvektif Lemah
1000 - 2500	Konvektif Sedang
>2500	Konvektif Kuat, Berpeluang Tornado

Sumber : Pusmetbang, BMKG

2.1.2.10 Cross Totals Index

Cross Totals Index merupakan indeks labilitas atmosfer yang didapat dari perhitungan perbedaan suhu titik embun di lapisan 850 mb

(sekitar 5.000 ft) dan suhu udara di lapisan 500 mb (sekitar 18.000 ft) (noaa, 2023).. Rumus matematisnya dinyatakan sebagai berikut :

$$CT = T_{d(850)} - T_{500} \quad (2.1)$$

2.1.2.11 *Vertical Totals Index*

Vertical Totals merupakan indeks labilitas atmosfer yang didapat dari perhitungan antara suhu udara di lapisan 850 mb (sekitar 5.000 ft) dengan suhu udara dilapisan 500 mb (sekitar 18.000 ft) (noaa, 2023).. Rumus matematisnya dinyatakan sebagai berikut :

$$VT = T_{850} - T_{500} \quad (2.2)$$

2.1.2.12 *Showalter Index (SI)*

SI mengindikasikan labilitas udara dalam troposfer bagian tengah, yaitu antara 850 mb – 500 mb. SI positif menunjukkan udara sampai troposfer tengah dalam keadaan stabil, sedangkan SI negatif menunjukkan keadaan atmosfer yang labil.

Tabel 2.2 Klasifikasi Nilai SI

Nilai SI	Prakiraan Terjadinya Thunderstorm
>3	Tidak ada Thunderstorm
0 – 3	Kemungkinan ada Thunderstorm
0 – (-3)	Ada Thunderstorm
-3 – (-6)	Thunderstorm hebat
< (-6)	Tornado

Sumber : Pusmetbang, BMKG

2.1.2.13 *Lifted Index (LI)*

Nilai LI merupakan perbedaan antara suhu parcel dan suhu lingkungan pada lapisan 500 mb. LI adalah variasi dari *Showalter indeks*, yang biasa digunakan untuk mendeteksi labilitas konvektif frontal (cuaca konvektif frontal). Setiap nilai SI dan LI memiliki nilai ambang batas yang dapat digunakan untuk meramalkan kemungkinan terjadinya badai petir.

Tabel 2.3 Klasifikasi Nilai LI

Nilai LI	Prakiraan Kondisi Cuaca
>10	Atmosfer cenderung clear
>2	No significant activity
0 – 2	Showers probable, isolated Thunderstorm
-2 – 0	Thunderstorm probable
-4 – (-2)	Severe Thunderstorm possible
<-4	Severe Thunderstorm possible, tornadoes possible

Sumber : Pusmetbang, BMKG

2.1.2.14 K Index (KI)

K indeks adalah nilai yang digunakan sebagai ukuran untuk menaksir potensi timbulnya awan badai guntur berdasarkan laju susut suhu vertikal dan kelembapan udara pada lapisan bawah. Nilai K indeks yang tinggi menunjukkan ketidakstabilan kuat antara lapisan 850 mb dan 500 mb. K Indeks lebih cocok untuk aktivitas non konvektif.

Tabel 2.4 Klasifikasi Nilai KI

K Value	Correlated Weather
<15	No significant activity
15 - 25	Possible steady precipitation; isolated thunderstorms
26 - 30	Probable steady precipitation; widely scattered thunderstorms
31 - 35	Steady precipitation; scattered thunderstorms > 35 steady precipitation; numerous thunderstorms

Sumber : Pusmetbang, BMKG

2.1.3 Machine Learning

Machine Learning merupakan *subfield* dari *Artificial Intelligence*. Definisi mengenai *machine learning* telah banyak dikemukakan oleh para ahli atau peneliti. Satu dari definisi mengenai *machine learning* disampaikan oleh Dios K, dalam bukunya yang berjudul *Pengenalan Machine Learning*, Dios menyebutkan bahwa yang dimaksud dengan *Machine Learning* adalah ilmu yang mempelajari tentang algoritma komputer yang bisa mengenali pola-pola didalam data, dengan tujuan untuk mengubah

beragam macam data menjadi suatu tindakan nyata dengan sesedikit mungkin campur tangan manusia (Dios Kurniawan, 2023).

Adapun Bedi Permana, mengutip definisi *machine learning* dari Tom Mitchell yang diklaim sebagai definisi yang banyak digunakan di lingkungan akademik. Definisi *machine learning* menurut Tom Mitchell adalah sebagai berikut : “ *A computer program is said to learn from experience E with respect to some task T and some performance measure P, if its performance on T, as measured by P, improves with experience E*” (Bedi Permana, 2019).

Terdapat tiga komponen dasar dalam *machine learning*, yaitu : algoritma matematis, prosessor komputer, dan data. Ketiganya harus tersedia dalam waktu yang bersamaan. Tanpa prosessor komputer, algoritma matematis tidak akan bisa di implementasikan, tanpa adanya data, maka algoritma matematis macam apapun tidak akan menghasilkan sesuatu. Algoritma *machine learning* umumnya mempunyai proses sebagai berikut :

Pengumpulan data, misalnya data hasil pengukuran dari transaksi, sensor-sensor, catatan-catatan, tulisan, angka, gambar, suara, atau bentuk data lainnya. Kumpulan data ini lazim disebut sebagai dataset dalam *machine learning*.

Abstraksi, yaitu proses yang menerjemahkan data-data menjadi suatu model yang lebih umum.

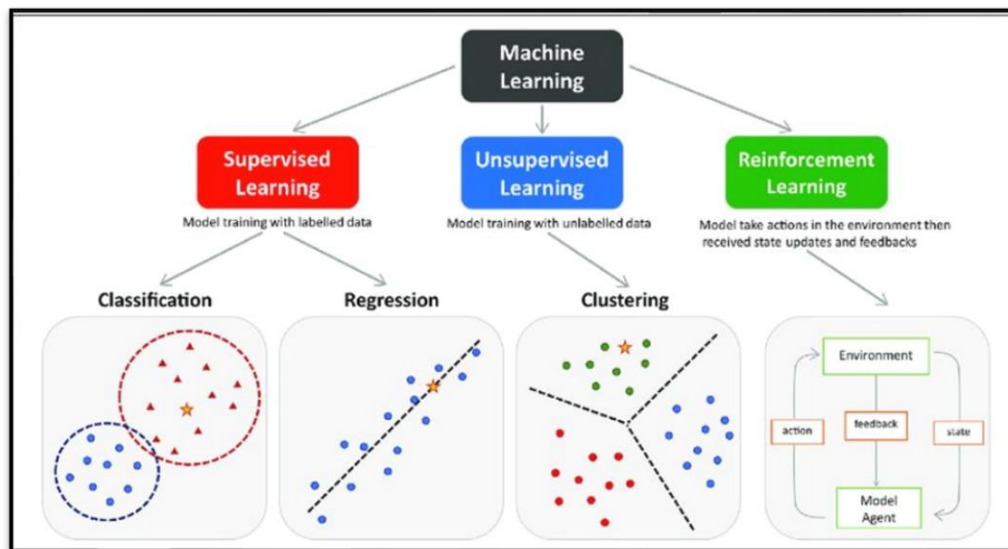
Generalisasi, yaitu proses yang menggunakan model hasil abtraksi sebagai dasar pembuatan keputusan atau kesimpulan.



Gambar 2.11 Proses Belajar Pada *Machine Learning*

Adapun fundamental tipe berdasarkan proses pembelajaran dari *machine learning* mayoritas pakar *machine learning* membaginya kedalam

tiga kelompok utama, yaitu : *Supervised Learning*; *Unsupervised Learning*; dan *Reinforcement Learning*.



Gambar 2.12 Fundamental Types of ML

Sumber : Bahan ajar mata kuliah MAI, RPS-Unhan 2022

Supervised learning menggunakan pendekatan di mana model atau algoritma mesin diajarkan untuk memahami hubungan antara input dan output dengan bantuan data pelatihan yang sudah memiliki label. Dalam *supervised learning*, tujuannya adalah untuk membuat model yang dapat memetakan input ke output yang benar atau dapat melakukan prediksi yang akurat berdasarkan contoh-contoh yang telah diberi label. Bentuk dari *supervised learning* berupa klasifikasi dan regresi.

Unsupervised learning berfokus pada pengolahan data yang tidak memiliki label. Dalam *unsupervised learning*, tujuannya adalah untuk mengidentifikasi pola atau struktur yang tersembunyi dalam data tanpa panduan label atau target yang jelas seperti dalam *supervised learning*. Bentuk dari *Unsupervised learning* adalah *clustering*.

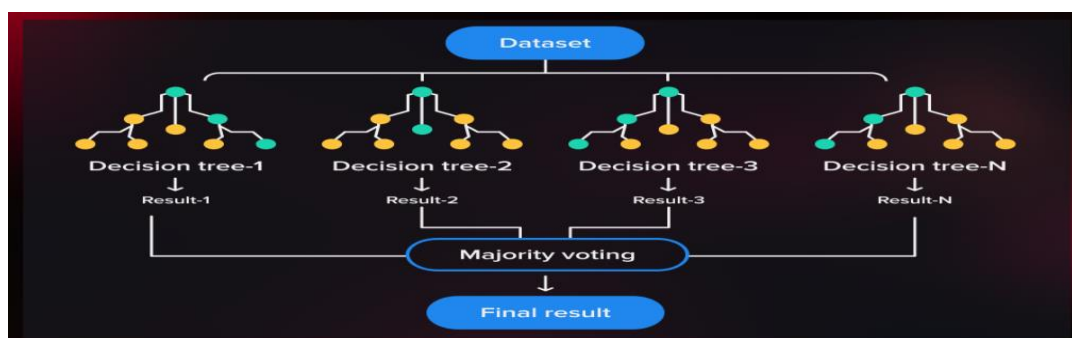
Reinforcement learning (RL) berfokus pada pembelajaran *agent* untuk membuat keputusan yang optimal dalam lingkungan tertentu untuk

mencapai tujuan tertentu. Paradigma ini mirip dengan bagaimana manusia belajar melalui pengalaman, eksperimen, dan umpan balik dari lingkungan sekitarnya. *Agent* belajar melalui interaksi berulang dengan lingkungannya, mencoba tindakan-tindakan yang berbeda untuk memaksimalkan *reward* yang diberikan.

2.1.3.1 *Random Forest* (RF)

Random Forest merupakan salah satu bentuk dari algoritma *supervised learning*. Sesuai namanya, RF adalah hutan acak yang berarti algoritma ini terdiri dari banyak pohon yang tidak terikat satu sama lain. Pada RF, setiap pohon akan menghasilkan nilai prediksi dan hasil akhirnya adalah memilih nilai prediksi yang muncul secara mayoritas. Jadi bisa dibayangkan, RF adalah algoritma *ensemble* yang berisi banyak *decision tree* didalamnya (Irwansyah Saputra, 2022).

Kumpulan *decision tree* ini biasanya dilatih dengan metode *bagging*. Ide umum dari metode *bagging* adalah kombinasi model pembelajaran untuk meningkatkan hasil keseluruhan. Algoritma RF meningkatkan keacakan pada model sambil menumbuhkan *tree*. Alaih-alih mencari feature yang paling penting saat memisahkan *node*, RF mencari feature terbaik di antara *subset* feature yang acak. Alhasil, cara ini menghasilkan keragaman yang luas dan umumnya menghasilkan model yang lebih baik (admin algoritma, 2022).



Gambar 2.13 Konsep *Random Forest*

Sumber : <https://serokell.io/blog/random-forest-classification>

Beberapa kelebihan dari RF, antara lain :

- a. Bisa mereduksi *overfitting* pada algoritma *decision tree* dengan teknik *bagging*.
- b. Akurasi lebih baik dibandingkan *decision tree* karena nilai akhir didapatkan dari nilai mayoritas.
- c. Algoritma ini dapat bekerja untuk kegiatan klasifikasi dan regresi.
- d. Algoritma ini bekerja dengan baik untuk tipe data yang kategorik dan numerik.

Adapun, beberapa kelemahan dari RF, antara lain :

- a. Algoritma ini membangun banyak pohon keputusan, karenanya waktu komputasi menjadi lebih tinggi dan kompleks saat melakukan pemodelan.
- b. Algoritma ini juga membutuhkan banyak waktu untuk latihan dan mengkombinasikan banyak pohon keputusan dalam menentukan nilai akhir (Irwansyah Saputra, 2022).

2.1.3.2 Support Vector Machine (SVM)

Support Vector Machine (SVM) juga merupakan algoritma *machine learning* dalam kelompok *supervised learning*. SVM digunakan untuk menganalisis data dan mengurutkannya ke dalam salah satu dari dua kategori. SVM bekerja untuk mencari fungsi pemisah atau *decision boundary* terbaik dalam memisahkan dua buah kelas atau lebih pada ruang input. Untuk data yang dapat dipisahkan secara linear digunakan SVM Linear (Trivusi, 2022).

SVM bekerja relatif baik jika ada margin pemisahan yang jelas antar kelas. Di sisi lain, SVM tidak bekerja dengan baik ketika dataset memiliki lebih banyak *noise* sehingga target menjadi tumpang tindih. Hal lainnya, jika fitur untuk setiap titik data melebihi jumlah sampel data *training*, SVM akan memiliki performa yang kurang baik. Algoritma SVM tidak cocok untuk dataset dalam jumlah yang besar karena membutuhkan waktu yang lama untuk *training*.

2.1.3.3 Gradient Boosting (GB)

Gradient Boosting merupakan salah satu algoritma *machine learning* yang banyak digunakan dalam menyelesaikan masalah regresi dan klasifikasi. GB diterapkan pada data yang kompleks atau sulit dimodelkan oleh model regresi linear biasa atau KNN. GB dapat digunakan untuk mempercepat waktu komputasi dengan teknik-teknik seperti *parallel computing* dan *caching*. GB memerlukan jumlah data yang besar agar diperoleh model yang akurat dan stabil. Jika jumlah datanya terlalu sedikit, model yang dihasilkan dapat menjadi tidak stabil dan kurang akurat (Trivusi, 2023).

Hal lainnya yang perlu diperhatikan adalah algoritma GB dapat cenderung *overfit* pada data *training* jika tidak dilakukan pengaturan parameter yang baik. Ketika model terlalu kompleks dan terlalu menyesuaikan dengan data *training*, model tidak dapat melakukan generalisasi dengan baik pada data yang belum pernah dikenali sebelumnya.

2.2 Hasil Penelitian Terdahulu

Kajian terhadap penelitian terdahulu perlu dilakukan untuk dapat memberikan landasan teoritis yang kuat dan merangkum temuan-temuan yang telah dilakukan oleh para peneliti sebelumnya. Dengan melakukan analisis yang sistematis maka kita dapat mengidentifikasi kerentanan penelitian sebelumnya, masalah yang masih belum terselesaikan, dan isu-isu terkini yang perlu dipertimbangkan.

Berikut beberapa penelitian terdahulu yang berkaitan dengan prediksi cuaca menggunakan algoritma *machine learning*. Bochenek dan Ustrnul (2022), telah menganalisis 500 artikel sains ilmiah sejak tahun 2018 menyebutkan bahwa metode *machine learning* akan menjadi sebuah *feature* kunci bagi prediksi cuaca dimasa yang akan datang (Bochenek & Ustrnul, 2022).

Oshodi (2022), melakukan penelitian menggunakan algoritma *machine learning Random Forest, Gradient Boosting, Gaussian Naïve Bayes*, dan *Decision Tree* untuk memprediksi fenomena *drizzle*, kabut, hujan, salju, dan cuaca cerah. Adapun datasetnya terdiri dari unsur presipitasi, temperatur maksimum, temperatur minimum, dan kecepatan angin di kota Seattle, Amerika Serikat periode 1 Januari 2012 sampai 31 Desember 2015. Hasilnya, prediksi dengan *Random Forest* tingkat akurasinya sebesar 79,5%, *Gradient Boosting* 80,87%, *Gaussian Naïve Bayes* 84,15%, dan *Decision Tree* 72,4% (Oshodi, 2022).

Kim *et al.* (2021) melakukan penelitian untuk memprediksi visibility (jarak pandang mendatar) di wilayah Korea Selatan dengan menggunakan algoritma *Random Forest*. Adapun *Datasetnya* adalah parameter temperatur, tekanan udara, kelembapan, kecepatan angin dan presipitasi dalam periode tahun 2017 sampai 2019. Hasil penelitian menunjukkan algoritma *Random Forest* menghasilkan prediksi yang sangat baik untuk musim kering (*dry season*) dengan nilai *bias*= 0.63 ; RMSE= 2.56 dan R= 0.87 (Kim *et al.*, 2021)

Penelitian lainnya dari dalam negeri, salah satunya yang dilakukan oleh Abdul Akbar (2022), pada tesis yang berjudul Rancang Model Prediksi Potensi Pertumbuhan Awan Cumulonimbus (Cb) Berbasis Artificial Neural Network (ANN) dengan Optimasi Grey Wolf Optimizer (GWO) Menggunakan Data Radiosonde yang di terbitkan oleh Universitas Indonesia. Berikut rangkuman beberapa penelitian yang pernah dilakukan sebelumnya terkait dengan prediksi fenomena cuaca dengan *machine learning*.

Tabel 2.5 Penelitian Terdahulu

No	Penulis	Data	Metode	Output	Kinerja
1	Agostino Manzato (2005)	Indeks Radiosonde setiap 6 jam	ANN (Model Regresi)	Thunderstorm	MSE = 0.031
2	A.F.Ali dkk (2011)	Tekanan, angin, titik embun, tipe awan	ANN (Multi Layer Perceptron)	Thunderstorm	Akurasi= 89 %
3	Litta A. J (2012) Suhu permukaan	Suhu permukaan	ANN (Feedforward)	Thunderstorm	Akurasi= 76%
4	Agie Wandala dkk (2014)	Indeks Radiosonde setiap 12 jam	PCA-ANN (Backpropagation)	Cumulonimbus	Akurasi = 82.5%
5	R M Putra dkk (2021)	Indeks Radiosonde setiap 12 jam	ANN (Multi Layer Perceptron)	Cumulonimbus	Akurasi = 80%
6	Kim, B. Y., dkk (2021)	temperatur, tekanan udara, kelembapan, angin dan presipitasi	Random Forest	Visibility	RMSE = 2.56
6	Abdul Akbar (2022)	Indeks Radiosonde setiap 12 jam	ANN (Multi Layer Perceptron) based on Grey Wolf Optimizer	Cumulonimbus	Akurasi = 89.6%
7	Oshodi (2022)	Presipitasi, temperatur maksimum, temperatur minimum, dan kecepatan angin	Random Forest, Gradient Boosting, Gaussian Naïve Bayes, dan Decision Tree	<i>Drizzle</i> , kabut, hujan, salju, dan cuaca cerah	<i>RF</i> akurasi = 79,5%; <i>GB</i> akurasi = 80,87%; <i>GNB</i> = 84,15%; <i>DT</i> = 72,4%

Ada beberapa persamaan dari penelitian dalam tabel diatas, yaitu : ada yang data inputnya menggunakan indeks labilitas atmosfer yang didapat dari observasi Radiosonde, kecuali tiga penelitian yang menggunakan data unsur cuaca berupa suhu, tekanan, angin, titik embun, dan awan. Adapun Algoritma *machine learning* yang digunakan dominan menggunakan ANN dengan beberapa variasi. Hasil penelitian yang cukup memuaskan yaitu metode *Multi Layer Perceptron* dengan akurasi mencapai 89%. Hasil outputnya berupa prediksi potensi terbentuknya awan cumulonimbus dan *thunderstorm*.

Penulis mencoba untuk menggunakan algoritma yang berbeda dengan penelitian sebelumnya, yaitu dengan menggunakan algoritma *random forest*. Hal ini ditujukan untuk mencari keterbaharuan dari penelitian sebelumnya. Disamping itu, algoritma *Random Forest* jauh lebih ekonomis dan lebih cepat dilatih jika dibandingkan dengan *neural network*. Pada saat yang sama, akurasi yang dihasilkan tidak terlalu berkurang (Inna Logunova, 2022).

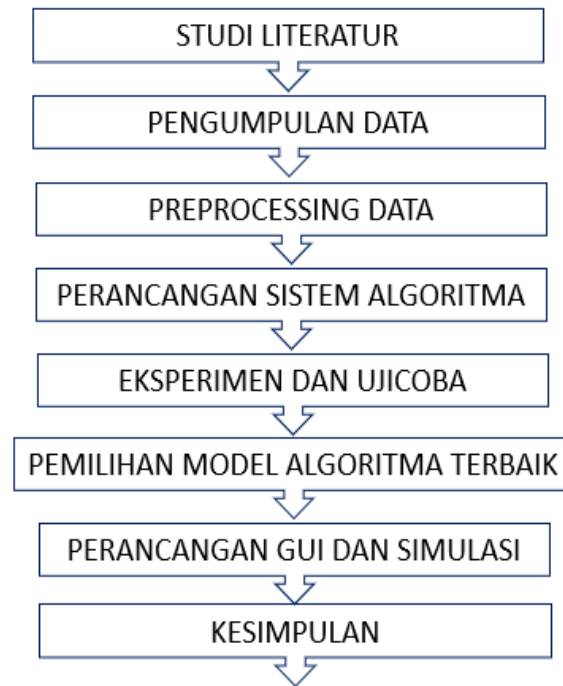
2.3 Kerangka Pemikiran

Penelitian yang penulis lakukan merupakan penelitian kuantitatif yang bersifat eksperimental. Penelitian ini dimulai dengan melakukan kajian terhadap penelitian-penelitian sebelumnya dalam bentuk studi literatur. Langkah awal ini dilakukan untuk mencari ide dan mengidentifikasi kekurangan-kekurangan dari metode yang digunakan. Selanjutnya dilakukan pengumpulan data dengan menggunakan teknik observasi ke lapangan dan pencarian melalui situs-situs tertentu yang menyediakan data Radiosonde yang sifatnya sebagai data publik.

Data yang didapat kemudian akan melewati proses *quality control* pada tahap *preprocessing* data, sehingga *dataset* yang dihasilkan sudah sesuai dan siap digunakan pada model rancangan algoritma yang akan dibuat. Setelah itu dilakukan perancangan sistem algoritma (*Random*

Forest) yang akan digunakan untuk prediksi potensi hujan dan *thunderstorm*.

Adapun bagan kerangka pemikiran yang penulis terapkan, lengkapnya dapat dilihat pada bagan alur dibawah ini.



Bagan 2.1 Kerangka Pemikiran

Langkah selanjutnya, setelah ada rancangan sistem algoritma maka dilakukan eksperimen untuk memperoleh model prediksi hujan dan *thunderstorm* menggunakan algoritma *Random Forest*. Hasil eksperimen kemudian dianalisis dan dievaluasi untuk memperoleh model yang memberikan kinerja terbaik untuk prediksi hujan dan *thunderstorm*. Ketika model terbaik didapatkan, maka model tersebut diimplementasikan ke dalam pengembangan aplikasi berbasis GUI untuk keperluan simulasi dengan data *real*. Aplikasi GUI yang dirancang diharapkan dapat memudahkan *user* dalam menggunakan model prediksi yang dibuat.

Langkah terakhir yaitu menganalisis hasil, kelemahan dan kelebihan serta pengembangan yang dapat dilakukan selanjutnya terhadap

model prediksi yang berhasil dirancang sehingga dapat ditarik kesimpulan akhir dari penelitian dan saran yang diharapkan.

2.4 Hipotesis

Prediksi hujan dan *thunderstorm* dengan menggunakan algoritma *machine learning random forest* berbasis data Radiosonde dapat dijadikan sebagai metode yang lebih objektif dan dapat meningkatkan tingkat akurasi prediksi dalam pembuatan *aerodrome forecast* di area Bandara Soekarno-Hatta dan Bandara Halim Perdanakusuma.