

Ekstraksi aturan *Decision Tree* berbasis *information gain* untuk mendekati klasifikasi risiko cuaca penerbangan berbasis skor SMB II Palembang

^{1*}Hesti Annisa Jannah, ²Afina Meutya Putri, ³Rendra Gustriansyah

^{1,2,3}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Indo Global Mandiri

^{1,2,3}Jl. Jend. Sudirman KM. 4, Palembang, Sumatera Selatan 30129, Indonesia

¹2023110023@students.uigm.ac.id, ²2023110056@students.uigm.ac.id, ³rendra@uigm.ac.id

Abstract

Aviation safety is a concern in global air transportation, where adverse weather conditions, including heavy rainfall, high humidity, and strong winds, can disrupt flight operations and threaten passenger and crew safety. Sultan Mahmud Badaruddin II (SMB II) Airport in Palembang, South Sumatra, operates within a tropical climate marked by extreme humidity and frequent heavy rainfall. This study applies the interpretable Decision Tree algorithm using an *information gain* criterion to reproduce a multivariable weighted-scoring classification of same-day aviation weather risk and generate transparent, auditable decision rules. The study uses meteorological data from the Indonesian Meteorological, Climatological, and Geophysical Agency (BMKG), covering May 2025 to May 2026, comprising 371 daily records with five attributes: average temperature (T_{avg}), relative humidity (RH_{avg}), rainfall (RR), wind direction (DDD_X), and wind speed (FF_{avg}). Risk labels were derived from a weighted-scoring system grounded in BMKG thresholds and references from the Civil Aviation Safety Regulation (CASR) and International Civil Aviation Organization (ICAO), yielding three classes: Safe (40.7%), Caution (39.1%), and Dangerous (20.2%). Data were split 80:20 with stratified sampling. The Synthetic Minority Over-sampling Technique (SMOTE) was applied to balance the training data. The model achieved 91.89% accuracy on the test set, with perfect recall on the Dangerous class (recall = 1.00, F1-score = 0.94). Because four of the five attributes are also used to construct the scoring labels, this accuracy primarily reflects the Decision Tree model's ability to reproduce the scoring structure rather than independently validating against actual operational risk.

Keywords: aviation weather risk classification, BMKG, Decision Tree, information gain, SMOTE

Abstrak

Keselamatan penerbangan merupakan prioritas utama dalam transportasi udara global, di mana cuaca buruk, termasuk curah hujan lebat, kelembapan tinggi, dan angin kencang, dapat mengganggu operasional penerbangan dan mengancam keselamatan penumpang serta kru pesawat. Bandara Sultan Mahmud Badaruddin II (SMB II) di Palembang, Sumatra Selatan, beroperasi dalam iklim tropis yang dicirikan oleh kelembapan ekstrem dan curah hujan lebat. Penelitian ini menerapkan algoritma *Decision Tree* berbasis *information gain* untuk mereproduksi klasifikasi risiko cuaca penerbangan hari yang sama (*same-day*) berbasis sistem skor multivariabel dan menghasilkan aturan keputusan yang transparan serta dapat ditelusuri. Penelitian menggunakan data meteorologi aktual dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), mencakup periode Mei 2025 hingga Mei 2026, sebanyak 371 data harian dengan lima atribut: suhu rata-rata (T_{avg}), kelembapan relatif (RH_{avg}), curah hujan (RR), arah angin (DDD_X), dan kecepatan angin (FF_{avg}). Label risiko diturunkan dari sistem skor tertimbang berdasarkan ambang batas BMKG serta rujukan *Civil Aviation Safety Regulation* (CASR) dan *International Civil Aviation Organization* (ICAO), menghasilkan tiga kelas: Aman (40,7%), Waspada (39,1%), dan Berbahaya (20,2%). Data dibagi 80:20 dengan *stratified*

sampling. *Synthetic Minority Over-sampling Technique* (SMOTE) digunakan untuk menyeimbangkan data latih. Model mencapai akurasi 91,89% pada data uji, dengan *recall* sempurna pada kelas Berbahaya (*recall* = 1,00, *F1-score* = 0,94). Karena empat dari lima atribut juga digunakan dalam pembentukan label berbasis skor, akurasi tersebut terutama mencerminkan kemampuan model *Decision Tree* mereproduksi struktur sistem skor, bukan memvalidasi secara independen risiko operasional aktual.

Kata Kunci: BMKG, *Decision Tree*, *information gain*, klasifikasi risiko cuaca penerbangan, SMOTE

1. Pendahuluan

Keselamatan penerbangan merupakan prioritas utama dalam sistem transportasi udara global. Kondisi cuaca buruk, meliputi curah hujan lebat, kelembapan tinggi, dan angin kencang merupakan faktor risiko yang dapat mengganggu operasional penerbangan dan mengancam keselamatan penumpang serta kru pesawat [1]. Di Indonesia, kondisi geografis wilayah tropis dengan variabilitas cuaca yang tinggi menjadikan risiko cuaca sebagai tantangan serius bagi operasional bandar udara [2]. Bandara Sultan Mahmud Badaruddin II (SMB II) Palembang beroperasi dalam lingkungan iklim tropis dengan kondisi meteorologis yang dapat memengaruhi pelayanan penerbangan. Pemanfaatan data dan teknologi meteorologi dalam mendukung pelayanan di Bandara SMB II juga telah menjadi perhatian dalam penelitian terdahulu [3]. Kondisi tersebut menunjukkan pentingnya klasifikasi risiko cuaca yang dapat digunakan untuk mengevaluasi kondisi meteorologis secara sistematis.

Sejumlah penelitian terdahulu telah mengembangkan model prediksi cuaca di lingkungan bandar udara menggunakan berbagai pendekatan pembelajaran mesin. Penerapan *Neural Network* dan *Random Forest* untuk prediksi kabut di bandara Indonesia menghasilkan akurasi yang cukup baik, namun kedua metode bersifat *black-box* sehingga sulit diinterpretasikan oleh operator yang tidak memiliki latar belakang teknis mendalam (akurasi tertinggi *Random Forest* 69,44% dan *Neural Network Backpropagation* 67,23%) [4]. Penelitian mengenai interpretabilitas *Random Forest* menunjukkan bahwa model *ensemble* tersebut memiliki mekanisme internal yang lebih sulit dipahami secara langsung, sehingga diperlukan pendekatan tambahan untuk menghasilkan representasi aturan yang lebih mudah diinterpretasikan [5]. Implementasi *Naive Bayes* untuk prediksi cuaca menunjukkan performa akurasi tinggi (96,56%), namun tetap dibatasi secara struktural oleh asumsi independensi kondisional antarvariabel yang secara konseptual kerap tidak terpenuhi pada data meteorologi berkorelasi tinggi seperti kelembapan dan curah hujan, sehingga berpotensi menurunkan keandalan model pada kondisi cuaca yang lebih kompleks [6]. Penerapan *Decision Tree* pada prediksi cuaca menunjukkan bahwa algoritma tersebut dapat digunakan untuk membentuk klasifikasi berbasis data meteorologi [7]. Selain itu, penerapan *Decision Tree* C4.5 untuk prakiraan hujan dan prediksi cuaca telah dikaji pada beberapa lokasi di Indonesia [8], [9]. Kondisi cuaca juga telah dikaji sebagai faktor yang berkaitan dengan keterlambatan keberangkatan penerbangan melalui pendekatan berbasis data [10].

Berdasarkan kajian literatur yang digunakan dalam penelitian ini, masih terdapat ruang penelitian untuk mengembangkan klasifikasi risiko cuaca penerbangan yang menggabungkan representasi aturan yang dapat ditelusuri dengan skema pelabelan risiko yang eksplisit pada konteks bandara di Indonesia, khususnya di wilayah Sumatra. Penelitian terdahulu [4], [7] berfokus pada penerapan dan evaluasi algoritma klasifikasi atau prediksi cuaca, sedangkan skema pelabelan risiko pada penelitian ini dirumuskan secara eksplisit berdasarkan parameter dan ambang batas cuaca yang digunakan.

Penelitian ini menggunakan klasifikasi berbasis data cuaca harian yang telah teramati pada hari yang sama (*same-day classification*), bukan peramalan (*forecasting*) kondisi cuaca

pada hari mendatang. Model mengklasifikasikan kategori risiko operasional dari data cuaca aktual hari berjalan, sehingga sesuai dimanfaatkan sebagai alat bantu evaluasi risiko operasional harian dan analisis retrospektif pola risiko musiman, bukan sebagai sistem prakiraan jangka pendek. Klasifikasi harian ini tidak dimaksudkan untuk memberikan penilaian risiko operasional secara *real-time* atau per jam yang dibutuhkan untuk keputusan taktis menit-ke-menit (misalnya keputusan lepas landas/pendaratan pada jam tertentu). Model ini lebih sesuai digunakan sebagai alat bantu evaluasi risiko harian dan analisis pola musiman. Data cuaca dengan frekuensi lebih tinggi (*intraday*/per jam) merupakan arah penelitian lanjutan yang diperlukan untuk mendukung aplikasi yang membutuhkan keputusan operasional secara *real-time*.


Kebaruan penelitian ini terletak bukan pada modifikasi algoritmik, melainkan pada dua kontribusi utama: (1) perumusan skema pelabelan risiko multivariabel yang eksplisit dan dapat ditelusuri berdasarkan ambang batas cuaca ekstrem BMKG serta rujukan operasional penerbangan, dan (2) penerapan dan evaluasi kinerja algoritma *Decision Tree* berbasis *information gain* pada data meteorologi Bandara SMB II Palembang.

Penelitian ini mengusulkan penggunaan algoritma *Decision Tree* berbasis *information gain* sebagai pendekatan yang mampu menghasilkan klasifikasi dengan aturan keputusan yang dapat diinterpretasikan. *Decision Tree* menghasilkan struktur aturan yang dapat divisualisasikan dan diinterpretasikan langsung oleh petugas operasional tanpa keahlian teknis khusus, mampu menangani data numerik dan kategorikal sekaligus, serta tidak memerlukan asumsi distribusi data tertentu sehingga dapat diterapkan pada data meteorologi BMKG yang heterogen [9].

Penelitian ini menggunakan data meteorologi aktual dari Stasiun Meteorologi Bandara SMB II Palembang (Kode Stasiun: 96221) yang diperoleh melalui layanan Data Online BMKG, mencakup 371 data harian periode Mei 2025 hingga Mei 2026. Tujuan penelitian adalah: (1) membangun model klasifikasi risiko cuaca penerbangan berbasis *Decision Tree* dengan kriteria *information gain* menggunakan data BMKG Stasiun SMB II Palembang; (2) mengevaluasi kinerja model menggunakan metrik akurasi, presisi, *recall*, dan F1-score; (3) mengidentifikasi atribut cuaca yang memiliki daya pisah statistik paling tinggi dalam membedakan kelas risiko; serta (4) menerapkan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) untuk mengatasi ketidakseimbangan kelas pada data latih.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimental kuantitatif dengan menerapkan algoritma *Decision Tree* dengan kriteria *information gain* pada data meteorologi BMKG. Alur penelitian terdiri atas lima tahapan utama sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian

2.1 Pengumpulan Data

Data meteorologi harian diperoleh dari portal resmi BMKG (*Data Online BMKG*) [11], khususnya Stasiun Meteorologi Sultan Mahmud Badaruddin II Palembang (kode stasiun 96221, koordinat $-2,89468^{\circ}$ LS dan $104,70129^{\circ}$ BT, elevasi 10 m). Data mencakup periode Mei 2025 hingga Mei 2026 dengan jumlah awal 372 data harian. Lima variabel yang dikumpulkan disajikan pada Tabel 1.

Tabel 1. Variabel dataset BMKG

Variabel	Keterangan	Satuan
Tavg	Suhu udara rata-rata harian	$^{\circ}\text{C}$
RH_avg	Kelembapan relatif rata-rata harian	%
RR	Curah hujan harian	mm
DDD_X	Arah angin saat kecepatan maksimum	$^{\circ}$
FF_avg	Kecepatan angin rata-rata harian	m/s

2.2 Pra-pemrosesan Data

2.2.1 Pembersihan dan Imputasi Data

Kode BMKG (8888 dan 9999) diidentifikasi dan diganti dengan nilai kosong (*NaN*). Jumlah nilai hilang yang ditemukan adalah RR sebanyak 43 data serta masing-masing 8 data pada Tavg, RH_avg, DDD_X, dan FF_avg. Seluruh nilai hilang diimputasi menggunakan metode *mean imputation*, yaitu mengganti setiap nilai kosong dengan nilai rata-rata variabel yang bersangkutan. Setelah prapemrosesan, seluruh 371 data dinyatakan valid untuk tahap pemodelan.

Proporsi nilai hilang tertinggi pada variabel RR, yaitu 43 dari 371 data atau 11,6%, sedangkan variabel lainnya masing-masing memiliki 8 nilai hilang. Pemilihan metode *mean imputation* didasarkan pada proporsi nilai hilang yang relatif kecil, yaitu di bawah 15%, serta pada pertimbangan kesederhanaan implementasi metode tersebut.

2.2.2 Pelabelan Risiko

Label risiko cuaca penerbangan ditetapkan menggunakan sistem skor multivariabel yang mempertimbangkan empat variabel cuaca secara terintegrasi. Skema skor dan ambang batas dirancang dengan mengacu pada kriteria intensitas curah hujan resmi BMKG [12], yang mengklasifikasikan hujan sedang pada rentang 20–50 mm/hari dan hujan lebat pada rentang 50–100 mm/hari, serta pada pedoman operasional penerbangan *Civil Aviation Safety Regulation* (CASR) [13] dan *International Civil Aviation Organization* (ICAO) Annex 3 [14] mengenai pengaruh curah hujan, jarak pandang, dan kelembapan terhadap keselamatan lepas landas dan pendaratan. Karena sensitivitas operasi penerbangan terhadap gangguan cuaca memerlukan tingkat kehati-hatian yang lebih tinggi daripada penggunaan ambang kategori bahaya cuaca umum, ambang batas penelitian ini dikalibrasi lebih konservatif (lebih rendah) daripada ambang kategori "lebat" BMKG, sejalan dengan prinsip kehati-hatian (*precautionary principle*) dalam manajemen risiko keselamatan penerbangan melalui *Safety Management System* (SMS) [15].

Bobot setiap kriteria ditetapkan secara proporsional terhadap besarnya dampak operasional masing-masing variabel: curah hujan (RR) memperoleh bobot tertinggi karena berkaitan dengan jarak pandang landas pacu (*runway visual range*) dan koefisien gesek (*braking action*); kelembapan (RH_avg) memperoleh bobot kedua karena berkaitan dengan potensi pembentukan kabut; suhu (Tavg) dan kecepatan angin (FF_avg) memperoleh bobot lebih rendah karena digunakan sebagai indikator pendukung kondisi atmosfer. Setiap data dihitung skor risikonya berdasarkan empat variabel dengan kriteria sebagai berikut:

- a. RR (Curah Hujan): ≥ 20 mm (+12 poin), $10 < 20$ mm (+8 poin), $5 < 10$ mm (+5 poin), dan $1 < 5$ mm (+2 poin).
- b. RH_avg (Kelembapan): $\geq 92\%$ (+10 poin), $88 < 92\%$ (+7 poin), $85 < 88\%$ (+4 poin), dan $82 < 85\%$ (+2 poin).
- c. Tavg (Suhu): < 26 °C (+4 poin), $26 < 27$ °C (+2 poin), dan $> 29,5$ °C (+1 poin).
- d. FF_avg (Kecepatan Angin): ≥ 4 m/s (+4 poin), $3 < 4$ m/s (+2 poin), dan $2 < 3$ m/s (+1 poin).

Rentang Tavg 27°C sampai dengan 29,5°C tidak memperoleh poin tambahan (skor 0 untuk komponen Tavg), karena rentang suhu tersebut dianggap berada dalam kondisi termal netral yang tidak berkontribusi signifikan terhadap peningkatan maupun penurunan risiko cuaca penerbangan berdasarkan skema yang dirancang. Klasifikasi risiko berdasarkan total skor adalah Berbahaya (skor ≥ 14), Waspada (skor 6–13), dan Aman (skor < 6). Jumlah tiga kelas (Aman, Waspada, dan Berbahaya) merupakan keputusan desain *a priori* yang dipilih sebelum pelabelan dilakukan, bukan hasil eksplorasi atau klusterisasi data pascapemrosesan. Pemilihan ini merujuk pada struktur matriks risiko tiga tingkat (rendah–sedang–tinggi) dalam kerangka SMS penerbangan sipil, sehingga tiap kelas dapat langsung dipetakan ke tindakan operasional: Aman (operasi normal), Waspada (peningkatan kewaspadaan), Berbahaya (evaluasi/penundaan operasi). Ambang skor (< 6 , 6–13, ≥ 14) ditetapkan sebagai bagian dari desain skema pelabelan sebelum proses klasifikasi dilakukan, dengan mempertimbangkan kriteria intensitas cuaca dan rujukan operasional penerbangan yang digunakan dalam penelitian ini. Hasil pelabelan menghasilkan 151 data Aman (40,7%), 145 data Waspada (39,1%), dan 75 data Berbahaya (20,2%) dari 371 data valid.

2.2.3 Pembagian Dataset

Dataset dibagi menggunakan *stratified random sampling* dengan rasio 80:20 untuk memastikan proporsi setiap kelas tetap konsisten pada data latih dan data uji. Data latih terdiri dari 297 data (Aman = 121; Waspada = 116; Berbahaya = 60) dan data uji terdiri dari 74 data (Aman = 30; Waspada = 29; Berbahaya = 15).

Rasio 80:20 dipilih untuk menyediakan data latih yang memadai bagi pembentukan pohon keputusan sekaligus mempertahankan jumlah data uji yang cukup untuk mengevaluasi kinerja model. Penggunaan *stratified sampling* memastikan proporsi ketiga kelas risiko pada data uji (Aman 40,5%, Waspada 39,2%, Berbahaya 20,3%) tetap merepresentasikan distribusi populasi data secara keseluruhan, sehingga evaluasi performa model tidak bias terhadap kelas tertentu.

2.2.4 Penyeimbangan Data dengan SMOTE

Distribusi kelas Berbahaya pada data latih, yaitu 60 data atau 20,2%, menunjukkan ketidakseimbangan yang relatif besar dibandingkan kelas Aman (121 data) dan Waspada (116 data), dengan rasio jumlah kelas maksimum sekitar 2:1. Ketidakseimbangan kelas dapat menyebabkan model cenderung bias terhadap kelas mayoritas sehingga performa pada kelas minoritas (Berbahaya) menurun [16]. Untuk mengatasi masalah ini, diterapkan teknik SMOTE pada data latih menggunakan paket *themis* di R dengan parameter $k = 5$ sebagai jumlah tetangga terdekat. Nilai $k = 5$ dipilih mengikuti praktik umum dalam penerapan SMOTE yang secara empiris memberikan keseimbangan antara variasi data sintetis yang dihasilkan dan risiko *overfitting* akibat interpolasi pada tetangga yang terlalu jauh dari sampel asli. SMOTE bekerja dengan menghasilkan data sintetis baru di sepanjang garis penghubung antara sampel minoritas dan tetangga terdekatnya dalam ruang fitur [17]. Teknik SMOTE hanya diterapkan pada data latih dan tidak menyentuh data uji agar evaluasi model tetap mencerminkan distribusi data nyata di lapangan [18].

2.3 Pemodelan Decision Tree Berbasis Information Gain

Algoritma *Decision Tree* C4.5 dikembangkan oleh Quinlan sebagai penyempurnaan ID3 dan secara konseptual menggunakan *gain ratio* sebagai kriteria pemilihan atribut [18]. Pada penelitian ini, implementasi model menggunakan paket *rpart* di RStudio dengan parameter *criterion* = '*information*', sehingga kriteria pemilihan atribut yang benar-benar diterapkan adalah *information gain*. Parameter tambahan yang digunakan meliputi *maxdepth* = 5, *minsplit* = 4, *minbucket* = 2, dan *seed* = 42.

Entropy digunakan untuk mengukur tingkat ketidakmurnian data dalam proses pembentukan pohon keputusan. Nilai *entropy* dapat dihitung menggunakan Persamaan (1) [18].

$$H(S) = - \sum_{c \in C} p(c) \log_2 p(c) \quad (1)$$

dengan $H(S)$ adalah nilai *entropy* pada himpunan data S , C adalah himpunan kelas, dan $p(c)$ adalah proporsi data yang termasuk dalam kelas c terhadap seluruh data pada S .

Information Gain digunakan untuk mengukur pengurangan *entropy* setelah data S dibagi berdasarkan atribut A . Nilai *information gain* dihitung menggunakan Persamaan (2) [18].

$$Gain(S, A) = H(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} H(S_v) \quad (2)$$

dengan $Gain(S, A)$ adalah nilai *information gain* atribut A terhadap himpunan data S , $H(S)$ adalah *entropy* sebelum pembagian data, $Values(A)$ adalah himpunan nilai atau partisi yang dihasilkan oleh atribut A , S_v adalah subset data untuk nilai atau partisi v , dan $|S_v|/|S|$ adalah proporsi jumlah data pada subset S_v terhadap jumlah data pada S . Atribut dengan *information gain* tertinggi dipilih sebagai *node* pemisah dan proses diulang secara rekursif hingga kriteria penghentian terpenuhi.

Pada penelitian ini, *entropy* awal dihitung berdasarkan data latih yang terdiri atas 297 data, yaitu 121 data Aman, 116 data Waspada, dan 60 data Berbahaya. Nilai *entropy* awal tersebut dihitung menggunakan Persamaan (1), sehingga diperoleh hasil perhitungan sebagai berikut:

$$H(S) = - \frac{121}{297} \log_2 \frac{121}{297} - \frac{116}{297} \log_2 \frac{116}{297} - \frac{60}{297} \log_2 \frac{60}{297} = 1,563 \text{ bit}$$

Nilai *entropy* sebesar 1,563 bit yang mendekati nilai maksimum untuk tiga kelas, yaitu 1,585 bit, mengindikasikan distribusi jumlah data antarkelas pada data latih relatif seimbang. Nilai tersebut bukan bukti independen mengenai validitas skema pelabelan, karena jumlah kelas telah ditetapkan sejak tahap pelabelan sebagai keputusan desain.

2.4 Evaluasi Model

Kinerja model dievaluasi pada data uji menggunakan empat metrik, yaitu akurasi, *precision*, *recall*, dan *F1-score* [19]. Akurasi mengukur proporsi prediksi yang benar secara keseluruhan dan dapat dihitung menggunakan Persamaan (3).

$$\text{Akurasi} = \frac{\sum_c TP_c}{\text{Total Data Uji}} \times 100\% \quad (3)$$

dengan TP_c (*True Positive*) adalah jumlah data kelas c yang diprediksi benar sebagai kelas c .

Presisi per kelas mengukur proporsi data yang benar-benar termasuk dalam kelas c dari seluruh data yang diprediksi sebagai kelas c . Presisi dihitung menggunakan Persamaan (4).

$$\text{Presisi}_c = \frac{TP_c}{TP_c + FP_c} \quad (4)$$

dengan FP_c (*False Positive*) adalah jumlah data dari kelas selain c yang salah diprediksi sebagai kelas c .

Recall mengukur proporsi data dari kelas c yang berhasil diprediksi dengan benar dari seluruh data yang sebenarnya termasuk dalam kelas c dan dapat dihitung menggunakan Persamaan (5).

$$Recall_c = \frac{TP_c}{TP_c + FN_c} \quad (5)$$

dengan FN_c (*False Negative*) adalah jumlah data kelas c yang salah diprediksi sebagai kelas selain c .


F1-score merupakan rata-rata harmonis antara presisi dan *recall* yang digunakan untuk memberikan ukuran gabungan kinerja klasifikasi suatu kelas dan dapat dihitung menggunakan Persamaan (6).

$$F1-score_c = \frac{2 \times Presisi_c \times Recall_c}{Presisi_c + Recall_c} \quad (6)$$

3. Hasil dan Pembahasan

3.1 Statistik Deskriptif Data

Data final terdiri dari 371 data harian valid selama periode Mei 2025–Mei 2026. Statistik deskriptif seluruh variabel disajikan pada Tabel 2, sedangkan visualisasi sebaran variasi harian seluruh variabel terhadap label risiko ditunjukkan pada Gambar 2. Data pada Gambar 2 disajikan secara kronologis untuk tujuan eksplorasi visual, bukan sebagai analisis deret waktu (*time-series*), karena model klasifikasi pada penelitian ini memperlakukan setiap hari sebagai observasi independen.



Gambar 2. Sebaran variabel cuaca harian terhadap label risiko Stasiun SMB II Palembang (Mei 2025–Mei 2026)


Tabel 2. Statistik deskriptif data final ($n = 371$)

Variabel	Min	Max	Rata-rata	Std. Deviasi	Median
T _{avg} (°C)	24,30	30,10	27,52	1,08	27,52
RH _{avg} (%)	65,00	99,00	84,09	5,39	84,00
RR (mm)	0,00	94,50	7,79	14,53	1,20
DDD _X (°)	50,00	360,00	208,49	70,31	198,00
FF _{avg} (m/s)	1,00	4,00	1,90	0,56	2,00

T_{avg} memiliki fluktuasi relatif rendah selama periode pengamatan ($SD = 1,08\text{ }^{\circ}\text{C}$, rentang $5,80\text{ }^{\circ}\text{C}$), mencerminkan stabilitas termal khas iklim tropis Palembang [20]. RH_{avg} rata-rata $84,09\%$ dengan median $84,00\%$ berada sedikit di bawah ambang batas Waspada (85%), sedangkan titik-titik Berbahaya pada Gambar 2 cenderung terkonsentrasi pada nilai $RH_{avg} \geq 88\%$. RR menunjukkan distribusi yang sangat miring kanan dengan median $1,20\text{ mm}$ namun nilai maksimum mencapai $94,50\text{ mm/hari}$, pola khas hujan konvektif tropis dan seluruh lonjakan ekstrem berlabel Berbahaya. FF_{avg} memiliki variasi yang relatif rendah ($SD = 0,56\text{ m/s}$).

3.2 Distribusi Label Risiko

Hasil pelabelan berdasarkan sistem skor multivariabel pada 371 data disajikan pada Tabel 3 dan Gambar 3.



Gambar 3. Distribusi label risiko cuaca ($n = 371$)

Tabel 3. Distribusi label risiko ($n = 371$)

Kelas	Jumlah	Proporsi
Aman	151	40,7%
Waspada	145	39,1%
Berbahaya	75	20,2%
Total	371	100%

Kelas Aman mendominasi dengan 151 data (40,7%), diikuti Waspada 145 data (39,1%) dan Berbahaya 75 data (20,2%). Secara kumulatif, 59,3% data harian termasuk kategori Waspada atau Berbahaya. Rasio kelas maksimum sebesar 2,01:1 antara Aman dan Berbahaya mengindikasikan adanya ketidakseimbangan kelas, yang selanjutnya ditangani menggunakan SMOTE pada data latih.

3.3 Distribusi Risiko Per Bulan

Distribusi risiko cuaca per bulan disajikan pada Tabel 4. Tabel 4 memperlihatkan perbedaan distribusi kelas risiko antarbulan. Periode musim kemarau (Juni-Agustus 2025) didominasi kelas Aman dengan puncak 18 hari Aman pada Juli 2025 dan jumlah data Berbahaya yang relatif rendah pada periode tersebut [21]. Memasuki musim hujan pada September 2025, frekuensi Berbahaya meningkat menjadi 11 [22], [23]. Puncak risiko tertinggi terjadi pada Desember 2025 bertepatan dengan aktifnya Monsun Asia dan tingginya curah hujan di wilayah Sumatera Selatan, termasuk Palembang [22], [24]. Periode Januari-Februari 2026 didominasi Waspada disertai frekuensi Berbahaya yang masih tinggi. Pola ini konsisten dengan karakteristik musim hujan di Sumatera bagian selatan yang umumnya


mencapai periode puncak pada periode November-Februari [21], [22], sehingga jumlah data berlabel Berbahaya pada periode November 2025–Februari 2026 terlihat relatif lebih tinggi dibandingkan beberapa bulan lainnya.

Tabel 4. Distribusi risiko cuaca per bulan (Mei 2025–Mei 2026)


Bulan	Aman	Waspada	Berbahaya	Total
Mei 2025	10	12	4	26
Jun 2025	14	12	4	30
Jul 2025	18	8	5	31
Agu 2025	15	12	4	31
Sep 2025	11	8	11	30
Okt 2025	14	9	8	31
Nov 2025	11	10	9	30
Des 2025	7	10	14	31
Jan 2026	5	17	9	31
Feb 2026	4	14	10	28
Mar 2026	14	13	4	31
Apr 2026	9	13	8	30
Mei 2026	9	12	5	26
Total	151	145	75	371

3.4 Hasil Pembagian *Dataset* dan Penyeimbangan SMOTE

Pembagian data menggunakan *stratified random sampling* dengan rasio 80:20 menghasilkan 297 data latih dan 74 data uji, sebagaimana ditunjukkan pada Gambar 4. Setelah diterapkan SMOTE, jumlah data pada setiap kelas dalam data latih menjadi seimbang, yaitu 121 data per kelas, sehingga total data latih setelah penyeimbangan menjadi 363, sebagaimana ditunjukkan pada Gambar 5.




Gambar 4. Distribusi kelas data latih dan data uji sebelum SMOTE



Gambar 5. Distribusi kelas data latih setelah SMOTE

3.5 Information Gain dan Pemilihan Atribut

Hasil perhitungan *information gain* seluruh atribut pada *dataset* disajikan pada Tabel 5 dan Gambar 6.



Gambar 6. Visualisasi *information gain* seluruh atribut


Tabel 5. *Information gain* seluruh atribut

Peringkat	Atribut	Information Gain	Keterangan
1	Tāvg	0,3153	Daya pisah statistik tertinggi
2	RH_avg	0,3014	Daya pisah statistik tinggi
3	RR	0,2787	Daya pisah statistik tinggi
4	DDD_X	0,0528	Daya pisah statistik rendah
5	FF_avg	0,0519	Daya pisah statistik rendah

Tāvg merupakan atribut dengan *information gain* tertinggi (0,3153), menunjukkan bahwa Tāvg memiliki daya pisah statistik tertinggi terhadap kelas risiko pada data penelitian ini. Hal ini menunjukkan bahwa Tāvg memberikan pemisahan statistik yang relatif kuat dalam membedakan kelas risiko berdasarkan skema pelabelan yang digunakan. RH_avg menjadi atribut ke-2 (0,3014) yang menunjukkan daya pisah statistik tinggi, diikuti RR (0,2787) yang juga menunjukkan daya pisah statistik tinggi dalam membedakan kelas risiko pada data penelitian ini. DDD_X memiliki *information gain* yang relatif rendah, sehingga tidak digunakan sebagai *node* pemisah pada pohon final. FF_avg juga memiliki *information gain* yang relatif rendah secara global, tetapi tetap digunakan sebagai *node* pemisah pada cabang tertentu dalam model final. Peringkat *information gain* ini tidak bertentangan dengan bobot skor risiko pada Subbab 2.2.2, karena keduanya mengukur hal yang berbeda. Bobot skor mencerminkan besarnya dampak operasional langsung suatu variabel terhadap keselamatan penerbangan (misalnya curah hujan ekstrem berdampak langsung pada traksi landasan), sedangkan *information gain* mengukur pengurangan *entropy* atau daya pisah statistik variabel tersebut dalam membedakan ketiga kelas risiko pada data penelitian ini. Tāvg memperoleh *information gain* tertinggi karena memberikan pengurangan *entropy* paling besar dalam membedakan kelas risiko pada data penelitian ini, bukan karena dampak operasionalnya lebih besar dari curah hujan.

3.6 Hasil Pemodelan Decision Tree

Model *Decision Tree* menghasilkan pohon keputusan dengan kedalaman 5 level menggunakan RR sebagai *root node* (threshold $RR \geq 4,7$ dan $RR < 4,7$) dan Tāvg, RH_avg, serta FF_avg sebagai *node* pemisah lanjutan sebagaimana ditunjukkan pada Gambar 7. Aturan-aturan IF-THEN yang dibaca langsung dari Gambar 7 dan disajikan pada Tabel 6.



Gambar 7. Decision Tree berbasis information gain setelah SMOTE


Tabel 6. Aturan IF-THEN Decision Tree

No	Kondisi IF	Prediksi
1	$RR \geq 4,7$ AND $Tavg < 27,5$ AND $RH_avg \geq 87$	Berbahaya
2	$RR \geq 4,7$ AND $Tavg < 27,5$ AND $RH_avg < 87$ AND $RR \geq 17,6$	Berbahaya
3	$RR \geq 4,7$ AND $Tavg < 27,5$ AND $RH_avg < 87$ AND $RR < 17,6$ AND $Tavg < 26,7$	Berbahaya
4	$RR \geq 4,7$ AND $Tavg < 27,5$ AND $RH_avg < 87$ AND $RR < 17,6$ AND $Tavg \geq 26,7$	Waspada
5	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR \geq 11,75$ AND $RH_avg \geq 81,5$ AND $RR \geq 18,5$	Berbahaya
6	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR \geq 11,75$ AND $RH_avg \geq 81,5$ AND $RR < 18,5$	Waspada
7	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR \geq 11,75$ AND $RH_avg < 81,5$	Waspada
8	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR < 11,75$ AND $FF_avg \geq 1,45$	Waspada
9	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR < 11,75$ AND $FF_avg < 1,45$ AND $RH_avg \geq 81,5$	Waspada
10	$RR \geq 4,7$ AND $Tavg \geq 27,5$ AND $RR < 11,75$ AND $FF_avg < 1,45$ AND $RH_avg < 81,5$	Aman
11	$RR < 4,7$ AND $RH_avg \geq 84,5$ AND $Tavg < 25,9$	Berbahaya
12	$RR < 4,7$ AND $RH_avg \geq 84,5$ AND $Tavg \geq 25,9$ AND $RH_avg \geq 87,3$	Waspada
13	$RR < 4,7$ AND $RH_avg \geq 84,5$ AND $Tavg \geq 25,9$ AND $RH_avg < 87,3$ AND $Tavg < 26,9$	Waspada
14	$RR < 4,7$ AND $RH_avg \geq 84,5$ AND $Tavg \geq 25,9$ AND $RH_avg < 87,3$ AND $Tavg \geq 26,9$	Aman
15	$RR < 4,7$ AND $RH_avg < 84,5$ AND $Tavg < 26,85$	Waspada
16	$RR < 4,7$ AND $RH_avg < 84,5$ AND $Tavg \geq 26,85$	Aman

Tiga pola struktural utama teramati. Pertama, $RR < 4,7$ mm dengan $RH_avg < 84,5\%$ dan $Tavg \geq 26,85^\circ\text{C}$ secara konsisten menghasilkan Aman dalam aturan keputusan yang diperoleh. Kedua, $Tavg < 25,9^\circ\text{C}$ berperan sebagai kondisi pemisah yang menghasilkan kelas berisiko lebih tinggi pada cabang tertentu. Pada kondisi kelembapan tinggi dan suhu rendah, cabang pohon tertentu menghasilkan minimal Waspada. Ketiga, $RR \geq 4,7$ mm disertai $RH_avg \geq 87\%$ menghasilkan kelas Berbahaya pada cabang keputusan yang sesuai, menunjukkan bahwa kombinasi hujan dan atmosfer jenuh merupakan kondisi yang paling banyak berkontribusi pada skor risiko tertinggi dalam skema pelabelan yang digunakan, bukan bukti independen bahwa kombinasi tersebut secara aktual paling berbahaya bagi operasional penerbangan di lapangan.

3.7 Evaluasi Model Empat Metrik

Evaluasi model dilakukan menggunakan 74 data uji. *Confusion matrix* dan grafik metrik per kelas ditunjukkan pada Gambar 8. Ringkasan seluruh metrik evaluasi model disajikan pada Tabel 7.



Gambar 8. *Confusion matrix* dan metrik evaluasi per kelas

Perhitungan akurasi, presisi, *recall*, dan F1-score sebagai berikut:

1. Akurasi

$$\text{Akurasi} = \frac{30 + 23 + 15}{74} \times 100\% = \frac{68}{74} \times 100\% = 91,89\%$$

2. Presisi

$$\text{Presisi}_{\text{Aman}} = \frac{30}{34} = 0,88, \quad \text{Presisi}_{\text{Waspada}} = \frac{23}{23} = 1,00, \quad \text{Presisi}_{\text{Berbahaya}} = \frac{15}{17} = 0,88$$

3. *Recall*

$$\text{Recall}_{\text{Aman}} = \frac{30}{30} = 1,00, \quad \text{Recall}_{\text{Waspada}} = \frac{23}{29} = 0,79, \quad \text{Recall}_{\text{Berbahaya}} = \frac{15}{15} = 1,00$$

4. F1-score

$$F1_{\text{Aman}} = \frac{2 \times 0,88 \times 1,00}{0,88 + 1,00} = 0,94, \quad F1_{\text{Waspada}} = \frac{2 \times 1,00 \times 0,79}{1,00 + 0,79} = 0,88, \quad F1_{\text{Berbahaya}} = 0,94$$

Tabel 7. Ringkasan metrik evaluasi model

Kelas	Presisi	Recall	F1-score	Support
Aman	88%	100%	94%	30
Waspada	100%	79%	88%	29
Berbahaya	88%	100%	94%	15
Macro Avg	92%	93%	92%	74
Akurasi	-	-	91,89%	74

Recall sempurna (100%) pada kelas Berbahaya mengindikasikan bahwa model tidak melewati satu pun data uji yang diberi label Berbahaya berdasarkan sistem skor yang digunakan. Dalam konteks klasifikasi risiko, kemampuan tersebut penting karena kesalahan *false negative*, yaitu data berlabel Berbahaya terklasifikasi sebagai Aman atau Waspada, dapat menyebabkan kondisi berisiko tidak teridentifikasi oleh model. Dibandingkan dengan model *black-box* pada penelitian [4] (*Random Forest* 69,44%, *Neural Network* 67,23%) dan [6] (*Naive Bayes* 96,56%), model *Decision Tree* pada penelitian ini menghasilkan akurasi kompetitif (91,89%) sekaligus menyediakan aturan keputusan yang dapat ditelusuri secara

eksplisit, keunggulan struktural yang tidak dimiliki pendekatan *black-box*. Kesalahan klasifikasi yang tersisa terjadi pada data berlabel Waspada yang diprediksi sebagai Aman sebanyak 4 data dan sebagai Berbahaya sebanyak 2 data, tanpa kesalahan langsung antara kelas Aman dan Berbahaya. Hal ini menunjukkan bahwa kesalahan klasifikasi terjadi terutama pada kelas Waspada. Penelitian ini belum membandingkan performa model dengan metode *ensemble* maupun performa tanpa SMOTE secara terisolasi, sehingga kontribusi relatif masing-masing komponen terhadap performa akhir masih perlu divalidasi pada penelitian lanjutan.

Empat dari lima variabel cuaca yang digunakan sebagai atribut *input*, yaitu RR, RH_avg, Tavg, dan FF_avg adalah variabel yang juga digunakan untuk menghitung skor pelabelan risiko, sedangkan DDD_X hanya digunakan sebagai atribut input model dan tidak digunakan dalam perhitungan skor pelabelan. Akibatnya, akurasi tinggi (91,89%) pada dasarnya menunjukkan bahwa model berhasil mereproduksi atau mendekati struktur sistem penilaian berbobot yang telah ditentukan sebelumnya, bukan bukti validasi independen bahwa kategori risiko yang dihasilkan benar-benar mencerminkan risiko penerbangan operasional yang sesungguhnya di lapangan. Evaluasi terhadap risiko aktual (misalnya kejadian penundaan, pembatalan, atau insiden penerbangan yang tercatat secara historis) memerlukan data *ground truth* independen yang berada di luar cakupan penelitian ini.

3.8 Interpretasi dan Pembahasan

Seluruh 15 data Berbahaya pada data uji terklasifikasikan tepat tanpa satu pun yang terlewat (*zero miss*). Dari perspektif keselamatan penerbangan, ini merupakan capaian paling kritis: model tidak pernah gagal mengidentifikasi data yang diberi label Berbahaya berdasarkan sistem skor yang digunakan [25]. Seluruh 15 data Berbahaya pada data uji berhasil terdeteksi sempurna (*recall* = 1,00). *Recall* sempurna ini kemungkinan besar disebabkan oleh keterpisahan yang kuat antara kelas Berbahaya dan kelas lain pada ruang fitur, karena label Berbahaya dihasilkan dari ambang skor gabungan (≥ 14) yang mensyaratkan kombinasi ekstrem pada beberapa variabel sekaligus (misalnya curah hujan dan kelembapan tinggi serta suhu rendah secara bersamaan), sehingga secara alami menghasilkan batas keputusan yang jelas dan mudah dipelajari oleh pohon keputusan. Penelitian ini tidak menyatakan bahwa SMOTE menyebabkan *recall* sempurna tersebut, karena penelitian ini tidak melakukan perbandingan terpisah antara model dengan dan tanpa SMOTE untuk menetapkan hubungan kausal tersebut. SMOTE hanya berperan menyeimbangkan proporsi kelas pada data latih [17].

Terdapat 4 data Waspada yang diprediksi sebagai Aman dan 2 data Waspada yang diprediksi sebagai Berbahaya. Dalam konteks operasional penerbangan, *false alarm* pada kelas Waspada perlu dipertimbangkan bersama risiko *miss* pada kelas Berbahaya karena pilot dan ATC dapat mengambil tindakan ekstra kehati-hatian [26]. *Recall* Waspada 0,79 berarti 21% kondisi Waspada tidak terdeteksi, yang menjadi area perbaikan pada penelitian selanjutnya.

Recall Aman sempurna (1,00) berarti seluruh data berlabel Aman berhasil diidentifikasi. Presisi 0,88 menunjukkan bahwa sebagian data Waspada diprediksi sebagai Aman. Pada kondisi ambang batas, model lebih memilih Waspada daripada Aman, yang dapat dipandang sebagai pendekatan yang lebih berhati-hati dalam konteks keselamatan karena kesalahan *miss* pada sistem peringatan penerbangan dapat berdampak lebih besar daripada *false alarm* [27].

Akurasi 91,89% pada data uji berada dalam rentang kompetitif dibandingkan model *black-box* pada penelitian sejenis, meskipun sedikit lebih rendah dari *Naive Bayes* pada penelitian [6] (96,56%) dan lebih tinggi dari *Random Forest* serta *Neural Network Backpropagation* pada penelitian [4] (69,44% dan 67,23%). Perbedaan ini wajar karena perbedaan data, jumlah kelas, dan konteks domain. Karakteristik penting dari pendekatan

yang digunakan dalam penelitian ini tidak hanya pada performa klasifikasi, tetapi juga kemampuan Decision Tree dalam menghasilkan aturan keputusan yang eksplisit dan dapat ditelusuri. Berbeda dengan pendekatan *ensemble* seperti *Random Forest*, *Decision Tree* menghasilkan struktur aturan *IF-THEN* yang dapat ditelusuri langsung dari jalur keputusan model. Aturan *IF-THEN* yang dihasilkan dapat menjadi bahan untuk evaluasi lebih lanjut mengenai kemungkinan pemanfaatannya sebagai informasi pendukung bagi pengambilan keputusan operasional. *Macro F1-score* 0,92 mengonfirmasi performa yang konsisten dan seimbang di seluruh kelas risiko.

4. Kesimpulan

Penelitian ini menghasilkan representasi aturan *IF-THEN* yang eksplisit, dapat ditelusuri, dan dapat diinterpretasikan dari klasifikasi risiko cuaca penerbangan berbasis sistem skor tertimbang yang digunakan. Representasi tersebut berpotensi memberikan manfaat dalam hal transparansi dan auditabilitas, karena aturan keputusan memperlihatkan interaksi antarvariabel secara eksplisit. Penelitian ini tidak melakukan eksperimen perbandingan langsung antara *Decision Tree* berbasis *information gain* dan sistem skor tertimbang, sehingga belum dapat disimpulkan bahwa *Decision Tree* berbasis *information gain* memiliki kinerja yang lebih baik daripada sistem skor tertimbang tersebut.

Model *Decision Tree* berbasis *information gain* mencapai akurasi 91,89% pada 74 data uji, dengan *macro F1-score* 0,92 dan *recall* 1,00 pada kelas Berbahaya, serta *F1-score* 0,94. Hasil tersebut menunjukkan bahwa *Decision Tree* berbasis *information gain* mampu menghasilkan representasi aturan eksplisit dengan performa klasifikasi yang baik. Namun, karena empat dari lima atribut *input* juga digunakan dalam pembentukan label berbasis skor, hasil tersebut terutama mencerminkan kemampuan *Decision Tree* berbasis *information gain* dalam mereproduksi struktur sistem skor dan bukan merupakan validasi independen terhadap risiko operasional penerbangan aktual.

Interpretabilitas *Decision Tree* secara konseptual relevan dengan sifat keputusan operasional Bandara SMB II (evaluasi atau penundaan operasi) yang idealnya dapat dipertanggungjawabkan secara transparan, sejalan dengan prinsip audit keputusan keselamatan dalam kerangka *Safety Management System*. Namun demikian, penelitian ini tidak menyertakan evaluasi kegunaan (*usability*) atau kajian kebutuhan pengguna secara formal, seperti wawancara atau analisis SOP dengan petugas ATC dan *Ground Handling*, sehingga klaim ini bersifat rasional metodologis dan bukan bukti empiris atas kebutuhan operasional yang telah ditetapkan. *Tavg* memiliki nilai *information gain* tertinggi yaitu 0,3153, diikuti *RH_avg* (0,3014) dan *RR* (0,2787), yang menunjukkan bahwa *Tavg* memiliki daya pisah statistik paling tinggi dalam membedakan kelas risiko pada data penelitian ini.

Kontribusi ilmiah utama penelitian ini adalah (1) perumusan skema pelabelan risiko multivariabel yang eksplisit dan dapat ditelusuri berdasarkan ambang batas BMKG serta rujukan operasional penerbangan, dan (2) penerapan dan evaluasi kinerja algoritma *Decision Tree* berbasis *information gain* pada konteks operasional bandara tropis Indonesia yang sebelumnya belum banyak dikaji. Penerapan SMOTE pada data latih berhasil menyeimbangkan distribusi kelas dari rasio 2:1 menjadi seimbang sempurna, namun kontribusi spesifiknya terhadap capaian *recall* sempurna pada kelas Berbahaya belum diisolasi secara eksperimental sehingga tidak diklaim sebagai penyebab tunggal. Untuk penelitian selanjutnya, disarankan untuk: (1) menguji performa model tanpa SMOTE untuk mengisolasi kontribusinya secara kuantitatif; (2) membandingkan model dengan metode *ensemble* seperti *Random Forest* atau *Gradient Boosting* untuk menguji *trade-off* antara interpretabilitas dan akurasi; serta (3) menguji transferabilitas model pada bandara lain di Sumatera Selatan menggunakan data intrahari dengan resolusi per jam.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Meteorologi Sultan Mahmud Badaruddin II Palembang atas penyediaan akses data cuaca yang digunakan dalam penelitian ini. Penulis juga mengucapkan terima kasih kepada Universitas Indo Global Mandiri atas dukungan fasilitas selama proses penelitian dan penulisan naskah ini.

Pernyataan

Kontribusi Penulis: H.A.J.: konseptualisasi, metodologi, analisis data, pemodelan, dan penulisan naskah. A.M.P. dan R.G.: supervisi, tinjauan metodologi, dan penyuntingan naskah.

Pendanaan: Penelitian ini tidak menerima pendanaan khusus dari lembaga pemerintah, komersial, maupun nirlaba manapun.

Konflik Kepentingan: Penulis menyatakan tidak terdapat konflik kepentingan dalam penelitian ini.

Ketersediaan Data: Data cuaca yang digunakan dalam penelitian ini bersumber dari layanan Data Online BMKG dan tersedia dari penulis korespondensi atas permintaan yang wajar.

Persetujuan Etika: Tidak berlaku, karena penelitian ini tidak melibatkan subjek manusia maupun hewan secara langsung dan menggunakan data meteorologi sekunder yang bersifat publik.

Pernyataan Penggunaan Kecerdasan Buatan (AI): AI digunakan secara terbatas untuk membantu proses revisi naskah, termasuk penyusunan justifikasi ilmiah tambahan, pemeriksaan tata bahasa, dan penyusunan visualisasi data. Seluruh analisis data, interpretasi hasil, dan kesimpulan ilmiah dalam penelitian ini merupakan tanggung jawab penuh penulis.

Daftar Referensi

- [1] R. Olaganathan and R. G. Ham, "Significance of incorporating weather technology training for GA pilots to curb fatalities," *Int. J. Aviat. Aeronaut. Aerosp.*, vol. 7, no. 2, Art. no. 13, 2020, doi: 10.58940/2374-6793.1478.
- [2] A. Saadah and M. N. Cahyadi, "Identification of cumulonimbus clouds as a trigger for extreme weather at Soekarno-Hatta International Airport on July 24, 2023 based on weather radar, LIDAR, and PWV estimates of the ECMWF-ERA5 numerical model," *J. Penelit. Pendidik. IPA*, vol. 11, no. 9, pp. 395–406, 2025, doi: 10.29303/jppipa.v11i9.12604.
- [3] A. R. Ramadhan, D. D. Kurniawan, and T. Sutabri, "Penerapan machine learning dalam pelayanan UPT BMKG Palembang di Bandara SMBII Palembang," *J. Sistim Inf. dan Teknol.*, vol. 5, no. 2, pp. 203–207, 2023, doi: 10.60083/jsisfotek.v5i2.255.
- [4] A. Kurniawan and R. Z. A. Aziz, "Prediksi kabut bandar udara di Indonesia menggunakan neural network dan random forest," *Build. Informatics, Technol. Sci.*, vol. 6, no. 2, pp. 746–757, 2024, doi: 10.47065/bits.v6i2.5544.
- [5] A. Khairunnisa, K. A. Notodiputro, and B. Sartono, "A comparative study of Random Forest and Double Random Forest models from view points of their interpretability," *Sci. J. Informatics*, vol. 11, no. 1, pp. 207–218, 2024, doi: 10.15294/sji.v11i1.48721.
- [6] S. A. S. S., S. Surono, and A. Thobirin, "Evaluation of hybrid KNN-Naïve Bayes model using cross validation for weather prediction," *JST (Jurnal Sains Dan Teknologi)*, vol. 14, no. 3, pp. 555–565, 2025, doi: 10.23887/jst-undiksha.v14i3.91956.
- [7] A. M. Siregar, S. Faisal, Y. Cahyana, and B. Priyatna, "Perbandingan algoritme klasifikasi untuk prediksi cuaca," *J. Account. Inf. Syst.*, vol. 3, no. 1, pp. 15–24, 2020, doi: 10.32627/aims.v3i1.280.
- [8] A. Prasetyo, "Pemanfaatan algoritma Decision Tree C4.5 dalam memprakirakan hujan

- di Stasiun Meteorologi Kelas I Sultan Hasanuddin,” *Bul. GAW Bariri*, vol. 5, no. 1, pp. 47–55, 2024, doi: 10.31172/bgb.v5i1.120.
- [9] A. N. Najah, A. N. Amalina, and R. Hidayat, “Penerapan algoritma Decision Tree C4.5 untuk prediksi cuaca di Kota Semarang,” *Indexia*, vol. 7, no. 1, pp. 46–52, 2025, doi: 10.30587/indexia.v7i1.9344.
- [10] S. Kim and E. Park, “Prediction of flight departure delays caused by weather conditions adopting data-driven approaches,” *J. Big Data*, vol. 11, no. 1, Art. no. 11, 2024, doi: 10.1186/s40537-023-00867-5.
- [11] Badan Meteorologi, Klimatologi, dan Geofisika, “Data Online,” Direktorat Data dan Komputasi BMKG. [Online]. Available: <https://dataonline.bmkg.go.id/dataonline-home> (Accessed May 15, 2026).
- [12] Badan Meteorologi, Klimatologi, dan Geofisika, Stasiun Meteorologi H. Asan Kotawaringin Timur, “Buletin Meteorologi: Edisi Juli 2025,” Sampit, Indonesia, Jul. 2025.
- [13] Kementerian Perhubungan Republik Indonesia, “Peraturan Menteri Perhubungan Nomor PM 80 Tahun 2011 tentang Perubahan Ketiga atas Keputusan Menteri Perhubungan Nomor KM 41 Tahun 2001 tentang Peraturan Umum Pengoperasian Pesawat Udara (General Operating and Flight Rules),” Jakarta, Indonesia, 2011.
- [14] International Civil Aviation Organization, *Annex 3 to the Convention on International Civil Aviation: Meteorological Service for International Air Navigation*, 20th ed., ICAO, 2018.
- [15] International Civil Aviation Organization, *Safety Management Manual (SMM)*, Doc 9859, 4th ed., ICAO, 2018.
- [16] W. Chen, K. Yang, Z. Yu, Y. Shi, and C. L. P. Chen, “A survey on imbalanced learning: Latest research, applications and future directions,” *Artif. Intell. Rev.*, vol. 57, Art. no. 137, 2024, doi: 10.1007/s10462-024-10759-6.
- [17] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic minority over-sampling technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002, doi: 10.1613/jair.953.
- [18] J. R. Quinlan, *C4.5: Programs for Machine Learning*. San Mateo, CA, USA: Morgan Kaufmann, 1993, doi: 10.1016/C2009-0-27846-9.
- [19] S. S. Mullick, S. Datta, S. G. Dhekane, and S. Das, “Appropriateness of performance indices for imbalanced data classification: An analysis,” *Pattern Recognit.*, vol. 102, Art. no. 107197, 2020, doi: 10.1016/j.patcog.2020.107197.
- [20] M. Romadoni and H. Akhsan, “Karakteristik iklim di Kota Palembang serta implikasinya terhadap bencana kabut asap,” *JIPFRI (Jurnal Inov. Pendidik. Fis. dan Ris. Ilmiah)*, vol. 6, no. 2, pp. 60–66, 2022, doi: 10.30599/jipfri.v6i2.1541.
- [21] W. Mardiansyah, D. Setiabudidaya, M. Y. N. Khakim, I. Yustian, Z. Dahlan, and I. Iskandar, “On the influence of ENSO and IOD on rainfall variability over the Musi Basin, South Sumatra,” *Science and Technology Indonesia*, vol. 3, no. 4, pp. 157–163, 2018, doi: 10.26554/sti.2018.3.4.157-163.
- [22] R. Muharomah and B. I. Setiawan, “Identification of climate trends and patterns in South Sumatra,” *Agromet*, vol. 36, no. 2, pp. 79–87, 2022, doi: 10.29244/j.agromet.36.2.79-87.
- [23] Stasiun Klimatologi Sumatera Selatan, Badan Meteorologi, Klimatologi, dan Geofisika, “Prediksi musim hujan tahun 2025/2026,” Sep. 19, 2025. [Online]. Available: <https://staklim-sumsel.bmkg.go.id/prediksi-musim-hujan-tahun-2025-2026/>. (Accessed: May 23, 2026).
- [24] Stasiun Klimatologi Sumatera Selatan, Badan Meteorologi, Klimatologi, dan Geofisika, “Distribusi curah hujan bulan Desember tahun 2025,” Jan. 5, 2026. [Online]. Available:

- <https://staklim-sumsel.bmkg.go.id/distribusi-curah-hujan-bulan-desember-tahun-2025/>. (Accessed: May 23, 2026).
- [25] M. A. Rahman, M. N. Y. Ali, F. T. Johora, A. A. Khan, and M. N. Huda, “Securing aviation networks: A generalized and robust machine learning solution for monitoring abnormalities in commercial aircraft,” *Results Eng.*, vol. 29, Art. no. 108884, 2025, doi: 10.1016/j.rineng.2025.108884.
- [26] K. J. Ruskin and A. C. Ruskin, “Validation of a new method for designing air traffic control alarms,” *Transp. Res. Interdiscip. Perspect.*, vol. 22, Art. no. 100965, 2023, doi: 10.1016/j.trip.2023.100965.
- [27] C. D. Wickens and A. Colcombe, “Dual-task performance consequences of imperfect alerting associated with a cockpit display of traffic information,” *Hum. Factors*, vol. 49, no. 5, pp. 839–850, 2007, doi: 10.1518/001872007X230217.