

EVALUASI PERFORMA RANDOM FOREST DALAM PREDIKSI THUNDERSTORM BERBASIS INDEKS LABILITAS ATMOSFER DI CILACAP

Cahya Sugiarto¹, Resti Maulina C C², Yosafat Donni Haryanto³

^{1, 2, 3}Program Studi Meteorologi, Sekolah Tinggi Meteorologi Klimatologi Dan Geofisika
Jl. Meteorologi No. 5, Kec. Tanah Tinggi, Kota Tangerang, 15119, Banten

cahyasugiarto11@gmail.com¹, fyim0382@gmail.com², yosafatdonni@gmail.com³

Abstrak

Thunderstorm (TS) merupakan salah satu fenomena cuaca signifikan yang berpotensi menimbulkan dampak hidrometeorologi, sehingga diperlukan pendekatan prediktif berbasis parameter udara atas untuk meningkatkan upaya mitigasi. Penelitian ini bertujuan membangun model prediksi kejadian TS di wilayah Cilacap menggunakan indeks labilitas atmosfer yang dihitung dari data radiosonde serta observasi cuaca permukaan. Dataset mencakup periode 2020–2024 dan terdiri dari lima indeks labilitas atmosfer, yaitu Showalter Index (SI), Lifted Index (LI), K-Index (KI), Totals Totals Index (TT), dan Convective Available Potential Energy (CAPE), yang dipadukan dengan data *present weather* untuk menentukan label kejadian TS. Model Random Forest Classifier digunakan dengan pembagian data latih dan uji sebesar 7:3, serta pengaturan *class weight* = 'balanced' untuk menangani ketidakseimbangan kelas. Hasil evaluasi menunjukkan akurasi sebesar 79% dan nilai Area Under Curve (AUC) sebesar 0.74 yang mengindikasikan kemampuan diskriminasi model berada pada kategori cukup baik. Analisis *feature importance* menunjukkan bahwa KI merupakan prediktor paling dominan, diikuti TT, SI, dan LI, sedangkan CAPE memberikan kontribusi terendah. Temuan ini menunjukkan bahwa pemodelan kejadian thunderstorm berbasis indeks labilitas atmosfer menggunakan algoritma Random Forest memiliki potensi diterapkan sebagai pendekatan prediktif pada wilayah Cilacap.

Kata kunci: indeks labilitas atmosfer, machine learning, prediksi cuaca, Random Forest, thunderstorm.

Abstract

Thunderstorms (TS) are significant weather phenomena that pose hydrometeorological risks, making predictive approaches based on upper-air parameters essential to support mitigation efforts. This study aimed to develop a TS prediction model for the Cilacap region by utilizing atmospheric instability indices derived from radiosonde data and surface weather observations. The dataset covers the period 2020 to 2024 and consists of five atmospheric instability indices, namely the Showalter Index (SI), the Lifted Index (LI), the K Index (KI), the Totals Totals Index (TT), and Convective Available Potential Energy (CAPE). These variables were combined with the present weather observations to determine the TS occurrence labels. A Random Forest Classifier was used with a 7 to 3 train and test split, and the class weight parameter was set to 'balanced' to address class imbalance. Model evaluation resulted in an accuracy of 79 percent and an Area Under Curve (AUC) value of 0.74, indicating a reasonably good level of discriminatory capability. Feature importance analysis showed KI to be the most dominant predictor, followed by TT, SI, and LI, whereas CAPE contributed the least. These findings indicate that thunderstorm prediction based on atmospheric instability indices using the Random Forest algorithm has promising potential for application as a predictive approach in the Cilacap region.

Keywords: atmospheric instability indices, machine learning, Random Forest, thunderstorm, weather prediction

I. PENDAHULUAN

Thunderstorm (TS) merupakan salah satu fenomena cuaca ekstrem yang kerap terjadi di Indonesia dan dapat menimbulkan berbagai dampak signifikan, seperti hujan berintensitas tinggi, sambaran petir, dan angin kencang yang berpotensi mengganggu aktivitas masyarakat maupun merusak

infrastruktur [1]. Fenomena ini dicirikan oleh pertumbuhan awan konvektif kuat dari awan cumulonimbus (Cb) yang disertai terjadinya guntur, kilat, hingga sambaran petir [2]. Oleh karena itu, pemantauan dan prediksi dini terhadap fenomena ini sangat penting dalam upaya mitigasi risiko bencana hidrometeorologi.

Pembentukan TS sangat dipengaruhi oleh tingkat ketidakstabilan atmosfer, yaitu kondisi ketika udara di lapisan bawah lebih hangat dan ringan dibandingkan lapisan di atasnya sehingga mudah terangkat dan memicu terbentuknya awan konvektif [3]. Tingkat ketidakstabilan ini dapat dievaluasi menggunakan data udara atas dari radiosonde yang menghasilkan sejumlah indeks labilitas atmosfer, seperti K-Index (KI), Lifted Index (LI), Showalter Index (SI), Total Totals Index (TT), dan Convective Available Potential Energy (CAPE) [4]. Indeks Labilitas atmosfer ini telah banyak digunakan dalam penilaian potensi konveksi dan kejadian TS [2], [5].

Berbagai penelitian sebelumnya telah mengevaluasi nilai ambang batas berbagai indeks labilitas atmosfer terhadap kejadian hujan lebat maupun TS di berbagai wilayah Indonesia seperti di Jawa, Sumatra, dan Sulawesi [4], [6], [7]. Namun, nilai ambang tersebut tidak dapat digunakan secara universal karena kondisi atmosfer dipengaruhi oleh perbedaan karakteristik atmosfer lokal, topografi, dan iklim [8]. Oleh karena itu, pendekatan berbasis ambang batas tetap memiliki keterbatasan dalam memprediksi TS secara lebih akurat untuk wilayah lain [2]. Variasi tersebut menyebabkan nilai ambang batas indeks yang efektif di satu wilayah belum tentu relevan ketika diterapkan di wilayah lain termasuk di wilayah Cilacap.


Perbedaan karakteristik ini menimbulkan kebutuhan akan metode prediksi yang lebih adaptif salah satunya dengan pendekatan berbasis pembelajaran pola dari data. Berkembangnya metode machine learning membuka peluang untuk mengoptimalkan prediksi kejadian thunderstorm melalui pendekatan berbasis pembelajaran data. Beberapa penelitian telah menggunakan machine learning dalam memprediksi potensi pembentukan awan CB dan kejadian thunderstorm di Indonesia [4], [5], [9]. Sejalan dengan perkembangan tersebut, penelitian ini menggunakan algoritma Random Forest untuk memprediksi kejadian TS berdasarkan indeks labilitas atmosfer dari radiosonde Stasiun Meteorologi Tunggul Wulung Cilacap.

Tujuan penelitian ini adalah membangun model prediksi thunderstorm menggunakan Random Forest Classifier berbasis indeks labilitas atmosfer, serta mengevaluasi kinerjanya menggunakan metrik evaluasi seperti Confusion Matrix dan ROC-AUC untuk menilai kemampuan model dalam membedakan kejadian TS dan tidak TS di wilayah Cilacap.

II. METODOLOGI PENELITIAN

Bagian ini menjelaskan tahapan penelitian yang dilakukan berdasarkan diagram alir pada Gambar 1,

yang menggambarkan alur proses mulai dari pengumpulan data, preprocessing data, pelatihan model Random Forest, hingga evaluasi model dan analisis *feature importance* sebelum diperoleh kesimpulan akhir. Setiap tahap dirancang untuk memastikan bahwa data yang digunakan bersih, terstruktur, dan siap untuk proses pemodelan. Seluruh proses pengolahan dan *preprocessing data* dilaksanakan menggunakan bahasa pemrograman Python melalui platform Google Colab.



Gambar 1. Diagram alir penelitian

A. Pengumpulan Data

1) Data indeks labilitas atmosfer

Data indeks labilitas atmosfer pada penelitian ini diperoleh dari hasil pengamatan radiosonde di Stasiun Meteorologi Kelas III Tunggul Wulung Cilacap selama lima tahun, yakni dari 1 Januari 2020 hingga 31 Desember 2024, yang diunduh melalui laman Upper-Air Sounding pada situs <https://weather.uwyo.edu/upperair/sounding.shtml>.

Dalam penelitian ini digunakan data radiosonde pada pukul 00.00 UTC dengan validitas data hingga 12 jam ke depan.

Indeks labilitas yang digunakan meliputi parameter yang umum dipakai dalam kajian konveksi dan thunderstorm. K-Index (KI) digunakan untuk mengukur potensi konveksi berdasarkan profil suhu dan kelembapan lapisan bawah hingga menengah atmosfer. Semakin besar nilai KI, semakin besar potensi terjadinya konveksi dan pertumbuhan awan Cb, sedangkan nilai KI yang rendah mengindikasikan atmosfer cenderung stabil dan kurang mendukung pembentukan TS. Lifted Index (LI) menunjukkan tingkat kestabilan atmosfer dengan mengangkat parsel udara dari permukaan hingga 500 mb, nilai negatif menandakan atmosfer yang sangat labil. Semakin negatif nilai LI, semakin kuat peluang konveksi, sedangkan nilai LI yang positif menunjukkan atmosfer lebih stabil. Showalter Index (SI) memperkirakan potensi konveksi di lapisan menengah dengan mengangkat parsel dari 850 mb. Nilai SI yang semakin kecil menandakan atmosfer yang lebih labil, sedangkan nilai positif menunjukkan konveksi yang lemah atau tidak signifikan. Totals Totals (TT) merupakan gabungan dari Vertical Totals dan Cross Totals yang menggambarkan kontras suhu–kelembapan antara 850 mb dan 500 mb, dan digunakan untuk mengidentifikasi peluang TS. Semakin tinggi nilai TT, semakin besar potensi terjadinya TS. Sementara itu, CAPE (Convective

Available Potential Energy) mengukur energi yang tersedia untuk menghasilkan *updraft* konvektif; nilai besar menunjukkan potensi kuat untuk pembentukan awan Cb. Semakin tinggi nilai CAPE, semakin besar peluang terjadinya konveksi kuat, hujan lebat, dan TS, sedangkan nilai CAPE yang rendah menandakan energi konveksi yang sangat lemah.

2) Data observasi cuaca permukaan

Data observasi cuaca permukaan berupa sandi sinoptik (SYNOP) dari Stasiun Meteorologi Kelas III Tunggul Wulung Cilacap digunakan sebagai acuan kondisi cuaca aktual. Analisis dilakukan pada variabel *present weather* (7wwW1W2), khususnya kode ww, yang menunjukkan fenomena cuaca yang sedang terjadi. Penentuan kejadian thunderstorm dilakukan dengan menyesuaikan jam kejadian pada data SYNOP dengan periode validitas radiosonde, yaitu dari 00 UTC hingga 12 UTC. Dengan demikian, kejadian TS atau tidak TS hanya ditentukan berdasarkan kondisi cuaca aktual yang terjadi dalam rentang waktu yang sesuai dengan kondisi atmosfer yang direpresentasikan oleh data radiosonde 00 UTC. Daftar sandi *present weather* yang digunakan sebagai acuan penentuan kejadian TS ditunjukkan pada Tabel 1 berikut.

Tabel 1. Sandi *present weather* (ww) yang digunakan dalam penentuan kejadian thunderstorm

Sandi	Keterangan
17	Badai guntur tanpa presipitasi
29	Badai guntur (dengan atau tanpa presipitasi)
91	Hujan ringan (badai guntur pada pengamatan sebelumnya, tetapi tidak terjadi saat pengamatan)
92	Hujan sedang atau lebat (badai guntur pada pengamatan sebelumnya, tetapi tidak terjadi saat pengamatan)
93	Badai guntur ringan atau sedang, tanpa disertai hail, tetapi disertai hujan dan atau salju pada saat pengamatan
94	Badai guntur sedang atau hebat disertai hail dan atau hujan dan salju
95	Badai guntur sedang, tanpa disertai hail dengan hujan atau hujan dan salju atau hanya salju
96	Badai guntur ringan atau sedang, disertai hail pada saat pengamatan
97	Badai guntur hebat tanpa disertai hail dengan hujan atau hujan dan salju atau hanya salju
98	Badai guntur disertai badai debu
99	Badai guntur hebat disertai hail

Kedua kelompok data tersebut selanjutnya digabungkan ke dalam satu file excel sebagai *dataset* untuk pemodelan. Penggabungan dilakukan dengan mencocokkan waktu validitas data sehingga setiap nilai indeks labilitas atmosfer dapat dipasangkan


secara tepat dengan kondisi cuaca aktual pada rentang waktu yang sama.

B. Preprocessing Data

Pada tahap pengolahan data dilakukan tahap preprocessing data untuk menyiapkan dataset sebelum memasuki proses pemodelan. Baris data yang memiliki nilai kosong (missing values) dihapus untuk memastikan kualitas dan konsistensi dataset. Selanjutnya, dataset dipisahkan menjadi dua komponen utama, yaitu prediktor yang terdiri dari indeks labilitas atmosfer (KI, LI, SI, TT, dan CAPE) serta prediktor berupa label kejadian thunderstorm (TS/Tidak TS). Setelah pemisahan variabel dilakukan, dataset dibagi menjadi data latih (training data) dan data uji (testing data) dengan rasio 7:3. Dalam penelitian terkait performa data splitting menggunakan machine learning di Vietnam menunjukkan bahwa kemampuan prediksi model sangat dipengaruhi oleh rasio training dan testing dimana model memiliki performa prediksi terbaik dengan rasio 7:3 [10]. *Dataset* yang telah dilakukan splitting lebih lanjut akan digunakan ke dalam pemodelan random forest classifier.

C. Pelatihan Model

Model prediksi yang digunakan dalam penelitian ini adalah Random Forest Classifier. Random Forest Classifier merupakan algoritma *ensemble learning* berbasis *bagging* yang menggabungkan banyak pohon keputusan (*decision trees*) untuk meningkatkan akurasi dan stabilitas prediksi [11]. Setiap pohon pada Random Forest dilatih menggunakan sampel data yang dipilih secara acak melalui teknik *bootstrap sampling*, sementara pemilihan variabel pada setiap pemisahan node juga dilakukan secara acak.



Gambar 2. Algoritma random forest [12]

D. Evaluasi Model

Tahapan analisis berupa evaluasi model dan analisis *feature importance*. Evaluasi model dilakukan untuk menilai kinerja Random Forest Classifier dalam memprediksi kejadian thunderstorm berdasarkan indeks labilitas atmosfer. Metrik utama yang digunakan adalah Confusion Matrix, yang menggambarkan jumlah true positive (TP), true

negative (TN), false positive (FP), dan false negative (FN), sehingga memungkinkan penghitungan ukuran performa seperti akurasi, presisi, recall, dan F1-Score [13].

Tabel 2. Confusion Matrix

		Prediksi	
		Negatif	Positif
Aktual	Negatif	TN	FP
	Positif	FN	TP

1) Akurasi

Akurasi menggambarkan proporsi keseluruhan prediksi yang benar dibandingkan dengan seluruh sampel data.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

2) Presisi

Presisi mengukur tingkat ketepatan prediksi positif model, yaitu seberapa besar bagian dari prediksi TS yang benar-benar merupakan kejadian TS.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

3) Recall

Recall atau sensitivitas menunjukkan kemampuan model dalam menangkap seluruh kejadian TS yang sebenarnya terjadi.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

4) F1-Score

F1-score merupakan harmonisasi antara presisi dan recall.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Selain itu, penelitian ini menggunakan Receiver Operating Characteristic – Area Under the Curve (ROC–AUC) untuk menilai kemampuan model dalam membedakan kelas TS dan Tidak TS. ROC adalah kurva yang menggambarkan kemampuan model klasifikasi dalam membedakan antara dua kelas pada berbagai nilai ambang (*threshold*). Sedangkan AUC adalah nilai yang menunjukkan luas area di bawah kurva ROC. Kurva ROC membandingkan True Positive Rate (TPR) dengan False Positive Rate (FPR) untuk setiap nilai ambang probabilitas. ROC dibangun dari dua komponen utama, yaitu:

$$TPR = \frac{TP}{TP + FN} \quad (5)$$

$$FPR = \frac{FP}{FP + TN} \quad (6)$$

Kemudian, analisis *feature importance* digunakan untuk menentukan kontribusi relatif dari tiap indeks labilitas atmosfer dalam proses klasifikasi. *Feature importance* adalah ukuran yang menunjukkan kontribusi relatif masing-masing variabel prediktor dalam menentukan hasil prediksi model [14]. Nilai *importance* dihitung berdasarkan seberapa besar suatu fitur mengurangi *impurity* (ketidakteraturan data) saat digunakan sebagai pemilah (*split*) pada setiap node pohon keputusan sehingga memberikan gambaran fitur mana yang paling berpengaruh dalam memprediksi potensi thunderstorm.

III. HASIL PENELITIAN

A. Deskripsi Data

Data penelitian ini merupakan hasil penggabungan antara data indeks labilitas atmosfer dari radiosonde dan data observasi cuaca permukaan berdasarkan sandi present weather (ww). Dataset mencakup periode lima tahun, mulai 1 Januari 2020 hingga 31 Desember 2024, dengan waktu pengamatan radiosonde pada 00 UTC. Setiap entri data berisi nilai indeks labilitas atmosfer diantaranya Showalter Index (SI), Lifted Index (LI), K-Index (KI), Totals Totals Index (TT), dan CAPE, serta label kejadian thunderstorm (TS/TIDAK) yang ditentukan berdasarkan kesesuaian waktu validitas data radiosonde dengan observasi permukaan yaitu antara 00–12 UTC. Berdasarkan pengolahan dataset, baris data setelah dilakukan pembersihan data kosong berkurang dari 1827 menjadi 1467, yang terdiri dari 1167 kejadian Tidak TS dan 300 kejadian TS. Seluruh variabel ini kemudian disusun ke dalam satu tabel terstruktur sehingga membentuk *dataset* terstruktur yang digunakan untuk pelatihan dan evaluasi model Random Forest.

Tabel 3. Sampel dataset penelitian

Waktu	SI	LI	KI	TT	CAPE	TS / No TS
2020/01/01 00Z	-2,6	- 3,6	39,6	46,6	878,5	TS
2020/01/02 00Z	0,6	- 1,4	34,6	42	574	TS
2020/01/03 00Z	0,4	- 0,6	34,6	41	811,4	TIDAK
...	...	...	...	...	...	...
2024/12/29 00Z	2,7	- 3,1	35,9	40	1808,2	TIDAK
2024/12/30 00Z	0,4	- 2,8	36,4	41,4	1348,8	TIDAK
2024/12/31 00Z	3,2	0,4	32,2	38,3	65,62	TIDAK

B. Pelatihan Model

Pemodelan dilakukan menggunakan algoritma Random Forest Classifier yang dilatih pada data indeks labilitas atmosfer dan label kejadian TS hasil tahap *preprocessing data*. *Dataset* dibagi menjadi data latih dan data uji dengan rasio 7:3 menggunakan fungsi *train_test_split*. Argumen *stratify* = *Y* digunakan untuk memastikan bahwa proporsi kelas TS dan Tidak TS tetap seimbang pada kedua subset data, sehingga distribusi kelas minoritas tidak semakin timpang selama proses pelatihan model maupun pengujian model. Parameter *random_state* = 42 digunakan untuk menjaga reproduktibilitas hasil pemodelan. Proses pelatihan dilakukan menggunakan konfigurasi parameter *default* dari Random Forest dengan penyesuaian pada parameter *class_weight* = 'balanced', yang berfungsi memberikan bobot lebih besar pada kelas minoritas (TS) agar model dapat mempelajari karakteristiknya secara lebih efektif. Seluruh pengaturan parameter model disajikan pada Tabel 4 berikut.

Tabel 4. Pengaturan parameter

Parameter	Konfigurasi
<i>stratify</i>	<i>Y</i>
<i>random_state</i>	42
<i>class_weight</i>	'balanced'
<i>n_estimators</i>	100
<i>max_depth</i>	none
<i>min_samples_split</i>	2
<i>min_samples_leaf</i>	1
<i>criterion</i>	'gini'
<i>bootstrap</i>	True


C. Evaluasi Hasil

Evaluasi performa Random Forest Classifier dilakukan menggunakan data uji dengan berbagai metrik, yakni presisi, *recall*, F1-score, akurasi, Confusion Matrix, dan kurva ROC-AUC. Hasil classification report pada Tabel 5 menunjukkan bahwa model memiliki akurasi keseluruhan sebesar 0.79, yang berarti model secara umum mampu memberikan prediksi yang cukup baik. Pada kelas Tidak TS, model mencapai presisi tinggi sebesar 0.81, *recall* 0.95, dan F1-score 0.88, hal ini menandakan bahwa model sangat efektif dalam mengidentifikasi hari tanpa kejadian thunderstorm. Namun, performa model untuk kelas TS lebih rendah, ditunjukkan oleh presisi 0.44, *recall* 0.16, dan F1-score 0.23. Nilai *recall* yang rendah menunjukkan bahwa model masih sering gagal mendeteksi kejadian TS, hal ini dapat disebabkan oleh ketidakseimbangan *dataset* di mana frekuensi kejadian TS lebih sedikit dibandingkan kondisi tidak terjadi TS.


Tabel 5. Classification Report

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
TIDAK TS	0.81	0.95	0.88
TS	0.44	0.16	0.23
<i>Accuracy</i>			0.79
<i>Macro avg</i>	0.63	0.55	0.55
<i>Weighted avg</i>	0.74	0.79	0.74

Berdasarkan hasil confusion matrix pada gambar 3, model berhasil mengidentifikasi 333 kasus tanpa kejadian thunderstorm (*True Negative*) dengan benar, sementara 18 kasus tanpa thunderstorm salah diklasifikasikan sebagai TS (*False Positive*). Untuk kejadian thunderstorm, model hanya mampu mendeteksi 14 kasus secara benar (*True Positive*), sedangkan 76 kasus lainnya justru salah diprediksi sebagai tidak terjadi TS (*False Negative*). Tingginya jumlah false negative ini menunjukkan bahwa model masih mengalami kesulitan dalam mengenali kejadian thunderstorm, yang secara alami merupakan kelas minoritas pada *dataset*. Meski demikian, jumlah *false positive* relatif rendah, sehingga model tidak terlalu sering memberikan prediksi TS yang keliru atau memicu alarm palsu.



Gambar 3. Confusion Matrix




Gambar 3. Kurva ROC

Kurva ROC yang dihasilkan menunjukkan nilai $AUC = 0.74$ yang mengindikasikan bahwa model memiliki kemampuan diskriminatif yang cukup baik dalam membedakan antara kejadian TS dan Tidak TS. Nilai AUC di atas 0.7 termasuk kategori *fair classification*, sehingga meskipun model kesulitan pada kelas minoritas, kemampuan globalnya untuk membedakan dua kelas tetap memadai. Kurva ROC menunjukkan bahwa model masih mampu mencapai *true positive rate* yang cukup baik pada tingkat *false positive rate* tertentu.

Tabel 6. Interpretasi nilai AUC [15]

Nilai AUC	Keterangan
0.90 – 1.00	<i>Excellent classification</i>
0.80 – 0.90	<i>Good classification</i>
0.70 – 0.80	<i>Fair classification</i>
0.60 – 0.70	<i>Poor classification</i>
0.50 – 0.60	<i>Failure classification</i>



Gambar 3. Feature importance

Berdasarkan hasil *feature importance* dari model Random Forest yang telah dilatih, variabel yang paling berpengaruh dalam memprediksi kejadian thunderstorm adalah K-Index (KI), yang menunjukkan bahwa kombinasi suhu dan kelembapan pada lapisan bawah hingga menengah atmosfer menjadi indikator utama dalam potensi terjadinya TS. Indeks berikutnya yang juga memberikan kontribusi signifikan adalah Totals Totals Index (TT), Showalter Index (SI), dan Lifted Index (LI), yang secara relatif menunjukkan tingkat kepentingan hampir setara dalam mendukung identifikasi potensi terjadinya TS. Sementara itu, CAPE memiliki pengaruh terendah, meskipun tetap relevan sebagai indikator energi konvektif, namun kontribusinya lebih kecil dalam menentukan kejadian TS dan Tidak TS.

D. Diskusi

Hasil penelitian menunjukkan bahwa model Random Forest mampu mengklasifikasikan kejadian thunderstorm (TS) berdasarkan indeks labilitas atmosfer dengan akurasi yang cukup baik, yaitu sebesar 79%. Namun demikian, hasil evaluasi juga mengungkapkan tantangan signifikan dalam mendeteksi kelas TS, yang tercermin dari nilai *recall*

yang rendah pada kelas tersebut serta tingginya jumlah *false negative*. Kondisi ini terutama dipengaruhi oleh ketidakseimbangan kelas pada *dataset*, di mana kejadian TS jauh lebih sedikit dibandingkan kejadian tidak TS. Ketidakseimbangan ini dapat menyebabkan model lebih cenderung memprediksi kelas mayoritas, sehingga kesulitan mendeteksi kejadian TS.

Hasil *feature importance* menunjukkan bahwa K-Index (KI) merupakan prediktor utama, diikuti oleh Totals Totals Index (TT), Showalter Index (SI), dan Lifted Index (LI). Hal ini menunjukkan bahwa ketidakstabilan lapisan bawah hingga menengah atmosfer memberikan kontribusi besar terhadap perkembangan awan konvektif pemicu fenomena cuaca thunderstorm. Sementara itu, CAPE memiliki pengaruh yang lebih rendah. Hal ini sejalan dengan penelitian oleh Kusumawardani dan Azani (2022) yang menyebutkan bahwa CAPE kurang efektif dalam merepresentasikan potensi kejadian hujan lebat maupun cuaca buruk.

Evaluasi model melalui kurva ROC menghasilkan nilai AUC sebesar 0.74, yang mengindikasikan kemampuan diskriminasi model berada pada kategori cukup baik. Namun rendahnya nilai *recall* dan tingginya *false negative* menunjukkan perlunya peningkatan model, terutama dalam mendeteksi kejadian TS yang jumlahnya terbatas.

Penelitian lanjutan dapat mempertimbangkan beberapa langkah untuk meningkatkan kinerja model. Pertama, penambahan data indeks labilitas atmosfer dari radiosonde pukul 12 UTC serta observasi cuaca permukaan selama 24 jam penuh. Integrasi kedua waktu pengamatan ini memungkinkan pembangunan model prediksi yang berlaku sepanjang hari, sehingga meningkatkan relevansi operasional model dalam mendukung prakiraan dan peringatan dini kejadian thunderstorm. Kedua, penambahan prediktor parameter dinamika atmosfer lainnya yang berpotensi meningkatkan sensitivitas model. Ketiga, memperluas rentang data lebih dari lima tahun dapat memberikan variasi atmosfer yang lebih beragam, sehingga model memiliki kemampuan generalisasi yang lebih baik. Keempat, penggunaan metode penyeimbangan data seperti SMOTE atau ADASYN dapat dicoba dengan penyesuaian parameter agar tidak menurunkan performa model.

Secara keseluruhan, penelitian ini menunjukkan bahwa pemodelan kejadian thunderstorm berbasis indeks labilitas atmosfer menggunakan algoritma Random Forest memiliki potensi diterapkan sebagai pendekatan prediktif pada wilayah Cilacap. Temuan yang diperoleh menunjukkan bahwa model mampu memberikan performa klasifikasi yang cukup baik, namun pengembangan lebih lanjut masih diperlukan agar kinerjanya semakin optimal. Upaya perbaikan

dapat dilakukan melalui penambahan variabel prediktor data cuaca, serta perluasan rentang *dataset* untuk meningkatkan kemampuan generalisasi, serta optimalisasi algoritma sehingga model dapat diterapkan secara lebih efektif dan akurat dalam mendukung sistem peringatan dini cuaca ekstrem.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model Random Forest mampu memprediksi kejadian thunderstorm (TS) berdasarkan indeks labilitas atmosfer dengan akurasi sebesar 79% dan nilai AUC 0.74. Meskipun demikian, performa model masih terbatas dalam mendeteksi kelas TS yang jumlahnya relatif sedikit, yang tercermin dari nilai *recall* yang rendah. Hasil *feature importance* mengindikasikan bahwa K-Index merupakan prediktor paling dominan, diikuti oleh TT, SI, dan LI, sementara CAPE memberikan kontribusi paling kecil. Temuan ini menegaskan bahwa model Random Forest dapat digunakan sebagai dasar dalam pemodelan prediksi kejadian TS, namun peningkatan kinerja model tetap diperlukan melalui penambahan variabel prediktor, serta perluasan rentang data yang digunakan. Secara keseluruhan, penelitian ini mampu memberikan kontribusi awal yang dapat mendukung pengembangan sistem peringatan dini cuaca ekstrem di wilayah Cilacap.

REFERENSI

- [1] H. Ismanto and H. N. Mahron, "ANALISIS ANGIN KENCANG DARI AWAN CUMULONIMBUS DENGAN WRF-ARW: STUDI KASUS DAERAH ISTIMEWA YOGYAKARTA FEBRUARI 2020," 2023.
- [2] A. A. Rusdin, P. Palloan, S. Subaer, and A. Prasetyo, "Uji Akurasi Ambang Batas Indeks Stabilitas Atmosfer Terhadap Pembentukan Thunderstorm dan Awan Cumulonimbus di Stasiun Meteorologi Kelas I Sultan Hasanuddin," *JFU*, vol. 12, no. 2, pp. 269–275, Apr. 2023, doi: 10.25077/jfu.12.2.268-274.2023.
- [3] W. Suryanto and Alusyah Luthfian, *Pengantar Meteorologi*. Ugm Press, 2019.
- [4] R. M. Putra *et al.*, "Cumulonimbus cloud prediction based on machine learning approach using radiosonde data in Surabaya, Indonesia," *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 724, no. 1, p. 012047, Apr. 2021, doi: 10.1088/1755-1315/724/1/012047.
- [5] I. Prawiro Adiredjo, "PREDIKSI KEJADIAN PETIR DENGAN ARTIFICIAL NEURAL NETWORK DI WILAYAH KABUPATEN KEPULAUAN TANIMBAR," *Bulletin of Meteorology, Climatology, Air Quality, Geophysics, and Environment*, vol. 14, no. 2, pp. 32–38, Feb. 2024, doi: 10.46824/megasains.v14i2.140.
- [6] I. J. A. Saragih, B. W. Yonas, and N. Rinaldy, "UJI AMBANG BATAS BARU INDEKS TOTAL-TOTAL UNTUK PRAKIRAAN KEJADIAN AWAN CUMULONIMBUS DAN THUNDERSTORM DI BANDARA KUALANAMU".
- [7] A. A. Azani and N. Kusumawardani, "KAJIAN INDEKS STABILITAS ATMOSFER TERHADAP KEJADIAN HUJAN LEBAT DI KOTA BITUNG," 2022.
- [8] B. Prasetyo, H. Irwandi, and N. Pusparini, "KARAKTERISTIK CURAH HUJAN BERDASARKAN RAGAM TOPOGRAFI DI SUMATERA UTARA," *JSTMC*, vol. 19, no. 1, p. 11, Dec. 2018, doi: 10.29122/jstmc.v19i1.2787.
- [9] M. Hermansyah, A. Saikhu, and B. Amaliah, "PEMODELAN DATA RADIOSONDE MENGGUNAKAN STACKING ENSEMBLE UNTUK KLASIFIKASI HUJAN," *jipi. jurnal. ilmiah. penelitian. dan. pembelajaran. informatika.*, vol. 10, no. 2, pp. 1678–1687, May 2025, doi: 10.29100/jipi.v10i2.7806.
- [10] Q. H. Nguyen *et al.*, "Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil," *Mathematical Problems in Engineering*, vol. 2021, pp. 1–15, Feb. 2021, doi: 10.1155/2021/4832864.
- [11] N. A. Prakoso Indaryono, "ANALISA PERBANDINGAN ALGORITMA RANDOM FOREST DAN NAÏVE BAYES UNTUK KLASIFIKASI CURAH HUJAN BERDASARKAN IKLIM DI INDONESIA," *jipi. jurnal. ilmiah. penelitian. dan. pembelajaran. informatika.*, vol. 9, no. 1, pp. 158–167, Feb. 2024, doi: 10.29100/jipi.v9i1.4421.
- [12] M. Fadli and R. A. Saputra, "KLASIFIKASI DAN EVALUASI PERFORMA MODEL RANDOM FOREST UNTUK PREDIKSI STROKE," vol. 12, no. 02, 2023.
- [13] H. Akbar and W. K. Sanjaya, "Kajian Performa Metode Class Weight Random Forest pada Klasifikasi Imbalance Data Kelas Curah Hujan," *SNATI*, vol. 3, no. 1, Dec. 2023, doi: 10.20885/snati.v3i1.30.
- [14] S. Fitriani, E. Budiman, M. Fadli, M. Surono, and H. Sulistiani, "Optimalisasi Metode Random Forest menggunakan Particle Swarm Optimization dalam Prediksi Prestasi Mahasiswa," vol. 3, no. 1, 2025.
- [15] "Analisis Perbandingan Algoritma KNN dan Naïve Bayes Dalam Mendiagnosis Penyakit Diabetes Mellitus," *jikstik*, vol. 23, no. 3, Sep. 2024, doi: 10.32409/jikstik.23.3.3617.