

## PREDIKSI KATEGORI CURAH HUJAN BERBASIS *MACHINE LEARNING* UNTUK MENDUKUNG KETAHANAN PANGAN

I Dewa Gede Loka Maheswara<sup>1</sup>; Kanaya Kaizzi Larasati<sup>2</sup>; Muhammad Nur Rizqi<sup>3</sup>; Muhammad Fany Nurwibowo<sup>4</sup>; Yosafat Donni Haryanto<sup>5\*</sup>

Program Studi Meteorologi<sup>1,2,3,4,5</sup>  
Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Kota Tangerang, Indonesia<sup>1,2,3,4,5</sup>  
[www.stmkg.ac.id](http://www.stmkg.ac.id)<sup>1,2,3,4,5</sup>  
[maheswaradewaloka@gmail.com](mailto:maheswaradewaloka@gmail.com)<sup>1</sup>, [kanayakaizzan@gmail.com](mailto:kanayakaizzan@gmail.com)<sup>2</sup>,  
[muhammadnurrizqi2004@gmail.com](mailto:muhammadnurrizqi2004@gmail.com)<sup>3</sup>, [mfanynurwibowo32@gmail.com](mailto:mfanynurwibowo32@gmail.com)<sup>4</sup>, [yosafat.haryanto@stmkg.ac.id](mailto:yosafat.haryanto@stmkg.ac.id)<sup>5\*</sup>

(\*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

**Abstract**— Rainfall variability significantly influences food security in Central Tapanuli Regency, North Sumatra, a region where agriculture is strongly reliant on climatic patterns. This research evaluates and compares the classification performance of Support Vector Machine (SVM), K-Nearest Neighbors (K-NN), and Random Forest (RF) for categorizing daily rainfall as supplementary information to strengthen food security. A total of 3,644 daily meteorological records obtained from FL Tobing Meteorological Station spanning 2015 to 2024 were utilized, encompassing seven predictor variables: minimum temperature, maximum temperature, average temperature, mean relative humidity, sunshine duration, peak wind speed, and average wind speed. To mitigate class imbalance, the original six rainfall categories were consolidated into four classes by merging the minority groups. The data were partitioned into training and testing subsets at an 80:20 ratio using stratified sampling, after which the Synthetic Minority Over-sampling Technique (SMOTE) was employed on the training set. Hyperparameter tuning was conducted through Grid Search combined with 5-fold cross-validation, and classification performance was assessed using accuracy, precision, recall, F1-score, and paired t-test analyses. The experimental results indicated that RF delivered superior performance, attaining an accuracy of 51.44% and a weighted F1-score of 0.5036, significantly outperforming both SVM and K-NN ( $p$ -value < 0.05). Feature importance analysis revealed that sunshine duration, average temperature, and maximum temperature were the most influential predictors. These outcomes demonstrate that RF holds considerable promise for advancing machine learning-driven rainfall category prediction systems capable of delivering early-stage information for agricultural planting schedules and preparedness against intense rainfall events in Central Tapanuli Regency.

**Keywords:** Food Security, K-Nearest Neighbors, Rainfall Category, Random Forest, Support Vector Machine

**Abstrak**— Variabilitas curah hujan secara signifikan berpengaruh terhadap ketahanan pangan di Kabupaten Tapanuli Tengah, Sumatera Utara, sebagai wilayah yang sektor pertaniannya sangat bergantung pada pola iklim. Penelitian ini mengevaluasi dan membandingkan performa klasifikasi *Support Vector Machine* (SVM), *K-Nearest Neighbors* (K-NN), dan *Random Forest* (RF) dalam mengkategorikan curah hujan harian sebagai informasi pendukung ketahanan pangan. Sebanyak 3.644 rekaman meteorologi harian dari Stasiun Meteorologi FL Tobing periode 2015–2024 dimanfaatkan, meliputi tujuh variabel prediktor: suhu minimum, suhu maksimum, suhu rata-rata, kelembapan relatif rata-rata, durasi penyinaran matahari, kecepatan angin tertinggi, dan kecepatan angin rata-rata. Untuk mengatasi ketidakseimbangan kelas, enam kategori curah hujan awal dikonsolidasikan menjadi empat kelas melalui penggabungan kelompok minoritas. Data dipartisi menjadi subset latih dan uji dengan rasio 80:20 secara berstrata, kemudian *Synthetic Minority Over-sampling Technique* (SMOTE) diterapkan pada data latih. Penyetelan hiperparameter dilaksanakan melalui *Grid Search* dengan validasi silang 5-fold, dan kinerja klasifikasi dinilai menggunakan akurasi, *precision*, *recall*, *F1-score*, serta uji *paired t-test*. Hasil eksperimen

mengindikasikan bahwa RF memberikan performa unggul dengan akurasi 51,44% dan *weighted F1-score* 0,5036, secara statistik berbeda signifikan dibandingkan SVM maupun K-NN ( $p\text{-value} < 0,05$ ). Analisis *feature importance* mengungkapkan bahwa durasi penyinaran matahari, suhu rata-rata, dan suhu maksimum merupakan prediktor paling berpengaruh. Temuan ini menunjukkan bahwa RF memiliki prospek menjanjikan untuk memajukan sistem prediksi kategori curah hujan berbasis machine learning guna menyediakan informasi dini bagi penjadwalan tanam dan kesiapsiagaan terhadap kejadian curah hujan intensif di Kabupaten Tapanuli Tengah.

**Kata kunci:** Ketahanan Pangan, K-Nearest Neighbors, Kategori Curah Hujan, Random Forest, Support Vector Machine.

## PENDAHULUAN

Kabupaten Tapanuli Tengah merupakan wilayah di Indonesia yang aktivitas pertaniannya sangat ditentukan oleh pola curah hujan, dengan komoditas utama berupa padi, kelapa, dan kakao (Rusmayadi et al., 2023). Fluktuasi curah hujan yang signifikan di kawasan ini berpotensi memicu kondisi kekeringan maupun penggenangan pada areal pertanian, yang pada akhirnya dapat menekan tingkat produktivitas dan mengancam kestabilan produksi pangan regional (Harvian & Yuhan, 2021; Ashari, 2023). Berdasarkan kondisi tersebut, ketersediaan prediksi kategori curah hujan yang tepat menjadi krusial guna menunjang perencanaan waktu tanam serta upaya mitigasi risiko kegagalan panen secara optimal. Kendati demikian, menghasilkan prediksi curah hujan yang tepat masih merupakan persoalan yang cukup menantang mengingat keterlibatan proses fisis yang rumit serta dampaknya yang meluas ke berbagai sektor (Nurhidayat et al., 2024). Teknik klasifikasi dalam *data mining* dapat dimanfaatkan untuk melakukan prediksi curah hujan (Pratama et al., 2022). Setiap algoritma yang digunakan dalam prediksi curah hujan dapat menghasilkan performa yang berbeda, bergantung pada ukuran dataset, jumlah data hilang, ketidakseimbangan kelas, serta parameter meteorologi yang digunakan. Dengan demikian, penentuan algoritma yang paling sesuai untuk prediksi curah hujan tetap menjadi isu terbuka dalam pengembangan model prediktif (Hapsari & Wisesa, 2025; Syahreza et al., 2024).

Berbagai penelitian terkait penerapan *machine learning* untuk klasifikasi curah hujan dan ketahanan pangan telah dilaksanakan di berbagai wilayah. Keunggulan kinerja SVM dibandingkan K-NN ditunjukkan oleh Sari et al. (2025) dalam pemodelan dampak perubahan iklim terhadap ketahanan pangan berbasis data cuaca *Seattle*. Pada pengujian tersebut, SVM menghasilkan akurasi sebesar 78%, sedangkan K-NN mencapai 74%. Berdasarkan hasil tersebut, penelitian ini juga mengemukakan potensi penggunaan metode *ensemble*, termasuk *Random Forest* (RF), sebagai pendekatan untuk memperoleh hasil prediksi yang

lebih akurat. Di wilayah lain, Aziza et al. (2024) menggunakan K-NN sebagai metode untuk mengelompokkan kondisi ketahanan pangan di Jawa Tengah. Selain itu, Egbunu et al. (2021) menggunakan RF untuk mengidentifikasi pengaruh berbagai faktor iklim terhadap ketahanan pangan di wilayah Nigeria dan menemukan bahwa curah hujan serta suhu merupakan faktor yang paling dominan.

Temuan-temuan dari studi tersebut mengindikasikan bahwa performa model klasifikasi curah hujan bergantung pada lokasi kajian, jumlah algoritma yang diperbandingkan, serta karakteristik data yang dianalisis. Penelitian Sari et al. (2025) belum menggunakan data observasi BMKG dari wilayah Indonesia dan hanya memperbandingkan dua jenis algoritma. Selain itu, studi komparatif multi-algoritma yang memanfaatkan data cuaca dari kawasan tropis masih relatif jarang ditemukan (Maheswara et al., 2026). Evaluasi terhadap kemampuan berbagai metode klasifikasi menjadi fokus dalam penelitian ini. Tiga algoritma, yaitu *Support Vector Machine* (SVM), *K-Nearest Neighbors* (K-NN), dan *Random Forest* (RF), diuji menggunakan data observasi BMKG selama sepuluh tahun untuk menentukan kategori curah hujan harian di Kabupaten Tapanuli Tengah. Perbandingan hasil ketiga algoritma tersebut digunakan untuk menentukan model dengan kinerja tertinggi. Model dengan kinerja tertinggi diharapkan dapat mendukung sistem peringatan dini cuaca yang relevan dengan mitigasi risiko terhadap ketahanan pangan di wilayah Kabupaten Tapanuli Tengah.

## BAHAN DAN METODE

Secara geografis, penelitian ini dilaksanakan di Kabupaten Tapanuli Tengah yang berada pada pesisir barat Sumatera Utara dan berbatasan langsung dengan Samudera Hindia. Dataset yang dimanfaatkan meliputi periode 1 Januari 2015 hingga 31 Desember 2024. Parameter meteorologi yang diteliti terdiri atas suhu minimum, suhu maksimum, suhu rata-rata, kelembapan relatif rata-rata, durasi penyinaran

matahari, kecepatan angin maksimum, kecepatan angin rata-rata, serta curah hujan. Data penelitian menggunakan hasil pengamatan Stasiun Meteorologi FL Tobing yang tersedia pada portal resmi BMKG sebagaimana diperlihatkan pada Tabel 1.

Tabel 1. Parameter Meteorologi

| Parameter                          | Tipe Data | Satuan | Valid Records | Missing Values |
|------------------------------------|-----------|--------|---------------|----------------|
| Suhu Minimum (Tn)                  | float64   | °C     | 3.488         | 156            |
| Suhu Maksimum (Tx)                 | float64   | °C     | 3.56          | 84             |
| Suhu Rata-Rata (Tavg)              | float64   | °C     | 3.635         | 9              |
| Kelembapan Rata-Rata (RH_avg)      | float64   | %      | 3.636         | 8              |
| Lama Penyinaran Matahari (ss)      | float64   | jam    | 3.539         | 105            |
| Kecepatan Angin Maks. (ff_x)       | float64   | m/s    | 3.643         | 1              |
| Kecepatan Angin Rata-Rata (ff_avg) | float64   | m/s    | 3.643         | 1              |
| Curah Hujan (RR)                   | float64   | mm     | 3.644         | 0              |

Sumber: (Hasil Penelitian, 2026)

Sebelum proses pemodelan, data terlebih dahulu melalui serangkaian prapemrosesan. Proses tersebut diawali dengan menghimpun data dari sejumlah parameter meteorologi yang rinciannya tercantum pada Tabel 1, lalu dilanjutkan dengan konversi keseluruhan dataset ke dalam format numerik (Geron, 2022). Penanganan nilai yang hilang dilakukan melalui dua pendekatan imputasi yang diselaraskan dengan karakteristik distribusi tiap-tiap variabel. Imputasi median diterapkan pada variabel Tn, Tx, dan ss karena distribusinya cenderung miring (*skewed*), sehingga median lebih tahan terhadap pengaruh pencilan (*outlier*). Adapun imputasi rata-rata (mean) digunakan pada variabel Tavg, RH\_avg, ff\_x, dan ff\_avg mengingat jumlah data hilang sangat minim dan distribusinya relatif simetris, sehingga tidak diperkirakan menimbulkan bias yang berarti, sebagaimana dirujuk dari Saputra & Kristiyanti (2021). Adanya data hilang berpotensi menurunkan performa model prediksi Sudrajat & Cholid (2023). Variabel curah hujan (RR) beserta tujuh parameter meteorologi lainnya digunakan sebagai landasan pembentukan fitur dan label dalam penelitian ini.

Selanjutnya, data curah hujan harian diberi label kelas berdasarkan kategori curah hujan 24 jam yang mengacu pada BMKG. Enam kelas digunakan dalam proses klasifikasi, meliputi kelas 1 untuk kondisi tidak hujan (0 mm), kelas 2 untuk hujan ringan (>0–20 mm), kelas 3 untuk hujan sedang (>20–50 mm), kelas 4 untuk hujan lebat (>50–100 mm), kelas 5 untuk hujan sangat lebat (>100–150 mm), dan kelas 6 untuk hujan ekstrem (>150 mm).

Distribusi data hasil klasifikasi didominasi oleh hujan ringan (kategori 2) sebanyak 1.483 data, diikuti kondisi tidak hujan (kategori 1) sebanyak 1.423 data. Jumlah data kemudian menurun pada kategori hujan sedang dan hujan lebat, masing-masing sebanyak 480 dan 205 data. Sementara itu, hujan sangat lebat hanya mencakup 40 data dan hujan ekstrem memiliki jumlah paling sedikit, yaitu 13 data.

Kategori 5 dan kategori 6 memiliki jumlah sampel yang sangat terbatas sehingga berpotensi menyebabkan ketidakseimbangan kelas dan menurunkan performa model klasifikasi. Untuk mengatasi hal tersebut, kategori 4, 5, dan 6 dikonsolidasikan menjadi satu kelas baru yang dinamakan "Hujan Lebat-Ekstrem" (curah hujan di atas 50 mm), proses tersebut selanjutnya menghasilkan empat kategori yang selanjutnya menjadi dasar klasifikasi dalam penelitian ini, dengan rincian kategori tercantum pada Tabel 2.

Tabel 2. Distribusi Kategori Curah Hujan

| Kelas | Rentang RR (mm/hari) | Kategori            | Jumlah | Proporsi |
|-------|----------------------|---------------------|--------|----------|
| 1     | 0                    | Tidak Hujan         | 1.423  | 39.1%    |
| 2     | 0.1 – 20             | Hujan Ringan        | 1.483  | 40.7%    |
| 3     | 20.1 – 50            | Hujan Sedang        | 480    | 13.2%    |
| 4     | >50                  | Hujan Lebat-Ekstrem | 258    | 7.1%     |
| Total |                      |                     | 3.644  | 100.0%   |

Sumber: (Hasil Penelitian, 2026)

Sebelum pemodelan, skala fitur disesuaikan pada algoritma yang sensitif terhadap perbedaan skala data. Pada K-NN digunakan Min-Max Scaling, sedangkan data untuk SVM ditransformasikan menggunakan Standard Scaling dengan mengacu pada Mdegela et al. (2023). *Random Forest* tidak membutuhkan normalisasi karena mekanisme pembagian *node (split)* bersifat invarian terhadap skala fitur (Pinheiro et al., 2025). Meski demikian, RF tetap dieksekusi pada data hasil *Min-Max Scaling* sebagai bagian dari *pipeline* yang selaras dengan K-NN tanpa memengaruhi performa prediksi. Tujuh variabel yang difungsikan sebagai fitur prediktor mencakup Tn, Tx, Tavg, RH\_avg, ss, ff\_x, dan ff\_avg. Sementara itu, variabel curah hujan (RR) tidak diikutsertakan sebagai fitur karena menjadi basis pembentukan kategori curah hujan sebagai variabel target, sehingga pemanfaatannya sebagai prediktor berpotensi menimbulkan data *leakage* (Sari et al., 2025; Bouke & Abdullah, 2023).

Data penelitian dipisahkan menjadi dua himpunan dengan alokasi 80% untuk pelatihan model dan 20% untuk pengujian. Pembagian dilakukan secara berstrata agar distribusi setiap kategori tetap terwakili secara proporsional, yang menghasilkan 2.915 data latih dan 729 data uji. Merujuk Tabel 2, kategori 1 dan kategori 2 mendominasi lebih dari 79% keseluruhan data, sehingga masih terdapat ketidakseimbangan kategori yang cukup substansial pada data latih. Guna mengatasinya, *Synthetic Minority Over-sampling Technique* (SMOTE) diterapkan untuk membangkitkan sampel sintesis pada kategori minoritas (kategori 3 dan 4) hingga mencapai 80% dari jumlah sampel kategori mayoritas sebagai kompromi antara pengurangan ketidakseimbangan kelas dan minimalisasi risiko overfitting akibat kelebihan data sintesis. Pendekatan tersebut merujuk pada prinsip penerapan SMOTE dalam mengatasi ketidakseimbangan kelas (Erlin et al., 2022; Nurmasani & Pristyanto, 2021). SMOTE hanya diterapkan pada data latih untuk menghindari data *leakage*, sedangkan data uji tetap mempertahankan distribusi kategori asli agar proses evaluasi mencerminkan kondisi data yang sebenarnya.

Setelah melalui tahap prapemrosesan data, dilakukan tahap pemodelan menggunakan tiga algoritma klasifikasi, yaitu *Support Vector Machine* (SVM), *K-Nearest Neighbors* (K-NN), dan *Random Forest* (RF). SVM digunakan karena mampu menangani data berdimensi tinggi dan hubungan non-linear antarvariabel melalui fungsi kernel (Hasibuan, 2024). K-NN dipilih karena kesederhanaannya dan efektivitasnya dalam mengenali pola lokal pada data (Aziza et al., 2024). Sementara itu, RF digunakan karena mampu menangani dataset berukuran besar dan tidak seimbang serta menghasilkan informasi *feature importance* (Egbunu et al., 2021; Maheswara & Al'aziz, 2025). Konfigurasi hiperparameter dan teknik optimasi yang diterapkan pada setiap model disajikan pada Tabel 3.


Tabel 3. Konfigurasi Hiperparameter

| Algoritma                           | Hiperparameter yang Diuji ( <i>Grid Search</i> )                                                | Teknik Optimasi dan Validasi                                                                                                 |
|-------------------------------------|-------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|
| <i>Support Vector Machine</i> (SVM) | kernel: {linear, rbf, poly}<br>C: {0,1; 1; 10; 100}<br>gamma: {scale, auto}                     | <i>Grid Search</i> dengan validasi silang <i>5-fold</i> pada data latih hasil SMOTE, pemilihan kombinasi terbaik berdasarkan |
| <i>K-Nearest Neighbors</i> (K-NN)   | n_neighbors: {3, 5, 7, 9, 11}<br>weights: {uniform, distance}<br>metric: {euclidean, manhattan} |                                                                                                                              |

| Algoritma                 | Hiperparameter yang Diuji ( <i>Grid Search</i> )                                               | Teknik Optimasi dan Validasi |
|---------------------------|------------------------------------------------------------------------------------------------|------------------------------|
| <i>Random Forest</i> (RF) | n_estimators: {100, 200, 500}<br>max_depth: {5, 10, 20, None}<br>min_samples_split: {2, 5, 10} | <i>F1-score weighted</i>     |

Sumber: (Hasil Penelitian, 2026)

Rangkaian tahapan penelitian ini dirangkum melalui diagram alir pada Gambar 1.



Sumber: (Hasil Penelitian, 2026)

Gambar 1. Diagram Alir Penelitian

Kinerja masing-masing model selanjutnya dinilai berdasarkan *precision*, *recall*, dan *F1-score*, sementara *Confusion Matrix* digunakan untuk menggambarkan hasil klasifikasi pada setiap kelas. Perhitungan ketiga metrik evaluasi tersebut mengacu pada Persamaan 1–3. Komponen TP, FP, dan FN yang digunakan dalam persamaan secara berturut-turut menunjukkan *True Positive*, *False Positive*, dan *False Negative*. Di samping itu, analisis *feature importance* pada model RF dilaksanakan guna mengidentifikasi variabel meteorologi yang paling berpengaruh, serta uji *paired t-test* terhadap nilai *F1-score* hasil validasi silang untuk memverifikasi signifikansi perbedaan kinerja antarmodel pada tingkat signifikansi *p-value* < 0,05. Seluruh hasil analisis kemudian dirangkum

melalui penyajian tabel dan grafik untuk memudahkan perbandingan dan interpretasi kinerja antarmodel.


$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

### HASIL DAN PEMBAHASAN

Distribusi curah hujan pada Gambar 2 memperlihatkan bahwa sebagian besar data terkonsentrasi pada kategori hujan ringan dan tidak hujan, masing-masing sebanyak 1.483 dan 1.423 data. Sementara itu, hujan sedang tercatat sebanyak 480 data, sedangkan kategori hujan lebat hingga ekstrem hanya berjumlah 258 data.



Sumber: (Hasil Penelitian, 2026)

Gambar 2. Distribusi Kategori Curah Hujan

Perbedaan jumlah antar kategori tersebut menunjukkan adanya ketidakseimbangan kelas, terutama pada kejadian dengan intensitas hujan yang lebih tinggi. Oleh karena itu, kategori hujan lebat, sangat lebat, dan ekstrem digabungkan menjadi satu kelas, yaitu kategori 4 (hujan lebat-ekstrem). Pengelompokan ini menghasilkan empat kategori akhir berdasarkan data curah hujan Stasiun Meteorologi FL Tobing yang mengacu pada klasifikasi curah hujan 24 jam BMKG. Penelitian ini memanfaatkan 3.644 data curah hujan dengan tujuh parameter sebagai variabel prediktor. Tabel 1 memperlihatkan bahwa ketersediaan data belum seragam pada seluruh parameter meteorologi, yang ditandai oleh adanya *missing value* pada beberapa variabel. Setelah melalui tahap prapemrosesan data, keseluruhan parameter memiliki 3.644 data melalui proses imputasi median dan rata-rata, sehingga tidak ada observasi yang dieliminasi dari dataset. Total *missing value* yang diimputasi

berjumlah 364 entri atau sekitar 1,25% dari keseluruhan data. Evaluasi ketiga model dilakukan terhadap 729 observasi pada data uji yang tetap mempertahankan distribusi 4 kelas. Kemampuan klasifikasi masing-masing model kemudian diukur menggunakan *precision*, *recall*, dan *F1-score*. Evaluasi dilakukan setelah parameter tiap model dioptimasi melalui *Grid Search* dengan validasi silang 5-fold pada data latih yang telah diproses menggunakan SMOTE. Perbandingan kinerja ketiga model berdasarkan hasil pengujian dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan Kinerja Model pada Data Pengujian

| Metrik Evaluasi             | K-NN   | SVM    | Random Forest |
|-----------------------------|--------|--------|---------------|
| Akurasi                     | 45,68% | 46,78% | 51,44%        |
| <i>Precision (weighted)</i> | 0,4615 | 0,4847 | 0,4970        |
| <i>Recall (weighted)</i>    | 0,4568 | 0,4678 | 0,5144        |
| <i>F1-score (weighted)</i>  | 0,4580 | 0,4744 | 0,5036        |
| <i>F1-score (macro)</i>     | 0,3807 | 0,3683 | 0,3945        |

Sumber: (Hasil Penelitian, 2026)

Tabel 4 menyajikan hasil evaluasi performa ketiga model pada data uji sesudah optimasi *Grid Search* dan validasi silang 5-fold pada data latih yang telah melalui SMOTE. Berdasarkan Tabel 4, model *Random Forest* mendemonstrasikan kinerja paling unggul dibandingkan SVM dan K-NN. Hal ini dibuktikan oleh nilai *weighted F1-score* sebesar 50,4%, melampaui SVM yang mencapai 47,4% dan K-NN yang memperoleh 45,8%. Di samping itu, *Random Forest* juga meraih akurasi tertinggi, yakni 51,4%, dibandingkan SVM sebesar 46,8% dan K-NN sebesar 45,7%.

**K-NN**  
**Akurasi: 45.68%**

|    |     |     |    |    |
|----|-----|-----|----|----|
|    | K1  | K2  | K3 | K4 |
| K1 | 170 | 85  | 18 | 12 |
| K2 | 108 | 119 | 38 | 32 |
| K3 | 17  | 33  | 34 | 12 |
| K4 | 6   | 24  | 11 | 10 |
|    | K1  | K2  | K3 | K4 |

Prediksi

(a)

**SVM**  
**Akurasi: 46.78%**

|    |     |     |    |    |
|----|-----|-----|----|----|
|    | K1  | K2  | K3 | K4 |
| K1 | 185 | 67  | 19 | 14 |
| K2 | 87  | 122 | 42 | 46 |
| K3 | 18  | 37  | 25 | 16 |
| K4 | 3   | 26  | 13 | 9  |
|    | K1  | K2  | K3 | K4 |

Prediksi

(b)

**Random Forest**  
**Akurasi: 51.44%**

|    |     |     |    |    |
|----|-----|-----|----|----|
|    | K1  | K2  | K3 | K4 |
| K1 | 191 | 77  | 11 | 6  |
| K2 | 100 | 156 | 24 | 17 |
| K3 | 18  | 51  | 20 | 7  |
| K4 | 3   | 29  | 11 | 8  |
|    | K1  | K2  | K3 | K4 |

(c)

Sumber: (Hasil Penelitian, 2026)


Gambar 3. (a)(b)(c) *Confusion Matrix* K-NN, SVM, dan *Random Forest*

Gambar 3 menampilkan *Confusion Matrix* dari model K-NN, SVM, dan *Random Forest* pada data uji. Secara keseluruhan, ketiga model memperlihatkan kemampuan yang lebih baik dalam mengklasifikasikan kategori tidak hujan (K1) dan hujan ringan (K2) dibandingkan kategori hujan sedang (K3) dan hujan lebat ekstrem (K4). *Random Forest* menghasilkan performa terbaik dengan akurasi 51,44%.


Model ini juga mencatatkan jumlah prediksi benar tertinggi pada kategori K1 dan K2, yakni masing-masing 191 dan 156 data. Meski demikian, keseluruhan model masih memperlihatkan kesulitan dalam mengidentifikasi kategori K3 dan K4, yang diindikasikan oleh rendahnya jumlah prediksi benar pada kedua kategori tersebut. Kesalahan klasifikasi yang paling sering terjadi adalah antar kategori yang bersebelahan, terutama antara K1 dan K2, yang mengisyaratkan adanya kesamaan karakteristik meteorologi antarkelas curah hujan. Hasil ini mengindikasikan bahwa *Random Forest* memiliki kemampuan klasifikasi yang lebih baik pada data meteorologi dibandingkan SVM dan K-NN.

Gambar 4 menampilkan gambaran komparatif mengenai capaian nilai *precision*, *recall*, dan *F1-score* dari ketiga model berdasarkan Tabel 4. *Random Forest* mencapai nilai tertinggi pada seluruh metrik evaluasi dibandingkan SVM dan K-NN. Meski demikian, akurasi ketiga model masih tergolong rendah, yakni berkisar antara 45,7% hingga 51,4%. Meskipun akurasi *Random Forest* sebesar 51,4% masih termasuk kategori moderat, angka tersebut melampaui dua *baseline* sederhana, yaitu *uniform random baseline* pada klasifikasi empat kategori (25%) dan *majority class classifier* yang senantiasa memprediksi kelas mayoritas, yakni hujan ringan (297 dari 729 data uji), dengan akurasi sebesar 40,7%. Hal ini membuktikan bahwa

*Random Forest* mampu mempelajari pola keterkaitan antara variabel meteorologi dan kategori curah hujan sehingga menghasilkan performa yang melampaui prediksi acak maupun strategi pemilihan kelas mayoritas saja.



(a)




(b)

Sumber: (Hasil Penelitian, 2026)

Gambar 4. (a)(b) Perbandingan Kinerja Model pada Setiap Metrik Evaluasi


Nilai *macro F1-score* RF (0,3945) melampaui K-NN (0,3807) dan SVM (0,3683), yang mengindikasikan kapabilitas yang lebih baik dalam mengklasifikasikan kategori minoritas, khususnya kategori 4 (Hujan Lebat Ekstrem). Kategori ini memiliki signifikansi khusus dalam konteks ketahanan pangan karena berkaitan dengan meningkatnya risiko penggenangan dan kegagalan panen. Performa RF yang lebih unggul diduga bersumber dari pendekatan *ensemble* yang menggabungkan sejumlah besar *decision tree*, sehingga lebih efektif dalam mempelajari pola data yang kompleks dan tidak seimbang (Indaryono et al., 2024; Fauzan & Ahmad, 2023; Putri et al., 2024).



Sumber: (Hasil Penelitian, 2026)

Gambar 5. *Feature importance Random Forest*

Kontribusi setiap variabel meteorologi terhadap klasifikasi kategori curah hujan pada model RF dianalisis melalui *feature importance*, dengan hasil yang disajikan pada Gambar 5. Durasi penyinaran matahari (ss) tercatat sebagai variabel terpenting dengan kontribusi 19,1%, diikuti oleh suhu rata-rata (Tavg) sebesar 18,1% dan suhu maksimum (Tx) sebesar 17,5%. Besarnya kontribusi ss menunjukkan bahwa lamanya penyinaran matahari memiliki korelasi erat dengan kondisi tutupan awan dan probabilitas terjadinya hujan. Selain itu, signifikansi Tavg dan Tx mengindikasikan adanya keterkaitan antara suhu udara dan variabilitas curah hujan. Kontribusi ketiga variabel yang relatif seimbang menunjukkan bahwa prediksi curah hujan di Tapanuli Tengah dipengaruhi oleh kombinasi beberapa parameter meteorologi, bukan oleh satu variabel yang dominan (Isnaeni & Prasetyo, 2022).



Sumber: (Hasil Penelitian, 2026)

Gambar 6. *Distribusi F1-Score Cross-Validation sebagai Dasar Uji Paired T-Test*

Perbedaan performa ketiga model selanjutnya dianalisis secara statistik menggunakan *paired t-test* berdasarkan *weighted F1-score* yang diperoleh dari validasi silang 5-fold. Sebagaimana

dirangkum pada Gambar 6, seluruh pasangan model menunjukkan perbedaan kinerja yang signifikan pada taraf signifikansi 0,05. Perbandingan RF dengan SVM menghasilkan  $t = 13,4581$  dan  $p\text{-value} = 0,0002$ , sedangkan RF dengan K-NN memperoleh  $t = 4,5480$  dan  $p\text{-value} = 0,0104$ . Perbedaan signifikan juga ditemukan antara SVM dan K-NN dengan  $t = -4,9040$  dan  $p\text{-value} = 0,0080$ . Keseluruhan  $p\text{-value}$  yang diperoleh berada di bawah ambang 0,05, sehingga perbedaan kinerja antara RF, SVM, dan K-NN dinyatakan signifikan secara statistik. Hasil ini menegaskan bahwa performa RF yang lebih tinggi dibandingkan kedua model lainnya merepresentasikan keunggulan yang konsisten dalam memodelkan data meteorologi di Kabupaten Tapanuli Tengah.

RF mendemonstrasikan performa yang lebih unggul dibandingkan SVM dan K-NN, sebagaimana dibuktikan oleh nilai *weighted F1-score* tertinggi dan perbedaan yang signifikan secara statistik. Performa tersebut diduga berkaitan dengan kemampuan RF sebagai metode *ensemble* dalam memodelkan relasi kompleks antarparameter (Indaryono et al., 2024). Meski demikian, *weighted F1-score* yang diperoleh ketiga model berada pada rentang 45,8–50,4%, yang menunjukkan bahwa performa yang tergolong sedang. Kondisi ini kemungkinan dipengaruhi oleh ketidakseimbangan kategori dalam *dataset*, mengingat kategori 1 dan 2 mendominasi lebih dari 79% data sebelum penerapan SMOTE (Gambar 2). Selain itu, kategori 4 (Hujan Lebat Ekstrem) mencakup curah hujan yang cukup tinggi (>50 mm), sehingga karakteristik meteorologinya cenderung lebih beragam dan lebih sulit dipelajari oleh model.

Model RF yang dikonstruksi memiliki potensi untuk menunjang upaya ketahanan pangan di Kabupaten Tapanuli Tengah. Kapabilitas model dalam memprediksi kategori hujan sedang (K3) dan hujan lebat ekstrem (K4) dapat dimanfaatkan sebagai informasi penunjang dalam mitigasi risiko penggenangan lahan pertanian (Buani et al., 2023), sedangkan dominasi prediksi kategori tidak hujan (K1) secara berturut-turut dapat berfungsi sebagai indikasi awal potensi kekeringan. Di samping itu, variabel durasi penyinaran matahari (ss), suhu rata-rata (Tavg), dan suhu maksimum (Tx) sebagai prediktor utama dapat diperoleh melalui BMKG. Dengan demikian, model RF berpotensi menunjang pengembangan sistem informasi cuaca berbasis data pengamatan untuk menyediakan informasi dini yang dapat dipergunakan dalam penjadwalan periode tanam serta antisipasi kejadian curah hujan tinggi (Harvian & Yuhan, 2021; Rusmayadi et al., 2023).

## KESIMPULAN

Berdasarkan perbandingan ketiga algoritma klasifikasi, *Random Forest* (RF) memberikan kinerja paling baik dalam mengidentifikasi kategori curah hujan di Kabupaten Tapanuli Tengah. Model ini mencapai *weighted F1-score* sebesar 50,4%, *macro F1-score* sebesar 39,5%, dan akurasi sebesar 51,4%, dengan capaian yang lebih tinggi dibandingkan *Support Vector Machine* (SVM) dan *K-Nearest Neighbors* (K-NN). Hasil uji *paired t-test* turut mengkonfirmasi bahwa perbedaan kinerja antara RF, SVM, dan K-NN signifikan secara statistik ( $p\text{-value} < 0,05$ ). Performa RF yang lebih unggul diduga berkaitan dengan pendekatan *ensemble* yang mengintegrasikan sejumlah besar *decision tree*, sehingga lebih efektif dalam memodelkan relasi kompleks antarvariabel meteorologi dibandingkan SVM dan K-NN. Analisis *feature importance* mengungkapkan bahwa durasi penyinaran matahari (ss), suhu rata-rata (Tavg), dan suhu maksimum (Tx) merupakan variabel yang paling berpengaruh dalam prediksi kategori curah hujan di Kabupaten Tapanuli Tengah, dengan tingkat kontribusi yang relatif proporsional.

Capaian *weighted F1-score* seluruh model berada pada rentang 45,8–50,4%, yang menunjukkan bahwa kemampuan klasifikasi yang dihasilkan masih tergolong sedang. Performa yang belum optimal ini diduga disebabkan oleh ketidakseimbangan kategori dalam dataset, mengingat kategori tidak hujan dan hujan ringan mendominasi lebih dari 79% data. Di samping itu, pengonsolidasian beberapa kategori curah hujan tinggi ke dalam kategori hujan lebat-ekstrem mengakibatkan karakteristik data menjadi lebih heterogen, sehingga lebih sulit dipelajari oleh model. Penelitian selanjutnya disarankan untuk aplikasi operasional yang memerlukan pembedaan tingkat ekstremitas hujan, dibutuhkan periode data yang lebih panjang agar setiap kategori memiliki jumlah sampel yang memadai, penambahan fitur temporal berupa lag curah hujan untuk menangkap autokorelasi deret waktu, serta evaluasi algoritma *ensemble* alternatif seperti *XGBoost*. Di samping itu, diperlukan studi perbandingan pada beberapa wilayah di Sumatera guna memperoleh pemahaman yang lebih komprehensif mengenai efektivitas metode machine learning dalam klasifikasi kategori curah hujan untuk menunjang ketahanan pangan.

## REFERENSI

- Ashari, A. M. (2023). Dampak Perubahan Iklim terhadap Ketahanan Pangan dan Adaptasinya oleh Masyarakat Pesisir. *Empiricism Journal*, 4(2), 426–431. <https://doi.org/10.36312/ej.v4i2.1611>
- Aziza, L. N., Astuti, R. Y., Maulana, B. A., & Hidayati, N. (2024). Penerapan Algoritma K-Nearest Neighbor untuk Klasifikasi Ketahanan Pangan di Provinsi Jawa Tengah. *MALCOM Indonesian Journal of Machine Learning and Computer Science*, 4(2), 404–412. <https://doi.org/10.57152/malcom.v4i2.1201>
- Bouke, M. A., & Abdullah, A. (2023). An empirical study of pattern leakage impact during data preprocessing on machine learning-based intrusion detection models reliability. *Expert Systems with Applications*, 230, 120715. <https://doi.org/10.1016/j.eswa.2023.120715>
- Buani, C. P., Abdussomad, A., Apriliah, W., & Saputra, R. A. (2023). Implementasi Algoritma *Random Forest* untuk Menentukan Penerima Bantuan Raskin. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(2), 421–428. <https://doi.org/10.25126/jtiik.20231026225>
- Egbunu, C. O., Ogedengbe, M. T., Yange, T. S., Rufai, M. A., & Muhammed, H. I. (2021). Towards Food Security: the Prediction of Climatic Factors in Nigeria using *Random Forest* Approach. *Journal of Computer Science and Information Technology*, 7(4), 70–81. <https://doi.org/10.35134/jcsitech.v7i4.15>
- Erlin, E., Desnelita, Y., Nasution, N., Suryati, L., & Zoromi, F. (2022). Dampak SMOTE terhadap Kinerja *Random Forest* Classifier berdasarkan Data Tidak Seimbang. *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 21(3). <https://doi.org/10.30812/matrik.v21i3.1726>
- Fauzan, A., & Ahmad, D. (2023). Analisis Hasil Prediksi Magnitudo Gempa di Wilayah Kota Padang Menggunakan Teknik *Random Forest*. *Jurnal Lebesgue*, 4(3), 1569–1576. <https://doi.org/10.46306/lb.v4i3.450>
- Geron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media.
- Hapsari, I., & Wisesa, S. P. (2025). Evaluasi Model Prediksi Curah Hujan Berbasis Machine Learning di Kota Bandung. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 11(2), 136–143. <https://doi.org/10.25077/teknosi.v11i2.2025.136-143>
- Harvian, K. A., & Yuhan, R. J. (2021). Kajian Perubahan Iklim Terhadap Ketahanan Pangan. *Seminar Nasional Official Statistics*, 2020(1), 1052–1061. <https://doi.org/10.34123/semnasoffstat.v2020i1.593>

- Hasibuan, F. H. (2024). Klasifikasi Data Material Pending Pada Perusahaan dengan Metode SVM. *Innovative Journal of Social Science Research*, 4, 5080–5090.
- Indaryono, N. A. P., Saedudin, R. R., & Hamami, F. (2024). Comparison Analysis of *Random Forest* and Naive Bayes Algorithms for Rainfall Classification Based on Climate in Indonesia. *SITEKNIK: Information Systems, Engineering and Applied Technology*, 1(2), 102–109.
- Isnaeni, A. Y., & Prasetyo, S. Y. J. (2022). Klasifikasi Wilayah Potensi Risiko Kerusakan Lahan Akibat Bencana Tsunami Menggunakan Machine Learning. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 33–42. <https://doi.org/10.28932/jutisi.v8i1.4056>
- Maheswara, I. D. G. L., & Al'aziz, A. H. (2025). Perbandingan Model Machine Learning pada Klasifikasi Curah Hujan di Bogor. *INTI Nusa Mandiri*, 19(2), 202–210. <https://doi.org/10.33480/inti.v19i2.6296>
- Maheswara, I. D. G. L., Ramadhan, A. Z., Maldina, R. A., Nurwibowo, M. F., & Norman, Y. (2026). Perbandingan Performa Multi-Algoritma Machine Learning dengan Dua Strategi Validasi pada Klasifikasi Curah Hujan. *Jurnal Sistem Komputer Dan Informatika (JSON)*.
- Mdegela, L., Municio, E., Bock, Y. D., Luhanga, E., & Leo, J. (2023). Extreme Rainfall Event Classification Using Machine Learning for Kikuletwa River Floods. *Water*, 15, 1–14. <https://doi.org/10.3390/w15061021>
- Nurhidayat, A., Difa, A. K. T., Nasrullah, F., Anwar, F. H., & Radianto, D. O. (2024). Pengaruh Perubahan Iklim Terhadap Produktivitas Pertanian Padi di Daerah Tropis. *Sains Student Research*, 2(2), 111–117.
- Nurmasani, A., & Pristyanto, Y. (2021). Algoritme Stacking untuk Klasifikasi Penyakit Jantung pada Dataset Imbalanced Class. *Pseudocode*, 8(1), 21–26. <https://doi.org/10.33369/pseudocode.8.1.21-26>
- Pinheiro, J. M. H., de Oliveira, S. V. B., Segreto Silva, T. H., Saraiva, P. A. R., de Souza, E. F., Godoy, R. V., Ambrosio, L. A., & Becker, M. (2025). The Impact of Feature Scaling in Machine Learning: Effects on Regression and Classification Tasks. *IEEE Access*, 13, 199903–199931. <https://doi.org/10.1109/ACCESS.2025.3635541>
- Pratama, A., Wihandika, R. C., & Dewi, C. (2022). Optimasi Klasifikasi Curah Hujan Menggunakan *Support Vector Machine* dan Recursive Feature Elimination. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 6(8), 3856–3863.
- Putri, N. H., Dananjaya, R. H., & Surjandari, N. S. (2024). Aplikasi Machine Learning Method pada Pemetaan Kerawanan Tanah Longsor di Kabupaten Karanganyar. *Media Komunikasi Teknik Sipil*, 6(1), 23–34.
- Rusmayadi, G., Salawati, U., & Suparwata, D. O. (2023). Analisis Sistem Agrometeorologi dalam Meningkatkan Ketahanan Pangan saat Kemarau. *Jurnal Geosains West Sci*, 1(03), 143–150. <https://doi.org/10.58812/jgws.v1i03.720>
- Saputra, I., & Kristiyanti, D. A. (2021). Application of Data Mining for Rainfall Prediction Classification in Australia with *Decision tree* Algorithm and C5.0 Algorithm. *Seminar Nasional Informatika (SEMNASIF)*.
- Sari, D. P., Risman, Maulana, F., Efrizoni, L., & Rahmadden. (2025). Prediction Model for the Impact of Climate Change on Food Security Using the *Support Vector Machine* and *K-Nearest Neighbors* Algorithms. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(3), 851–861. <https://doi.org/10.57152/malcom.v5i3.1975>
- Sudrajat, W., & Cholid, I. (2023). K-Nearest Neighbor (K-NN) untuk Penanganan Missing Value pada Data UMKM. *Jurnal Rekayasa Sistem Informasi Dan Teknologi*, 1(2), 54–63. <https://doi.org/10.59407/jrsit.v1i2.77>
- Syahreza, A., Ningrum, N. K., & Syahrazy, M. A. (2024). Perbandingan Kinerja Model Prediksi Cuaca: *Random Forest*, *Support Vector Regression*, dan *XGBoost*. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 526–534. <https://doi.org/10.29408/edumatic.v8i2.27640>