

## DECADE RAINFALL PREDICTION USING PROPHET ALGORITHM AND LSTM (CASE STUDY IN BANJARNEGARA REGENCY)

### PREDIKSI CURAH HUJAN DASARIAN MENGGUNAKAN ALGORITMA PROPHET DAN LSTM (STUDI KASUS DI KABUPATEN BANJARNEGARA)

Sulistiyowati<sup>1</sup>. Eri Zuliarsa<sup>2</sup>

Jurusan Magister Teknologi Informasi, Fakultas Teknologi Informasi dan Industri  
Universitas Stikubank, Jl. Tri Lomba Juang Semarang, Indonesia  
sulistiyowati0032@mhs.unisbank.ac.id<sup>1</sup>. eri299@edu.unisbank.ac.id<sup>2</sup>

**Abstract** – Hydrometeorological disasters such as floods and landslides in Banjarnegara Regency are closely related to fluctuating rainfall variability. This study aims to predict decadal (10-day) rainfall by comparing the performance of the Prophet algorithm and the Long Short-Term Memory (LSTM) model. The dataset comprises daily rainfall records from 14 observation stations spanning the period 2005–2024. The research stages included preprocessing, modelling, hyperparameter optimization using Optuna, and evaluation with Root Mean Square Error (RMSE) and Mean Absolute Error (MAE). The results indicate that the Prophet model outperformed LSTM in most locations, with an average RMSE of 69.55 and MAE of 53.05, lower than LSTM, which recorded 73.03 and 55.72, respectively. The ensemble averaging model produced competitive results at several locations, although it was less responsive to sharp fluctuations in rainfall. These findings confirm that Prophet is more effective in capturing seasonal patterns and long-term trends, thus providing significant potential to support climate-based disaster mitigation systems in vulnerable areas such as Banjarnegara.

**Keywords** - Rainfall Prediction, Decadal, Prophet, LSTM, Banjarnegara,

**Abstrak** - Bencana hidrometeorologi seperti banjir dan longsor di Kabupaten Banjarnegara sangat erat kaitannya dengan variabilitas curah hujan yang fluktuatif. Penelitian ini bertujuan memprediksi curah hujan dasarian (10 harian) dengan membandingkan kinerja algoritma Prophet dan Long Short-Term Memory (LSTM). Data yang digunakan berupa catatan curah hujan harian dari 14 pos pengamatan selama periode 2005–2024. Proses penelitian meliputi *preprocessing*, pemodelan, optimasi *hyperparameter* dengan Optuna, serta evaluasi menggunakan Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE). Hasil penelitian menunjukkan bahwa model Prophet memiliki performa lebih baik dibandingkan LSTM di sebagian besar lokasi, dengan nilai RMSE rata-rata 69,55 dan MAE 53,05, lebih rendah daripada LSTM yang mencatat RMSE 73,03 dan MAE 55,72. Model rata-rata (*ensemble averaging*) mampu memberikan hasil kompetitif pada beberapa lokasi, meskipun kurang responsif terhadap fluktuasi curah hujan yang tajam. Temuan ini menegaskan bahwa Prophet lebih unggul dalam menangkap pola musiman dan tren jangka panjang, sehingga berpotensi besar digunakan untuk mendukung sistem mitigasi bencana berbasis prediksi iklim di wilayah rawan bencana seperti Banjarnegara.

**Kata Kunci** –Prediksi Curah Hujan, Dasarian, Prophet, LSTM, Banjarnegara.

## I. PENDAHULUAN

Bencana hidrometeorologi seperti banjir, longsor, kekeringan, serta kebakaran hutan cenderung meningkat seiring variabilitas iklim yang tidak menentu. Curah hujan menjadi indikator utama dalam memprediksi kejadian ekstrem sehingga analisis dan prediksi akurat penting untuk mitigasi dan adaptasi. Prediksi curah hujan dasarian (10 harian) relevan di wilayah tropis karena lebih detail dibandingkan skala bulanan, meski tantangan akurasi tinggi akibat sifat non-linear dan pengaruh atmosfer, oseanografi, serta geografi. Informasi ini memiliki signifikansi strategis karena banyak sektor yang bergantung pada informasi tersebut mulai dari pertanian, pengelolaan sumber daya air, hingga penanggulangan bencana, sekaligus mendukung pembangunan Nasional [1] [2]. Definisi curah hujan menurut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) merujuk pada ketinggian air hujan yang terkumpul di permukaan datar tanpa mengalami penguapan, peresapan, atau aliran. Curah hujan dasarian adalah jumlah curah hujan selama 10 hari. Dalam 1 bulan terdapat 3 dasarian. Awal musim hujan ditetapkan jika tiga dasarian berturut-turut  $>50$  mm, sedangkan musim kemarau  $<50$  mm [3]. Karena itu, prediksi curah hujan dasarian krusial bagi sistem peringatan dini dan mitigasi bencana. Sejauh pengetahuan kami, prediksi curah hujan dasarian di Banjarnegara dengan pendekatan multi-stasiun belum pernah dilaporkan. Sebagian besar studi masih fokus pada skala bulanan atau tahunan.

Kemajuan teknologi memungkinkan pengembangan metode prakiraan cuaca dan iklim yang lebih adaptif. *Machine learning* menawarkan peluang besar dalam pemodelan deret waktu [4]. Metode konvensional seperti ARIMA kurang mampu menangkap pola *non-linear*, sementara baseline sederhana seperti musiman naif penting sebagai pembanding. Model modern seperti *Prophet* dan *Long Short-Term Memory* (LSTM) unggul dalam mengenali pola jangka panjang serta mengatasi *missing value* dan *outlier* [5] [6]. Meski prediksi curah hujan banyak dikaji, kesenjangan masih ada pada skala dasarian, terutama di wilayah rawan bencana. Skala ini penting karena memberi informasi lebih rinci dibandingkan prediksi bulanan. Kabupaten Banjarnegara dipilih sebagai lokasi penelitian karena tingkat kerawanan longsor sangat tinggi. Berdasarkan peta kemiringan, wilayah ini didominasi lereng  $> 40\%$  yang tergolong Zona Tipe A menurut Peraturan Menteri Pekerjaan Umum No. 22/PRT/M/2007, dengan potensi longsor tinggi di kaki gunung, lereng pegunungan, dan perbukitan [7]. Selain itu, Banjarnegara menempati peringkat pertama kejadian longsor di Jawa Tengah, dengan 152 kasus pada 2022 dan tujuh kecamatan terdampak hingga Februari 2024 [8]. Kondisi ini menegaskan urgensi prediksi curah hujan dasarian di Banjarnegara untuk mendukung mitigasi bencana secara lebih spesifik.

## II. SIGNIFIKANSI STUDI


### A. Studi Literatur

Data curah hujan historis telah lama digunakan untuk memahami pola musiman dan tren jangka panjang, namun metode tradisional sering kali kurang mampu menangkap sifat non-linier dan kompleks dari data iklim. Perkembangan machine learning dan deep learning membuka peluang baru, terutama melalui pemodelan deret waktu (*time series forecasting*) dengan algoritma seperti *Long Short-Term Memory* (LSTM) dan *Prophet*. LSTM, salah satu arsitektur *Recurrent Neural Network* (RNN), dirancang untuk mengatasi masalah *vanishing gradient* dan efektif mempelajari ketergantungan jangka panjang dalam deret waktu. Model ini terbukti memberikan hasil baik pada prediksi iklim, beban listrik, maupun curah hujan [9] [10][11]. Sementara itu *Prophet* yang dikembangkan oleh Facebook, menawarkan pendekatan berbasis *dekomposisi* tren, musiman, dan hari libur. Keunggulannya adalah kemudahan implementasi serta kemampuan menangani data

dengan tren musiman kuat dan ketidakteraturan. *Prophet* mampu mengungguli LSTM dalam prediksi curah hujan bulanan di Jakarta Pusat, terutama karena model ini efektif menangkap pola musiman yang konsisten [12]. Penggunaan *Prophet* juga meluas ke bidang lain seperti prediksi polusi udara [13] dan *epidemiologi* [14].

Peneliti lain [15] memperkenalkan *NeuralProphet* yang menetapkan tolok ukur untuk peramalan. Model ini menggabungkan modul *auto-regresi* dan konteks lokal, sekaligus mempertahankan elemen desain *Prophet* sehingga tetap mudah digunakan. *NeuralProphet* mampu menghasilkan kualitas prediksi dengan peningkatan akurasi untuk prediksi jangka pendek hingga menengah sebesar 55–92 %. Beberapa penelitian terkini menggabungkan LSTM dan *Prophet* untuk mengatasi keterbatasan masing-masing model. Usulan model hibrida yang memanfaatkan *Prophet* untuk mempertahankan informasi musiman [16], sementara LSTM digunakan untuk memodelkan data yang telah dihilangkan komponen musimannya. Pendekatan ini terbukti mampu meningkatkan akurasi prediksi curah hujan maupun beban listrik. Efektivitas kombinasi ini menunjukkan bahwa integrasi keduanya dapat menghasilkan model prediksi yang lebih stabil dan adaptif terhadap berbagai pola iklim [17]. Sementara [18] mengusulkan model klasifikasi intensitas hujan berbasis data *radiosonde* dengan metode *stacking ensemble* yang memadukan *Random Forest*, *XGBoost*, *LightGBM*, dan *SVM*, dengan *HistGradientBoosting* sebagai *meta-learner*. Hasil menunjukkan bahwa model *stacking* memiliki performa paling unggul (*precision* 0.91; *F1-score* 0.87; *average precision* hujan sedang-lebat 0.95), sehingga berpotensi besar untuk mendukung sistem peringatan dini cuaca ekstrem di wilayah tropis.

Berdasarkan literatur tersebut, penggunaan LSTM dan *Prophet* baik secara terpisah maupun terintegrasi menawarkan potensi besar dalam meningkatkan akurasi prediksi curah hujan. Keunggulan LSTM dalam menangkap pola jangka panjang dan kompleks, serta kemampuan *Prophet* dalam memodelkan tren musiman dengan efisien menjadi alasan kuat untuk mengeksplorasi keduanya dalam penelitian ini. *Novelty* penelitian ini terletak pada penerapan prediksi dasarian multi-stasiun di Banjarnegara dengan membandingkan *Prophet* LSTM dan model rata-rata sederhana data. Data yang digunakan adalah data curah hujan harian dari 14 pos pengamatan hujan di Kabupaten Banjarnegara yaitu: Banjarmangu, Banjarnegara, Bawang, Clangap, Karangkoar, Krikil, Limbangan, Mandiraja, Penusupan Pejawaran, Rakit, Sigaluh BPP, Stasiun Geofisika Banjarnegara, Susukan dan Wanadadi selama 20 tahun terakhir dari tahun 2005 - 2024.



Gambar 1. Titik Lokasi Penelitian

Data curah hujan tersebut diperoleh dari sistem aplikasi berbasis web yang digunakan oleh Badan Meteorologi, Klimatologi, dan Geofisika untuk mengelola dan memantau data meteorologi, klimatologi, dan geofisika secara online dan terpusat (*BMKGsoft*). Karena keterbatasan alat pengukur curah hujan yang tidak tersedia di semua lokasi di Kabupaten Banjarnegara, maka menggunakan data dari pos pengamatan curah hujan yang sebarannya dapat mewakili beberapa wilayah yang tidak ada pos pengamatan curah hujannya.

### B. Lokasi Penelitian


Lokasi penelitian ditentukan berdasarkan letak geografis dan fluktuasi curah hujan yang menjadi fokus analisis. Data yang digunakan berasal dari sumber sekunder, sehingga posisi stasiun atau titik pengamatan diidentifikasi melalui koordinat lintang dan bujur yang disediakan *BMKGsoft*. Koordinat tersebut menunjukkan persebaran titik pengamatan pada wilayah kajian dan menjadi acuan dalam proses pengolahan serta analisis data. Penyajian informasi lokasi ini bertujuan memberikan gambaran spasial area penelitian serta memastikan keterlacakan hasil yang diperoleh.

**TABEL 1**  
**LOKASI POS PENGAMATAN CURAH HUJAN DI WILAYAH PENELITIAN**

| Nama Pos Hujan                 | Bujur    | Lintang  |
|--------------------------------|----------|----------|
| Banjarmangu                    | 109.6873 | -7.36125 |
| Banjarnegara                   | 109.6941 | -7.39805 |
| Bawang                         | 109.6132 | -7.39883 |
| Clangap                        | 109.6930 | -7.35993 |
| Karangkobar                    | 109.7414 | -7.26779 |
| Krikil                         | 109.4106 | -7.51001 |
| Limbangan                      | 109.7642 | -7.37478 |
| Mandiraja                      | 109.5210 | -7.33020 |
| Penusupan Pejawaran            | 109.7950 | -7.24852 |
| Rakit                          | 109.5308 | -7.45302 |
| Sigaluh BPP                    | 109.7634 | -7.39702 |
| Stasiun Geofisika Banjarnegara | 109.4200 | -7.1900  |
| Susukan                        | 109.3988 | -7.49135 |
| Wanadadi                       | 109.6258 | -7.3686  |

### C. Metode Penelitian dan Evaluasi

Penelitian ini mengimplementasikan dua algoritma peramalan deret waktu yaitu *Prophet* dan *Long Short-Term Memory (LSTM)* dalam memprediksi curah hujan dasarian selama periode Januari hingga Desember 2025. Pemodelan dilakukan untuk mengidentifikasi pola distribusi curah hujan serta mengevaluasi kinerja kedua pendekatan dalam menghasilkan prediksi yang akurat. Pendekatan ini bersifat terapan, mengingat hasil prediksi yang diperoleh dapat digunakan sebagai dasar dalam perumusan kebijakan, terutama pada sektor - sektor yang rentan terhadap variabilitas iklim, seperti pertanian, sumber daya air dan mitigasi bencana hidrometeorologi. Tahapan kegiatan penelitian disusun secara sistematis sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Tahapan Penelitian

Penelitian ini menggunakan pendekatan *kuantitatif* berbasis analisis deret waktu untuk memprediksi curah hujan dengan dua model utama, yaitu *LSTM* dan *Prophet*, yang keduanya dioptimasi menggunakan *Optuna*. Hasil prediksi dari kedua model kemudian digabungkan melalui metode rata-rata (*ensemble averaging*) guna memperoleh estimasi yang lebih stabil dan akurat.

### 1. Pengumpulan Data

Tahapan awal dalam penelitian dimulai dengan pengumpulan data sebagai fondasi utama proses analisis. Kualitas dan kuantitas data yang dikumpulkan sangat berpengaruh terhadap akurasi model prediksi. Data yang digunakan berupa deret waktu curah hujan dalam interval harian yang dikumpulkan melalui pengukuran menggunakan *ombrometer* di sejumlah wilayah di Kabupaten Banjarnegara. Seluruh data hasil pengukuran dihimpun dan dipusatkan di Stasiun Klimatologi Jawa Tengah. Data tersebut kemudian dimasukkan ke dalam aplikasi *BMKGsoft* untuk pengelolaan awal. Format data disusun dalam bentuk time series menggunakan *Microsoft Excel* yang memuat informasi tanggal, lokasi pengamatan, serta nilai curah hujan dasarian dalam satuan *milimeter*. Hasil pengolahan data *Excel* digunakan sebagai input awal untuk tahapan berikutnya. Data tersebut kemudian diproses melalui tahap *preprocessing* menggunakan pemrograman *Python*. Proses ini menghasilkan format data yang siap digunakan sebagai dataset dalam pemodelan prediksi.

### 2. Preprocessing

Data mentah diperiksa untuk mengidentifikasi nilai hilang (*missing values*). Penanganan dilakukan dengan interpolasi spline dan Piecewise Cubic Hermite Interpolating Polynomial (PCHIP). Setelah itu, data diagregasi ke skala dasarian (10 harian). Untuk model LSTM, data dinormalisasi dengan *MinMaxScaler()*, sementara Prophet tetap menggunakan skala aslinya. Dataset kemudian dibagi menjadi data latih (80%) dan data uji (20%). Normalisasi hanya diterapkan pada model LSTM karena model ini sensitif terhadap skala data. Teknik Min-Max Scaling digunakan untuk mengubah nilai fitur ke dalam rentang  $[0, 1]$  menggunakan rumus:

$$x' = \frac{x - X_{min}}{X_{max} - X_{min}}$$

Proses ini dilakukan dengan bantuan *MinMaxScaler* dari *sklearn.preprocessing*. Sebaliknya, *Prophet* tidak memerlukan *normalisasi* karena mampu menangani data dalam skala aslinya melalui pendekatan statistik yang dimilikinya.

### 3. Modelling

#### a. Model Prophet

Model *Prophet* adalah *open-source software* yang dikembangkan oleh Tim Data Sains Facebook pada tahun 2017 yang dirancang untuk menangani fitur umum data *time series* dan tersedia dalam bentuk *library* di *Python* dan *R*. Model ini menggunakan model *regresi modular* sederhana yang sering bekerja dengan baik dengan parameter default. *Prophet* menggunakan model aditif (*additive model*) dengan tiga komponen utama.

$$y(t) = g(t) + s(t) + h(t) + \epsilon t \quad (1)$$

Dari persamaan diatas  $g(t)$  merupakan fungsi tren yang memodelkan perubahan non-periodik dari data *time series*,  $s(t)$  merepresentasikan pola berulang secara periodik (seperti musiman mingguan dan tahunan),  $h(t)$  merepresentasikan fluktuasi jangka panjang yang tidak terikat periode tertentu (beda dengan musiman), dan  $\epsilon t$  yaitu istilah bagian data yang tidak bisa dijelaskan oleh tren, musiman, atau siklus. Komponen Tren  $g(t)$ , memiliki dua pilihan metode. yaitu Tren Logistik (*Logistic Growth*) jika data memiliki batas saturasi atau *piecewise linear* dan Tren Linear (*Piecewise Linear*) untuk tanpa saturasi.

$$g(t) = \frac{C}{1} + e^{-k(t-m)} \quad (2)$$

$$g(t) = (k + a(t)^T \delta) \cdot t + (m + a(t)^T \gamma) \quad (3)$$

Persamaan (1) persamaan untuk *Logistic Growth* dan persamaan (2) merupakan persamaan Tren Linear (*Piecewise Linear*).

Komponen Musiman  $s(t)$ . menggunakan deret *Fourier* untuk memodelkan musiman.

$$s(t) = \sum_{n=1}^N \left( a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \quad (4)$$

Komponen Hari Libur  $h(t)$

$$h(t) = \sum_{i=1}^L \kappa_i \cdot 1_{\{t \in D_i\}} \quad (5)$$

Berdasarkan persamaan di atas model ini memiliki sejumlah parameter penting. Parameter penting meliputi laju pertumbuhan  $k$ , titik perubahan  $\delta$ , dan offset  $\gamma$ .

Dalam penelitian ini, *Prophet* dioptimalkan menggunakan *Optuna* untuk menemukan kombinasi *hyperparameter* terbaik, khususnya *changepoint\_prior\_scale* dan *seasonality\_prior\_scale*, yang memengaruhi sensitivitas tren dan kompleksitas musiman. Pemodelan dilakukan dengan *multiplicative seasonality* serta komponen musiman harian, mingguan, dan tahunan. Prediksi dibuat hingga 36 periode (frekuensi dasarian), dengan evaluasi menggunakan RMSE pada 144 titik waktu terakhir (sekitar 4 tahun). Model dilatih dengan data 2005–2020, divalidasi dengan *rolling window* 2021–2024, lalu digunakan untuk menghasilkan prediksi *out-of-sample* tahun 2025. Rentang pencarian *hyperparameter Prophet* menggunakan *Optuna* disajikan pada tabel 2.

**TABEL 2**  
KONFIGURASI HYPERPARAMETER PROPHET (OPTUNA)

| Nama Hyperparameter            | Rentang Nilai     |
|--------------------------------|-------------------|
| <i>changepoint_prior_scale</i> | 0.001 – 0.5 (log) |
| <i>seasonality_prior_scale</i> | 0.01 – 20.0 (log) |

#### b. Model Long Short-Term Memory (LSTM)

LSTM adalah varian yang sangat baik dari RNN karena dapat menambang karakteristik temporal data dengan akurasi yang tinggi. Untuk mengukur status karakteristik historis menggunakan ketergantungan jangka panjang data pembelajaran dengan LSTM meningkatkan akurasi prediksi. Berikut adalah gambar Unit Jaringan Dasar LSTM.

$$i_t = \sigma(W_1 X + b_1). \quad (6)$$

$$f_t = \sigma(W_2 X + b_2). \quad (7)$$

$$o_t = \sigma(W_3 X + b_3). \quad (8)$$

$$g_t = \tanh(W_4 X + b_4). \quad (9)$$

$$c_t = c_{t-1} * f_t + g_t * i_t. \quad (10)$$

$$h_t = \tanh(\tanh(c_t) * o_t) \quad (11)$$

dengan  $f_t$  sebagai *forget gate*,  $i_t$  sebagai *input gate*,  $o_t$  sebagai *output gate*,  $c_t$  sebagai *cell state*, dan  $h_t$  sebagai *hidden state*. Fungsi  $\sigma$  adalah *sigmoid*, sedangkan  $\tanh$  merupakan fungsi aktivasi *hiperbolik*. Persamaan tersebut menggambarkan bagaimana LSTM memutuskan informasi mana yang dipertahankan atau dilupakan pada setiap langkah waktu, sehingga model lebih efektif dalam menangani data deret waktu yang panjang. Model LSTM dalam penelitian ini dirancang secara fleksibel dan dioptimalkan menggunakan algoritma *Optuna*. Proses pelatihan dijalankan hingga maksimal 50 *epoch* lapisan *dense*, diakhiri dengan lapisan output regresi. Proses pelatihan dijalankan hingga maksimal 50 *epoch*.

**TABEL 3**  
KONFIGURASI HYPERPARAMETER LSTM (OPTUNA)

| Nama Hyperparameter | Rentang Nilai                                  |
|---------------------|------------------------------------------------|
| lookback            | 18. 36                                         |
| n_layers            | 1 – 5                                          |
| units per layer     | 16. 32. 64. 128 (dipilih untuk setiap lapisan) |
| dropout             | 0.1 – 0.2 (dengan langkah 0.1)                 |
| batch_size          | 256 – 2048 (dengan langkah 256)                |

#### 4. EVALUASI MODEL

Kinerja kedua model diukur untuk melihat seberapa akurat prediksinya. Metrik evaluasi menggunakan data uji (*test data*). Evaluasi model merupakan kegiatan yang dilakukan untuk mengevaluasi performa model menggunakan matrik RMSE ( *Root Mean Square Error* ) dan MAE ( *Mean Absolute Error* ) menurut Bin Hilmi [19]. RMSE adalah akar kuadrat dari rata-rata kuadrat kesalahan, metrik ini membantu mengukur tingkat kesalahan (*error*) antara nilai yang diprediksi dan nilai aktual yang diamati. Evaluasi dilakukan dengan membandingkan hasil, semakin rendah nilai RMSE maka semakin baik kinerja model. Menurut Chhetri [1] MAE merupakan metrik evaluasi untuk mengukur rata – rata kesalahan absolut (perbedaan absolut) antara nilai yang prediksi dan nilai yang diamati sebenarnya. Semakin akurat model dalam prediksinya, semakin rendah nilai MAE dengan perhitungannya sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$n$  adalah jumlah titik yang diamati,  $y_i$  adalah nilai aktual yang diamati pada titik ke –  $i$ .  $\hat{y}_i$  adalah nilai yang prediksi pada titik  $i$ ,  $\sum$  = notasi penjumlahan dari  $i = 1$  hingga  $n$   $|y_i - \hat{y}_i|$  adalah nilai *absolut* (selisih tanpa tanda negatif),  $\bar{y}$  = rata-rata dari semua nilai aktual.

### III. HASIL DAN PEMBAHASAN


Hasil prediksi curah hujan diuji menggunakan model LSTM dan *Prophet* yang telah dioptimasi dengan *Optuna*, serta rata-rata keduanya, pada 14 lokasi. Evaluasi dilakukan dari data historis 2021-2024 dengan menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Nilai RMSE dan MAE yang lebih rendah menunjukkan prediksi lebih akurat dan stabil.

**TABEL 4**  
MATRIK EVALUASI 14 LOKASI

|                                   | LSTM  |       | Prophet |       | Rataan |       |
|-----------------------------------|-------|-------|---------|-------|--------|-------|
|                                   | RMSE  | MAE   | RMSE    | MAE   | RMSE   | MAE   |
| Banjarmangu                       | 88.05 | 50.48 | 82.97   | 48.9  | 82.03  | 46.99 |
| Banjarnegara                      | 63.3  | 51.87 | 61.68   | 50.2  | 61.04  | 50.29 |
| Bawang                            | 60.49 | 46.85 | 58.44   | 42.69 | 57.75  | 43.20 |
| Clangap                           | 82.44 | 68.64 | 80.12   | 63.60 | 80.27  | 65.44 |
| Karangkobar                       | 73.79 | 54.59 | 69.92   | 51.15 | 69.85  | 51.18 |
| Krikil                            | 82.86 | 62.83 | 82.62   | 62.11 | 80.70  | 61.18 |
| Limbangan                         | 76.10 | 59.62 | 71.34   | 55.9  | 71.83  | 56.92 |
| Mandiraja                         | 75.10 | 54.83 | 75.84   | 55.10 | 73.49  | 53.57 |
| Penusupan Pejawaran               | 68.70 | 54.21 | 65.58   | 50.03 | 64.87  | 50.23 |
| Rakit                             | 68.81 | 51.56 | 62.17   | 46.56 | 63.39  | 47.87 |
| Sigaluh BPP                       | 68.81 | 55.10 | 64.68   | 51.06 | 64.82  | 51.93 |
| Stasiun Geofisika<br>Banjarnegara | 72.60 | 58.81 | 70.05   | 55.53 | 69.55  | 56.05 |
| Susukan                           | 74.16 | 55.27 | 70.10   | 53.65 | 70.73  | 53.25 |
| Wanadadi                          | 87.61 | 69.07 | 83.25   | 48.95 | 91.89  | 67.56 |

Berdasarkan Tabel 4, hasil evaluasi menunjukkan bahwa model *Prophet* umumnya memiliki kinerja yang lebih baik dibandingkan dengan LSTM pada sebagian besar lokasi. Hal ini ditunjukkan oleh nilai RMSE rata-rata sebesar 69.55 dan MAE rata-rata 53.05 untuk *Prophet*, yang lebih rendah dibandingkan LSTM dengan RMSE 73.03 dan MAE 55.72. Salah satu hasil terbaik ditunjukkan pada lokasi Bawang, di mana *Prophet* menghasilkan MAE terendah yaitu 42.69, menandakan akurasi prediksi yang tinggi. Meskipun demikian, terdapat beberapa lokasi seperti Clangap dan Wanadadi yang masih menunjukkan nilai kesalahan relatif tinggi pada kedua model, yang mengindikasikan pola data lebih kompleks atau fluktuatif. Secara keseluruhan, *Prophet* lebih unggul dalam menangkap pola tren pada data deret waktu ini, namun pemilihan model tetap perlu disesuaikan dengan karakteristik data di masing-masing lokasi.


Sementara itu, model rata-rata cenderung memberikan hasil menengah, namun tetap kompetitif. Contohnya di lokasi Susukan dan Mandiraja, rata-rata model menghasilkan MAE lebih rendah dibandingkan dua pendekatan lainnya. Namun di lokasi Wanadadi, *Prophet* dan rata-rata sama-sama menghasilkan nilai yang tinggi, yang mungkin mengindikasikan adanya pola data yang sulit diprediksi secara konsisten oleh kedua model. Berikut adalah perbandingan data aktual dengan hasil prediksi model LSTM dan *Prophet* pada 14 pos hujan di Banjarnegara.



Gambar 3 Line Chart Hasil Prediksi Curah Hujan di 14 Lokasi

Gambar 3 merupakan evaluasi model LSTM, *Prophet*, dan rataannya dalam mempelajari data lampau dari 2021-2024. Hasil dari ketiga model, yaitu LSTM, *Prophet*, dan rataannya, menunjukkan keterbatasan dalam memprediksi fluktuasi data aktual. Secara umum, model-model tersebut hanya dapat mengikuti tren data secara kasar, dan seringkali gagal menangkap puncak dan lembah yang tajam atau perubahan yang cepat. Model LSTM dan *Prophet*, meskipun lebih baik dari rataannya, masih belum mampu mereplikasi fluktuasi tajam pada data aktual. Garis prediksi dari kedua model ini (merah dan oranye) cenderung lebih halus dan melakukan "perataan" data dibandingkan dengan data aktual yang lebih bergejolak (biru). Hal ini mengindikasikan bahwa model-model ini hanya mampu menangkap pola secara kasar dan mungkin memerlukan penyesuaian lebih lanjut untuk meningkatkan akurasi. Sementara itu, model rataannya (*Mean*) gagal merespons setiap lonjakan atau penurunan data aktual. Ini terjadi karena model rataannya didapat dengan merata-rata hasil prediksi dari model *Prophet* dan LSTM, yang menyebabkan prediksi menjadi lebih stabil dan tidak sensitif terhadap fluktuasi tajam yang ada pada data aktual. Keterbatasan ini menegaskan bahwa pendekatan rata-rata dari kedua model canggih tersebut tidak cocok untuk peramalan deret waktu yang memiliki pola dinamis atau musiman.

Grafik hasil *inference* ditampilkan untuk mengilustrasikan pola estimasi curah hujan dari masing-masing model. Tampilan ini merepresentasikan bentuk output prediksi berdasarkan input historis yang telah dilatih sebelumnya tanpa membandingkan secara langsung dengan data observasi. Visualisasi ini digunakan untuk menilai struktur umum prediksi yang dihasilkan oleh model secara temporal.

Gambar 4 Hasil *Inference* di Semua Lokasi

Berdasarkan Gambar 4. hasil inferensi dari model LSTM terlihat lebih halus dan tidak fluktuatif dibandingkan *Prophet*. Kurva prediksi LSTM cenderung mengikuti tren umum secara perlahan tanpa banyak variasi tajam yang mengindikasikan bahwa model ini kurang responsif terhadap perubahan nilai aktual yang bersifat lokal atau mendadak. Hal ini dapat disebabkan oleh proses normalisasi menggunakan *MinMaxScaler* serta karakteristik LSTM yang mengandalkan memori jangka panjang sehingga lebih fokus pada pola global. Sebaliknya, *Prophet* menunjukkan kemampuan yang lebih baik dalam menangkap fluktuasi lokal, termasuk perubahan musiman yang tajam sehingga memberikan hasil prediksi yang lebih adaptif terhadap dinamika data curah hujan bulanan.

#### IV. KESIMPULAN

Berdasarkan evaluasi menggunakan metrik RMSE dan MAE pada 14 lokasi pengamatan, model *Prophet* menunjukkan kinerja yang secara konsisten lebih baik dibandingkan LSTM, terutama di Banjarmangu, Purwonegoro, Rakit, Bawang, dan Karangobar. Nilai RMSE terendah tercatat pada model rata-rata di Bawang sebesar 57.75, sedangkan tertinggi pada LSTM di Banjarmangu sebesar 88.05. Untuk MAE, nilai terendah diperoleh pada model rata-rata di Bawang sebesar 43.20. sementara tertinggi pada *Prophet* di Wanadadi sebesar 83.25. Pendekatan rata-rata LSTM–*Prophet* memberikan hasil kompetitif di beberapa lokasi, seperti Stasiun Geofisika Banjarnegara, Susukan, dan Mandiraja, meskipun umumnya berada di antara performa masing-masing model tunggal. Visualisasi prediksi menunjukkan bahwa LSTM menghasilkan kurva yang lebih halus dan stabil, namun kurang responsif terhadap perubahan lokal yang tajam. Sebaliknya, *Prophet* mampu menangkap pola musiman dan fluktuasi mendadak secara lebih adaptif, sehingga lebih sesuai digunakan untuk memodelkan dinamika curah hujan dasarian. Secara keseluruhan, *Prophet* direkomendasikan sebagai metode utama dalam prediksi curah hujan pada wilayah kajian ini, sedangkan kombinasi rata-rata kedua model dapat menjadi alternatif yang efektif pada kondisi tertentu.

Penelitian ini membandingkan kinerja algoritma *Prophet* dan LSTM dalam memprediksi curah hujan dasarian di Kabupaten Banjarnegara. Hasil evaluasi menunjukkan bahwa *Prophet* secara umum lebih akurat dibandingkan LSTM, dengan nilai RMSE dan MAE yang lebih rendah pada sebagian besar lokasi. Model rata-rata (*ensemble averaging*) memberikan hasil yang stabil, namun kurang sensitif terhadap fluktuasi ekstrem. Puncak curah hujan kategori tinggi hingga sangat tinggi (>151 mm) teridentifikasi terutama pada periode Desember–Maret yang bertepatan dengan musim hujan utama. Temuan ini menegaskan bahwa *Prophet* lebih sesuai untuk mendukung sistem peringatan dini dan mitigasi bencana hidrometeorologi di wilayah rawan longsor seperti Banjarnegara.

#### REFERENSI

- [1] M. Chhetri, S. Kumar, P. P. Roy, and B. G. Kim, “Deep BLSTM-GRU model for monthly rainfall prediction: A case study of Simtokha, Bhutan,” *Remote Sens.*, vol. 12, no. 19, pp. 1–13, 2020, doi: 10.3390/rs12193174.
- [2] A. Z. Al-Ozeer, M. A. Abdaki, A. R. Al-Iraqi, S. H. Al-Samman, and N. A. Al-Hammadi, “Estimation of mean areal rainfall and missing data by using gis in nineveh, northern Iraq,” *Iraqi Geol. J.*, vol. 53, no. 1, pp. 93–103, 2020, doi: 10.46717/igj.53.1e.7ry-2020-07.07.
- [3] N. M. M. Candra Devi, I. P. A. Bayupati, and N. K. A. Wirdiani, “Prediksi Curah Hujan Dasarian dengan Metode Vanilla RNN dan LSTM untuk Menentukan Awal Musim Hujan dan Kemarau,” *J. Edukasi dan Penelit. Inform.*, vol. 8, no. 3, p. 405, 2022, doi: 10.26418/jp.v8i3.56606.
- [4] J. Pebralia, “Analisis Curah Hujan Menggunakan Machine Learning Metode Regresi Linier Berganda Berbasis Python dan Jupyter Notebook,” *J. Ilmu Fis. dan Pembelajarannya*, vol. 6, no. 2, pp. 23–30, 2022, doi: 10.19109/jifp.v6i2.13958.
- [5] D. Rizkya, H. Roosaputri, and C. Dewi, “Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka Theme Park),” *J. Penerapan Sist. Informatika (Komputer Manajemen)*, vol. 4, no. 3, pp. 507–517, 2023.
- [6] C. Chandra and S. Budi, “Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru,” *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, pp. 278–287, 2020, doi: 10.28932/jutisi.v6i2.2676.
- [7] Rahman. A.Z, “Kajian Mitigasi Bencana Tanah Longsor di Kabupaten Banjarnegara,” *Gema Publica*, vol. 1, no. 1, pp. 1–14, 2015.
- [8] I. NEFERTITI AURELIA FADIAHAYA, Dr. Ir. Catur Aries Rokhmana, S.T., M.T., “Pemetaan Risiko Bencana Tanah Longsor Studi Kasus: Kabupaten Banjarnegara,” pp. 9–10, 2024.
- [9] H. F. Freecenta, E. Yulia Puspaningrum, and H. Maulan, “Prediksi Curah Hujan Di Kab. Malang Menggunakan LSTM (Long Short Term Memory),” *J. Inform. dan Sist. Inf.*, vol. 3, no. 1, pp. 51–55, 2022, doi: 10.33005/jifosi.v3i1.448.

- [10] N. Neeraj, J. Mathew, M. Agarwal, and R. K. Behera, "Long short-term memory-singular spectrum analysis-based model for electric load forecasting," *Electr. Eng.*, vol. 103, no. 2, pp. 1067–1082, 2021, doi: 10.1007/s00202-020-01135-y.
- [11] K. Skarlatos, E. S. Bekri, D. Georgakellos, P. Economou, and S. Bersimis, "Projecting Annual Rainfall Timeseries Using Machine Learning Techniques," *Energies*, vol. 16, no. 3, pp. 1–20, 2023, doi: 10.3390/en16031459.
- [12] A. Sulasikin, Y. Nugraha, J. I. Kanggrawan, and A. L. Suherman, "Monthly Rainfall Prediction Using the Facebook Prophet Model for Flood Mitigation in Central Jakarta," *8th Int. Conf. ICT Smart Soc. Digit. Twin Smart Soc. ICISS 2021 - Proceeding*, no. August 2021, 2021, doi: 10.1109/ICISS53185.2021.9532507.
- [13] A. Hasnain *et al.*, "Time Series Analysis and Forecasting of Air Pollutants Based on Prophet Forecasting Model in Jiangsu Province, China," *Front. Environ. Sci.*, vol. 10, no. July, pp. 1–12, 2022, doi: 10.3389/fenvs.2022.945628.
- [14] C. B. Aditya Satrio, W. Darmawan, B. U. Nadia, and N. Hanafiah, "Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET," *Procedia Comput. Sci.*, vol. 179, no. 2020, pp. 524–532, 2021, doi: 10.1016/j.procs.2021.01.036.
- [15] O. Triebe, H. Hewamalage, P. Pilyugina, N. Laptev, C. Bergmeir, and R. Rajagopal, "NeuralProphet: Explainable Forecasting at Scale," pp. 1–40, 2021, [Online]. Available: <http://arxiv.org/abs/2111.15397>
- [16] S. Arslan, "A hybrid forecasting model using LSTM and Prophet for energy consumption with decomposition of time series data," *PeerJ Comput. Sci.*, vol. 8, no. 2020, 2022, doi: 10.7717/PEERJ-CS.1001.
- [17] M. J. A. Shohan, "Forecasting of Electric Load Using a Hybrid LSTM-Neural Prophet Model," pp. 1–18, 2022.
- [18] A. D. Hartanto, Y. N. Kholik, and Y. Pristyanto, "Stock Price Time Series Data Forecasting Using the Light Gradient Boosting Machine (LightGBM) Model," *Int. J. Informatics Vis.*, vol. 7, no. 4, pp. 2270–2279, 2023, doi: 10.30630/joiv.7.4.1740.
- [19] M. Z. Bin Hilmi, T. Anwar, and D. R. B. A. Rambli, "Long Short-Term Memory With Gated Recurrent Unit Based on Hyperparameter Settings and Hybridization for Reference Evapotranspiration Rate Prediction," *J. Theor. Appl. Inf. Technol.*, vol. 100, no. 22, pp. 6702–6714, 2022.