

MODEL PREDIKSI CURAH HUJAN HARIAN KOTA PADANG MENGUNAKAN DEEP NEURAL NETWORK (DNN)

Aisyah Fadri¹, Satrio Junaidi², Ainil Mardiyah³

Universitas PGRI Sumatera Barat, Padang

e-mail: ¹aisyahfadri14@gmail.com, ²satriojunaidy@gmail.com, ³m.ainil@yahoo.com

Abstract: *Extreme weather in coastal areas such as Kota Padang is influenced by complex topography and local atmospheric dynamics, making daily rainfall prediction a critical challenge for disaster mitigation and sectoral planning. This study aims to develop a daily rainfall prediction model using a Deep Neural Network (DNN) and evaluate its performance. The dataset consists of daily temperature, humidity, and air pressure data collected from the Automatic Weather Station (AWS) of BMKG Maritime Teluk Bayur from January 2020 to December 2024, comprising 1,823 samples after preprocessing. The research methodology follows the CRISP-DM framework, which includes six main phases. The proposed DNN architecture contains three hidden layers (128, 64, and 32 neurons) with ReLU activation and dropout regularization, enhanced by lag and rolling average features to capture temporal patterns. The model achieved an MAE of 1.79, RMSE of 17.31, and R² of 0.8972, indicating strong predictive performance. The model was deployed through a Streamlit-based interactive dashboard.*

Keyword: *Deep Neural Network (DNN); rainfall prediction; CRISP-DM; meteorological data; deep learning.*

Abstrak: Cuaca ekstrem di wilayah pesisir seperti Kota Padang dipengaruhi oleh topografi kompleks dan dinamika atmosfer lokal, sehingga prediksi curah hujan harian menjadi tantangan penting bagi mitigasi bencana dan perencanaan sektor terkait. Penelitian ini bertujuan membangun model prediksi curah hujan harian menggunakan *Deep Neural Network (DNN)* serta mengevaluasi kinerjanya. Data yang digunakan merupakan data harian suhu, kelembaban, dan tekanan udara dari *Automatic Weather Station (AWS)* BMKG Maritim Teluk Bayur periode Januari 2020 hingga Desember 2024 dengan 1.816 sampel setelah pra-pemrosesan. Metodologi mengacu pada kerangka CRISP-DM yang mencakup enam tahapan utama. Arsitektur DNN terdiri dari tiga lapisan tersembunyi (128, 64, 32 neuron) dengan aktivasi ReLU dan dropout, serta fitur lag dan *rolling average* untuk menangkap pola temporal. Model menghasilkan MAE 1,79, RMSE 17,31, dan R² 0,8972, menunjukkan performa prediksi yang baik. Implementasi dilakukan melalui dashboard berbasis Streamlit.

Kata kunci: Deep Neural Network (DNN); prediksi curah hujan; CRISP-DM; data meteorologi; pembelajaran mendalam.

PENDAHULUAN

Cuaca merupakan sistem atmosfer yang dinamis dan berpengaruh terhadap berbagai sektor strategis seperti pertanian, transportasi, dan kesehatan. Peningkatan variabilitas iklim global serta frekuensi kejadian cuaca ekstrem dalam beberapa tahun terakhir menimbulkan tantangan serius dalam proses prakiraan cuaca,

khususnya di wilayah tropis (Meenal et al., 2021). Indonesia sebagai negara tropis dengan pola musim yang dipengaruhi dinamika atmosfer regional memiliki karakteristik curah hujan yang fluktuatif dan sulit diprediksi. Ketidakpastian tersebut berdampak langsung pada peningkatan risiko banjir, kekeringan, serta gangguan aktivitas sosial-ekonomi,

sehingga diperlukan sistem prediksi curah hujan harian yang akurat dan adaptif.

Kondisi kompleks tersebut juga terjadi di Kota Padang, wilayah pesisir dengan topografi pegunungan yang memengaruhi interaksi suhu, kelembaban, dan tekanan udara secara non-linear. Kejadian hujan ekstrem pada 7 Maret 2024 dengan intensitas 394,6 mm/hari menunjukkan tingginya variabilitas curah hujan dan keterbatasan pendekatan prediksi konvensional dalam menangkap dinamika lokal (Alnur et al., 2023). Urbanisasi serta pengaruh sirkulasi darat–laut semakin memperumit pola atmosfer regional (Alvines et al., 2025). Data pengamatan cuaca di wilayah ini direkam melalui *Automatic Weather Station* (AWS) yang menyediakan data meteorologis kontinu dan beresolusi tinggi, sehingga berpotensi mendukung pengembangan model prediksi berbasis data (Ariffudin & Musa, 2022).

Pendekatan statistik klasik sering kali tidak mampu merepresentasikan hubungan non-linear antar variabel meteorologis. Perkembangan kecerdasan buatan, khususnya *deep learning*, memungkinkan pembelajaran pola kompleks dari data historis secara lebih mendalam (Novita, 2013). *Deep learning* memiliki kemampuan representasi fitur bertingkat yang mampu mengekstraksi pola tersembunyi dari data atmosfer (Yafik & Chairani, 2025). Penelitian sebelumnya menunjukkan bahwa jaringan saraf tiruan mampu meningkatkan akurasi prediksi curah hujan dibandingkan metode konvensional, sebagaimana ditunjukkan oleh Rubangi et al. (2021) di wilayah Yogyakarta, Septiadi (2020) di Kalimantan, serta Hendrianto et al. (2022) yang menegaskan pengaruh signifikan suhu, kelembaban, dan tekanan udara terhadap akurasi model prediksi.

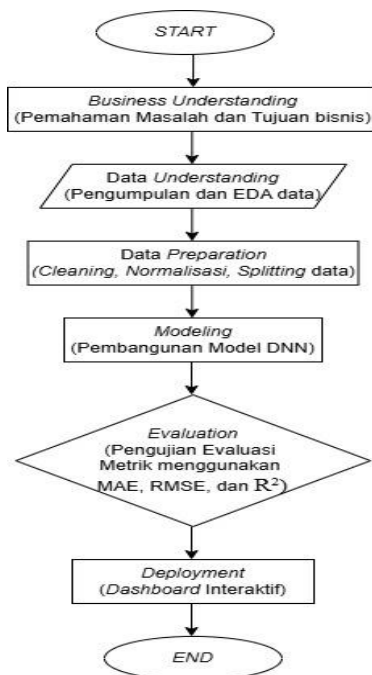
Meskipun berbagai studi telah membuktikan potensi *neural network* dalam prediksi curah hujan, penerapan model *Deep Neural Network* (DNN) berbasis data AWS secara spesifik pada wilayah pesisir Kota Padang masih terbatas (Sumihar et al., n.d.).

Kompleksitas pola hubungan antarparameter meteorologis di wilayah ini memerlukan pendekatan yang mampu mempelajari relasi non-linear secara lebih mendalam dan adaptif terhadap dinamika lokal. Oleh karena itu, penelitian ini bertujuan membangun model prediksi curah hujan harian berbasis *Deep Neural Network* (DNN) menggunakan data suhu, kelembaban, dan tekanan udara dari AWS BMKG Maritim Teluk Bayur. Pengembangan model dilakukan menggunakan kerangka CRISP-DM untuk memastikan proses yang sistematis, mulai dari pemahaman data hingga evaluasi model. Hasil penelitian diharapkan dapat memberikan kontribusi dalam peningkatan akurasi prakiraan curah hujan harian serta mendukung mitigasi risiko hidrometeorologi di wilayah pesisir Kota Padang.

METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang berfokus pada pengujian kinerja metode *Deep Neural Network* (DNN) dalam memprediksi curah hujan harian di wilayah pesisir Kota Padang. Data yang digunakan merupakan data sekunder yang diperoleh dari *Automatic Weather Station* (AWS) BMKG Maritim Teluk Bayur, Kota Padang, pada periode Januari 2020 hingga Desember 2024. Dataset terdiri dari 1.825 observasi harian. Variabel dependen dalam penelitian ini adalah curah hujan harian (mm), sedangkan variabel independen meliputi suhu udara (°C), kelembaban udara (%), tekanan udara (mbar) dan curah hujan sebagai target.

Proses pengembangan model mengacu pada kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Kerangka ini dipilih karena menyediakan alur sistematis mulai dari pemahaman masalah hingga implementasi model. Tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

Penelitian dilakukan menggunakan kerangka CRISP-DM yang meliputi business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Pada tahap awal dilakukan pemahaman tujuan penelitian dan karakteristik data, kemudian data dipersiapkan melalui proses pembersihan, penanganan nilai hilang, normalisasi, serta pembagian data latih dan data uji. Selanjutnya dibangun model Deep Neural Network (DNN) untuk mempelajari pola hubungan antarvariabel meteorologi dalam memprediksi curah hujan harian. Kinerja model dievaluasi menggunakan metrik MAE, RMSE, dan R-Squared (R^2). Model yang telah dikembangkan kemudian diimplementasikan dalam bentuk dashboard interaktif untuk mendukung analisis dan prediksi curah hujan harian di Kota Padang.

HASIL DAN PEMBAHASAN

Proses Pemodelan dan Pengujian

Proses analisis data dilakukan

menggunakan pendekatan CRISP-DM (*Cross Industry Standard Process for Data Mining*). Karena pendekatan ini memberikan tahapan yang sistematis dan terstruktur dalam pengembangan model, mulai dari pemahaman masalah hingga evaluasi dan penerapan model.

Business Understanding

Tahap awal dalam metodologi CRISP-DM ini bertujuan untuk memahami kebutuhan dan tujuan bisnis dari penelitian. Berdasarkan hasil wawancara dengan pihak BMKG Maritim Teluk Bayur dan observasi lapangan, diidentifikasi bahwa permasalahan bisnis yang dihadapi adalah prediksi cuaca konvensional seringkali kurang akurat dalam menangkap pola curah hujan di wilayah pesisir Kota Padang yang memiliki karakteristik topografi kompleks, sehingga berdampak pada sektor pertanian, transportasi laut, dan mitigasi bencana banjir. Oleh karena itu, tujuan bisnis yang ingin dicapai adalah membangun model prediksi curah hujan harian yang lebih akurat dengan memanfaatkan data historis meteorologi dan teknologi *deep learning*, sehingga dapat mendukung pengambilan keputusan yang lebih baik dalam perencanaan dan mitigasi risiko bencana.

Data Understanding

Persiapan data dilakukan untuk memahami karakteristik awal dataset yang akan digunakan dalam pemodelan. Berdasarkan hasil eksplorasi data, ada beberapa temuan penting:

```

Data columns (total 5 columns):
#   Column      Non-Null Count  Dtype
---  -
0   Datetime    1825 non-null   datetime64[ns]
1   Suhu        1590 non-null   float64
2   Kelembaban  1590 non-null   float64
3   Tekanan Udara  1590 non-null   float64
4   Curah Hujan  1820 non-null   float64
dtypes: datetime64[ns](1), float64(4)
memory usage: 71.4 KB
None
      Suhu      Kelembaban      Tekanan Udara      Curah Hujan
count  1590.000000  1590.000000  1590.000000  1820.000000
mean   27.028872    82.311514    1001.855445    50.071440
std    1.542104    14.689146    61.909207     163.201476
min    19.655938    0.633333    500.300000     0.000000
25%    26.230527    78.801087    1008.581169    0.000000
50%    27.152083    85.075831    1009.495536    0.653889
75%    27.932955    90.658261    1010.400000    19.186979
max    39.205556    99.999914    1013.952941    1873.400000
Datetime    0
Suhu        235
Kelembaban  235
Tekanan Udara  235
Curah Hujan  5
    
```

Gambar 2 Hasil Eksplorasi Data

Data Preparation

Tahap persiapan data merupakan langkah yang wajib dilakukan untuk memastikan data siap digunakan dalam pemodelan DNN. Langkah pertama yang dilakukan adalah penanganan *datetime* dan pengurutan data berdasarkan waktu untuk mempertahankan urutan temporal yang penting dalam analisis deret waktu. Selanjutnya, untuk mengatasi nilai hilang menggunakan metode *forward fill* dan *backward fill* karena data meteorologi cenderung memiliki pola berkelanjutan, sehingga nilai pengganti yang paling mendekati adalah nilai sebelum dan sesudahnya.

Dalam proses ini, ditemukan satu baris dengan nilai tekanan udara 500,3 mbar pada tanggal tertentu yang secara logika mustahil terjadi di permukaan laut, ini terjadi karena data tersebut merupakan *error* pencatatan sensor. Untuk menjaga integritas data, nilai tersebut diimputasi menggunakan interpolasi linear dari nilai hari sebelumnya dan sesudahnya, sehingga data yang digunakan dalam pemodelan menjadi realistis dan tidak merusak pola.

Karena distribusi curah hujan yang membentuk pola menceng ke kanan (*right-skewed*), yang dimaksud di sini yaitu distribusi curah hujan Kota Padang didominasi oleh nilai rendah (0-10 mm) dengan beberapa kejadian ekstrem yang sangat jarang. Dilakukan transformasi logaritmik menggunakan fungsi `np.log1p` untuk menormalkan distribusi dan meningkatkan kinerja model. Transformasi ini juga mengatasi masalah nilai nol karena $\log 0$ tidak terdefinisi.

Untuk menangkap pola temporal, dilakukan *feature engineering* dengan membuat fitur-fitur baru, yaitu Lag1 (nilai curah hujan 1 hari sebelumnya), Lag2 (nilai curah hujan 2 hari sebelumnya), dan Roll3 (rata-rata bergerak 3 hari). Setelah pembuatan fitur lag, beberapa baris awal menjadi kosong dan dihapus, sehingga data siap pakai berkurang dari 1.825 menjadi 1.823 baris. Data kemudian dibagi menjadi 80% data latih (1.458

sampel) dan 20% data uji (365 sampel) tanpa pengacakan untuk mempertahankan urutan waktu, di mana data latih mencakup periode Januari 2020 hingga pertengahan November 2023 dan data uji mencakup periode pertengahan November 2023 hingga Desember 2024.

Terakhir, normalisasi dilakukan menggunakan *Standard Scaler* yang menstandarisasi fitur menjadi mean = 0 dan standar deviasi = 1, dengan *scaler* hanya dilatih pada data *training* untuk menghindari *data leakage*. Setelah melakukan tahap persiapan data tersebut, diperoleh dataset akhir sebanyak 1.816 sampel hari yang siap digunakan untuk proses pemodelan.

| | Suhu | Kelembaban | Tekanan Udara | Curah Hujan | Curah Hujan Log | Lag1 | Lag2 | Roll3 |
|------------|-----------|------------|---------------|-------------|-----------------|----------|----------|----------|
| 2020-01-04 | 28.221739 | 82.173913 | 1008.734783 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| 2020-01-05 | 28.221739 | 82.173913 | 1008.734783 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| 2020-01-06 | 28.942105 | 75.284737 | 1009.515789 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| 2020-01-07 | 28.495455 | 78.431818 | 1008.181818 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| 2020-01-08 | 26.725000 | 87.391667 | 1007.308333 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 2024-12-27 | 27.733451 | 58.096379 | 1010.065251 | 0.000000 | 0.000000 | 0.000000 | 0.000712 | 0.002904 |
| 2024-12-28 | 27.680998 | 79.431389 | 1009.647014 | 0.000000 | 0.000000 | 0.000000 | 0.000000 | 0.000000 |
| 2024-12-29 | 28.237153 | 70.442153 | 1009.471111 | 0.665139 | 0.509909 | 0.000000 | 0.000000 | 0.169970 |
| 2024-12-30 | 27.055625 | 66.950278 | 1010.230486 | 0.190972 | 0.174770 | 0.509909 | 0.000000 | 0.228226 |
| 2024-12-31 | 27.470786 | 84.289607 | 1009.188624 | 0.000140 | 0.000140 | 0.174770 | 0.509909 | 0.228273 |

Gambar 3 Data akhir setelah proses feature engineering

Modeling

Tahap pemodelan dilakukan dengan membangun arsitektur *Deep Neural Network* menggunakan *framework* TensorFlow Keras. Model DNN yang dibangun memiliki arsitektur dengan *input layer* sebanyak 6 fitur yang terdiri dari Suhu, Kelembaban, Tekanan Udara, Lag1, Lag2, dan Roll3. *Hidden layer* pertama terdiri dari 128 neuron dengan aktivasi ReLU dan *Dropout* sebesar 30%. *Hidden layer* kedua terdiri dari 64 neuron dengan aktivasi ReLU dan *Dropout* sebesar 20%.

Hidden layer ketiga terdiri dari 32 neuron dengan aktivasi ReLU. *Output layer* terdiri dari 1 neuron yang merupakan output prediksi curah hujan. Penggunaan lapisan *Dropout* bertujuan untuk mencegah *overfitting* dengan cara secara acak menonaktifkan sebagian neuron selama pelatihan.

```
Epoch 1/500
73/73 _____ 1s 4ms/step - loss: 0.7639 - mae: 0.7134 - val_loss: 0.197
2 - val_mae: 0.3640
Epoch 2/500
73/73 _____ 0s 2ms/step - loss: 0.2468 - mae: 0.3784 - val_loss: 0.059
9 - val_mae: 0.1908
Epoch 3/500
73/73 _____ 0s 2ms/step - loss: 0.1481 - mae: 0.2945 - val_loss: 0.023
3 - val_mae: 0.1279
...
Epoch 41/500
73/73 _____ 0s 2ms/step - loss: 0.0137 - mae: 0.0777 - val_loss: 0.002
0 - val_mae: 0.0364
...
Epoch 71/500
73/73 _____ 0s 2ms/step - loss: 0.0058 - mae: 0.0473 - val_loss: 0.039
5 - val_mae: 0.1273
...
Training berhenti pada epoch ke-187 (early stopping)
```

Gambar 4 Hasil epoch modeling data

Evaluation

Evaluasi model dilakukan pada data uji yang tidak pernah dilihat model selama pelatihan. Berikut adalah hasil dari evaluasi model:

Tabel 2 Hasil evaluasi metrik

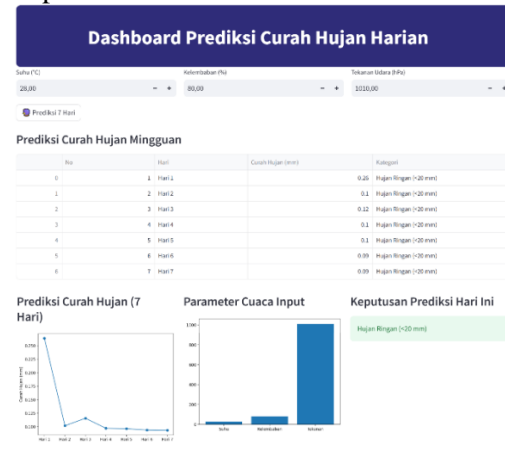
| MAE | RMSE | R ² |
|------|-------|----------------|
| 1.79 | 17.31 | 0.8972 |

Hasil evaluasi menunjukkan bahwa model memiliki kinerja yang sangat baik dalam memprediksi curah hujan harian. Nilai MAE sebesar 1,79 menandakan rata-rata kesalahan prediksi relatif kecil, terutama karena sebagian besar data berada pada kisaran hujan ringan (0–10 mm). Namun, RMSE yang lebih besar yaitu 17,31 mengindikasikan adanya beberapa kesalahan signifikan pada kejadian hujan ekstrem, karena metrik ini lebih sensitif terhadap error besar. Sementara itu, nilai R² sebesar 0,8972 menunjukkan bahwa model mampu menjelaskan 89,72% variasi curah hujan, sehingga memiliki kemampuan generalisasi yang kuat, meskipun masih terdapat sebagian kecil variasi yang dipengaruhi oleh faktor lain di luar variabel yang digunakan dalam penelitian.

Deployment

Tahap akhir dari metodologi ini adalah *deployment*, yaitu penerapan model dalam lingkungan operasional sehingga dapat dimanfaatkan secara nyata. Dalam penelitian ini, *deployment* dilakukan dalam bentuk sebuah *dashboard* interaktif berbasis web

menggunakan *farmwork* streamlit. *Dashboard* ini digunakan untuk memudahkan dalam pengambilan keputusan.



Gambar 5 Dashboard prediksi curah hujan harian

Pembahasan

Penelitian ini berhasil membangun model prediksi curah hujan harian berbasis *Deep Neural Network* (DNN) dengan kinerja yang sangat baik, ditunjukkan oleh nilai MAE sebesar 1,79 mm, RMSE 17,31 mm, dan R² sebesar 0,8972 pada data uji. Nilai R² tersebut menunjukkan bahwa model mampu menjelaskan 89,72% variasi curah hujan harian di Kota Padang. Penerapan arsitektur tiga hidden layer, penambahan fitur lag (Lag1, Lag2) dan *rolling average* (Roll3), serta transformasi logaritmik pada variabel target terbukti efektif dalam meningkatkan kemampuan model menangkap pola non-linear dan karakteristik temporal data deret waktu. Temuan bahwa fitur Lag1 memiliki kontribusi dominan mengindikasikan adanya persistensi curah hujan harian, yang sejalan dengan karakteristik wilayah tropis. Selain itu, kelembaban relatif menunjukkan hubungan positif terhadap curah hujan, mendukung teori meteorologi bahwa kondisi udara mendekati jenuh meningkatkan potensi presipitasi.

Meskipun performa model sangat baik pada rentang curah hujan normal,

perbedaan yang cukup besar antara MAE dan RMSE menunjukkan bahwa model masih kurang optimal dalam memprediksi kejadian hujan ekstrem. Hal ini dipengaruhi oleh ketidakseimbangan data, di mana kejadian ekstrem memiliki proporsi sangat kecil, serta tidak dimasukkannya variabel skala besar seperti fenomena ENSO atau MJO. Dari sisi implementasi, model yang telah diintegrasikan dalam dashboard interaktif berbasis Streamlit memberikan nilai praktis bagi BMKG sebagai alat bantu analisis dan validasi prakiraan harian. Namun, keterbatasan pada jumlah variabel input dan periode data lima tahun menunjukkan bahwa pengembangan lebih lanjut masih diperlukan untuk meningkatkan kemampuan prediksi, khususnya dalam mendeteksi kejadian hujan ekstrem dan memperluas generalisasi model ke wilayah lain.

SIMPULAN

Berdasarkan hasil penelitian, model prediksi curah hujan harian di wilayah pesisir Kota Padang berhasil dibangun menggunakan metode Deep Neural Network (DNN) dengan memanfaatkan data suhu, kelembaban, dan tekanan udara dari BMKG Maritim Teluk Bayur periode Januari 2020–Desember 2024. Model dikembangkan melalui arsitektur tiga lapisan tersembunyi (128, 64, dan 32 neuron) serta penambahan fitur lag dan rolling average untuk menangkap pola temporal. Hasil evaluasi menunjukkan performa yang sangat baik dengan nilai MAE sebesar 1,79, RMSE 17,31, dan R^2 0,8972, yang berarti model mampu menjelaskan 89,72% variasi data curah hujan harian dan menunjukkan bahwa pendekatan DNN cukup akurat untuk digunakan pada wilayah tersebut.

Namun demikian, untuk pengembangan selanjutnya disarankan agar penelitian menggunakan periode data yang lebih panjang guna merepresentasikan variabilitas iklim secara lebih komprehensif, menambahkan

variabel meteorologi lain seperti kecepatan angin, arah angin, tutupan awan, dan radiasi matahari agar kemampuan prediksi meningkat, serta mengembangkan dashboard lebih lanjut dengan menambahkan fitur prediksi waktu terjadinya hujan hingga skala jam agar manfaatnya semakin optimal dalam mendukung kebutuhan operasional.

DAFTAR PUSTAKA

- Afriani, R., Ringo, S., Sitohang, M. O., Silalahi, Z., & Indonesia, U. P. (2026). *PERBANDINGAN KINERJA ALGORITMA LOGISTIC REGRESSION DAN SUPPORT VECTOR MACHINE DALAM PREDIKSI RISIKO PENGGUNAAN NARKOBA*. 4307(April), 2062–2067.
- Alnur, B., Mulyono, Fitri Amillia, & Sutoyo, S. (2023). JITE (Journal of Informatics and Telecommunication Engineering). *Journal of Informatics and Telecommunication Engineering*, 7(1), 102–111. <https://doi.org/10.31289/jite.v9i1.13638>
- Alvines, M., Ravi Wijayanto, M., Archi Daffa Danendra, M., Rizky Herdiansyah, M., Karimsyah Lubis, M., Ichsan Farel Rachmad, M., Ditha Tania, K., & Meiriza, A. (2025). Komparasi Ridge Regression, Random Forest, Dan Gradient Boosting Untuk Prediksi Curah Hujan Harian Di Sumatra Selatan Berbasis Time Series Cross-Validation. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 5742–5748. <https://doi.org/10.36040/jati.v9i4.13915>
- Antonius, T., Kurniawan, D., Setiawan, A., Tita, F., & Tengah, J. (2025). *Perbandingan Kinerja Metode Support Vector Regression dan Metode Regresi Linier Berganda dalam Memprediksi BMI pada Dataset ASTHMA*. 8(2), 133–142.
- Ariffudin, & Musa, P. (2022). *Analisa*

- Sistem Komunikasi Data Berbasis Internet Of Things (IOT) Menggunakan Metode Pieces Pada Sistem Pengamatan Cuaca Otomatis Di Badan Meteorologi Klimatologi Dan Geofisika (BMKG)*. 83–92.
- Arshinta, U. F., & Ahmad, D. (2019). *Analisis Curah Hujan di Kota Padang dengan Menggunakan Rantai Markov*. 2(4), 45–50.
- Darono, A. (2021). *Sains Data Perpajakan di Indonesia*. 1(1), 9–17.
- Hanifah, A. I., & Hermawan, A. (2023). *Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network*. *Komputika : Jurnal Sistem Komputer*, 12(2), 49–56. <https://doi.org/10.34010/komputika.v12i2.9999>
- Kusnadi, H., Taek, Y. S. A., & Supriadi, O. (2020). *Monitoring Suhu, Kelembaban, Dan Tekanan Udara Menggunakan Wireles nRF24L01 Dikampus Unpam Viktor*. 3(1).
- Mazyza, S., Tyas, P., Sarno, R., & Rintyarna, B. S. (2024). *Analisis Perbandingan Metode Klasifikasi Sentimen Berita Saham : Pendekatan Machine Learning , Deep Learning , Transfer Learning , dan Graf*. 9(1), 58–64.
- Meenal, R., Michael, P. A., Pamela, D., & Rajasekaran, E. (2021). *Weather prediction using random forest machine learning model*. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(2), 1208–1215. <https://doi.org/10.11591/ijeecs.v22.i2.pp1208-1215>
- Novita, A. (2013). *Prediksi Pergerakan Harga Saham Pada Bank Terbesar Di Indonesia Dengan Metode Backpropagation Neural Network*. 965–972.
- Oktavia, B. A., Tarigan, A., Pratiwi, C., Putra, F. C., Chrisnawati, G., & Hendrian, Y. (2025). *Clustering Pencemaran Udara Yogyakarta Menggunakan Algoritma K-Means dan Orange Data Mining*. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(2), 3804–3811. <https://doi.org/10.31004/riggs.v4i2.1116>
- Paskalis, E., Orpa, K., & Ripanti, E. F. (2019). *Model Prediksi Awal Masa Studi Mahasiswa*. 7(4), 272–278.
- Priyulida, F., & Sitorus, M. (2026). *ALARM PENDETEKSI DINI BANJIR DI DESA JATI SARI LANGKAT*. 4307(April), 2219–2221.
- Rubangi, Hermawan, A., & Avianto, D. (2021). *Prediksi Curah Hujan Wilayah Provinsi Yogyakarta dengan Algoritma Neural Network*. 3(1).
- Sumihar, P., Juri, K., Lase, D., Lase, J. H., & Immanuel, U. K. (n.d.). *Pengembangan Model Deep Learning dengan Slang-Aware Embeddings untuk Deteksi Promosi Judi Online*. 1479–1487.
- Sze, V., Chen, Y.-H., Yang, T.-J., & Emer, J. (2020). *Efficient Processing of Deep Neural Networks : A Tutorial and Survey*. 1–32.
- Tarumingkeng, R. C. (2024). *Deep Learning*.
- Yafik, M. I., & Chairani, C. (2025). *Optimalisasi Akurasi Prediksi Curah Hujan Bulanan Menggunakan Deep Learning*. 5(5), 1021–1028.