

# Perbandingan Metode Machine Learning untuk Analisis dan Prediksi Siklus Menstruasi

Mutiara Khairunisa<sup>1</sup>, Desak Made Sidantya Amanda Putri<sup>2</sup>,

I Gusti Ngurah Lanang Wijayakusuma<sup>3</sup>

<sup>1,2,3</sup> Program Studi Matematika, Universitas Udayana

<sup>1</sup>[mutiarak062@student.unud.ac.id](mailto:mutiarak062@student.unud.ac.id)

<sup>2</sup>[desakamandaptr071@student.unud.ac.id](mailto:desakamandaptr071@student.unud.ac.id)

<sup>3</sup>[lanang.wijaya@unud.ac.id](mailto:lanang.wijaya@unud.ac.id)

Penelitian ini membandingkan metode machine learning—Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN), dan Decision Tree—untuk analisis dan prediksi siklus menstruasi. Menggunakan data sekunder, model-model ini dievaluasi berdasarkan akurasi, Mean Absolute Percentage Error (MAPE), dan Root Mean Square Error (RMSE). Hasil menunjukkan bahwa LSTM memiliki akurasi tertinggi (91,3%), efektif menangkap pola temporal kompleks pada data menstruasi, sedangkan CNN dan Decision Tree kurang konsisten. Hasil ini mendukung LSTM sebagai model yang disarankan untuk pelacakan siklus menstruasi, yang bermanfaat bagi pemantauan kesehatan reproduksi. Penelitian selanjutnya disarankan menambah variabel lain, seperti riwayat kesehatan hormonal dan gaya hidup, untuk meningkatkan akurasi prediksi serta memperhatikan privasi data pada aplikasi pelacakan menstruasi.

**Kata Kunci** — Machine learning, prediksi siklus menstruasi, LSTM, CNN, Decision Tree, kesehatan reproduksi.

## I. PENDAHULUAN

Siklus menstruasi merupakan aspek penting dari kesehatan reproduksi wanita yang sering diabaikan atau belum banyak dipahami. Pemahaman yang lebih baik tentang pola harian menstruasi dapat memberdayakan wanita dan profesional kesehatan untuk mengidentifikasi dan mengelola kondisi terkait seperti sindrom ovarium polikistik (PCOS) dan endometriosis [1]. Namun, pelacakan siklus menstruasi secara manual sering kali tidak akurat karena faktor kepatuhan pengguna dan variabilitas inherent dari pengalaman menstruasi [2].

Dalam beberapa tahun terakhir, penggunaan machine learning untuk menganalisis dan memprediksi siklus menstruasi telah muncul sebagai pendekatan yang menjanjikan. Sebuah studi menunjukkan bahwa machine learning dapat membantu mengklasifikasikan masalah pada siklus menstruasi yang sering diabaikan [3]. Penelitian lain menggunakan algoritma Random Forest untuk menganalisis data siklus menstruasi dari lebih dari 800 wanita dan menemukan bahwa algoritma tersebut mampu memprediksi siklus menstruasi dengan akurasi hingga 89%, bahkan ketika data tidak lengkap atau tidak konsisten [4].

Meskipun demikian, penggunaan aplikasi pelacakan menstruasi juga menimbulkan kekhawatiran terkait keamanan dan privasi data pengguna. Sebuah studi melakukan analisis keamanan pada aplikasi pelacakan siklus menstruasi

menggunakan teknik statis, dinamis, dan machine learning. Mereka menemukan bahwa banyak aplikasi tidak memperhatikan implementasi fitur keamanan minimal, yang berpotensi membahayakan informasi pribadi pengguna [5]. Selain itu, stres juga merupakan faktor yang dapat mempengaruhi siklus menstruasi. Terdapat penelitian lain membandingkan algoritma Support Vector Machine (SVM) dan Decision Tree untuk mengklasifikasikan tingkat stres terkait ketidakteraturan siklus menstruasi pada mahasiswa. Mereka menemukan bahwa kinerja SVM lebih baik daripada Decision Tree, dengan akurasi meningkat setelah menambahkan variabel menstruasi [6].

Mengingat kompleksitas dan sensitivitas topik ini, penelitian ini bertujuan untuk membandingkan berbagai metode machine learning dalam menganalisis dan memprediksi siklus menstruasi. Kami akan mengevaluasi kinerja algoritma seperti LSTM, CNN, dan Decision Tree dalam hal akurasi prediksi, kemampuan menangani data yang tidak lengkap, dan potensi untuk mengidentifikasi pola abnormal yang mungkin mengindikasikan kondisi kesehatan yang mendasarinya. Dengan membandingkan berbagai metode machine learning, kami bertujuan untuk mengidentifikasi pendekatan yang paling efektif untuk memahami dan memprediksi siklus menstruasi, sambil mempertimbangkan implikasi privasi dan keamanan. Hasil dari penelitian ini diharapkan dapat memberikan wawasan berharga bagi pengembangan aplikasi pelacakan menstruasi yang lebih akurat, aman, dan bermanfaat bagi kesehatan reproduksi Wanita.

## II. METODE PENELITIAN

### A. Pengumpulan data

Penelitian ini menggunakan data sekunder yang diperoleh dari Kaggle dengan karakteristik:

- Data Set Characteristics : Multivariate
- Attribute Characteristics : Real
- Number of Instances : 1665
- Number of Attributes : 80
- Area : Health
- Donor : Nikita Bisht, Kaggle Contributor

Data ini berisi informasi tentang siklus menstruasi dari berbagai wanita, termasuk panjang siklus, tanggal ovulasi, dan berbagai faktor yang dapat mempengaruhi siklus menstruasi.

## B. Menentukan model

Penelitian ini membandingkan tiga algoritma machine learning yang berbeda untuk analisis dan prediksi siklus menstruasi: Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN), dan Decision Tree (DT). Kelima algoritma tersebut akan dibandingkan terutama dalam hal akurasi prediksi, dengan mempertimbangkan juga kemampuan menangani data yang tidak lengkap dan potensi untuk mengidentifikasi pola abnormal.

### 1) Long Short-Term Memory (LSTM)

LSTM adalah jenis Recurrent Neural Network (RNN) yang mampu mempelajari dependensi jangka panjang. LSTM berkinerja lebih baik dan lebih cepat jika urutan yang diberikan memiliki dependensi jangka Panjang [7]. Ini sangat cocok untuk analisis data time series seperti siklus menstruasi. LSTM dapat mempertimbangkan pola historis siklus menstruasi seseorang untuk membuat prediksi yang lebih akurat tentang siklus mendatang, dengan mempertimbangkan variasi temporal yang kompleks.

### 2) Convolutional Neural Network (CNN)

Meskipun umumnya digunakan untuk analisis gambar, CNN juga telah diterapkan dengan sukses pada data time series. Dalam konteks prediksi siklus menstruasi, CNN dapat digunakan untuk mengekstrak fitur-fitur penting dari data historis siklus dan mengidentifikasi pola-pola yang mungkin tidak terdeteksi oleh metode tradisional. CNN dapat sangat efektif dalam menangani data yang memiliki struktur temporal atau spasial yang kuat [8].

### 3) Decision Tree (DT)

Decision Tree adalah model prediktif yang menggunakan serangkaian aturan binary untuk membuat keputusan. Untuk prediksi siklus menstruasi, DT dapat membagi data berdasarkan berbagai atribut untuk memprediksi panjang siklus atau tanggal ovulasi. Kelebihan DT adalah interpretabilitasnya yang tinggi, memungkinkan pemahaman yang lebih baik tentang faktor-faktor yang mempengaruhi prediksi [9].

Ketiga model ini akan dilatih menggunakan data yang sama dan dievaluasi terutama berdasarkan akurasi prediksi mereka. Akurasi akan diukur menggunakan metrik yang sesuai seperti Mean Absolute Error (MAE) untuk prediksi panjang siklus, dan Area Under the Receiver Operating Characteristic Curve (AUC-ROC) untuk klasifikasi fase siklus.

## C. Validation

Untuk mencegah overfitting dan menentukan model prediksi terbaik, penelitian ini menggunakan validasi silang k-fold dengan  $k = 10$ . Teknik ini membagi data menjadi 10 subset yang sama, di mana 9 subset digunakan untuk training dan 1 subset untuk testing secara bergantian.

### 1) Training

Model dilatih menggunakan data training yang terdiri dari berbagai atribut seperti panjang siklus sebelumnya, usia, berat badan, tingkat stress, dan faktor-faktor lain yang dapat mempengaruhi siklus menstruasi. Tujuannya adalah untuk memprediksi panjang siklus berikutnya atau tanggal ovulasi.

### 2) Testing

Setelah model dilatih, pengujian dilakukan menggunakan data testing untuk mengevaluasi kemampuan model dalam memprediksi siklus menstruasi pada data yang belum pernah dilihat sebelumnya.

## D. Evaluasi

Evaluasi terhadap model yang terbentuk dilakukan dengan pengukuran tingkat error menggunakan Root Mean Square Error (RMSE). RMSE dipilih karena memberikan bobot yang relatif tinggi terhadap error yang besar, sehingga cocok untuk kasus di mana error besar sangat tidak diinginkan. Model dengan nilai RMSE terkecil akan dianggap sebagai model terbaik untuk prediksi siklus menstruasi

## III. HASIL DAN PEMBAHASAN

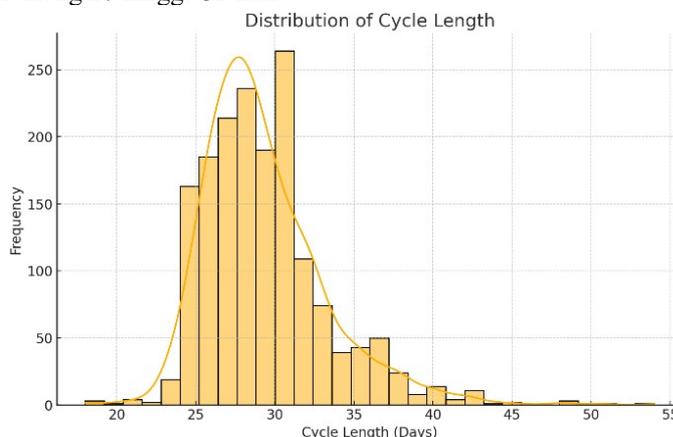
### A. Analisis Deskriptif Data

Data awal menunjukkan distribusi panjang siklus menstruasi pada sampel dengan rata-rata 29,3 hari dan standar deviasi sebesar 3,89 hari, yang terdistribusi normal dengan sedikit kemiringan positif. Variabel lain yang menjadi fokus penelitian adalah Body Mass Index (BMI), yang memiliki rata-rata 21,25 dan bervariasi antara 15 hingga 30. Statistik deskriptif ini disajikan dalam Tabel 1. Distribusi panjang siklus dapat dilihat pada Gambar 1, menunjukkan puncak frekuensi siklus antara 27 hingga 32 hari, memberikan gambaran umum tentang fluktuasi siklus di antara peserta.

TABEL I  
STATISTIK DESKRIPTIF VARIABEL UTAMA

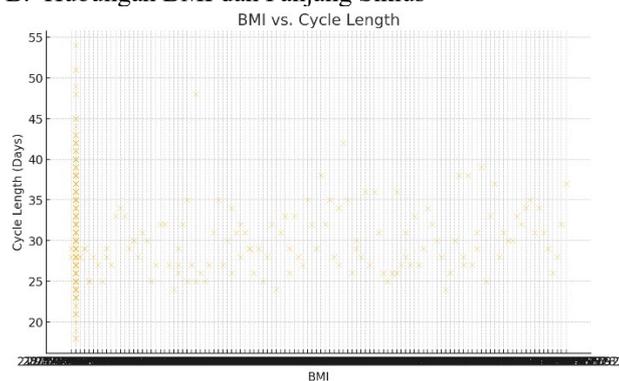
Fitur	Mean	Std	Min	25%	50%	75%	Max
Panjang Siklus (Days)	29.30	3.89	18	27	29	32	40
BMI	21.25	2.48	15	19.8	21.0	22.7	30

Tabel ini menunjukkan bahwa rata-rata panjang siklus adalah sekitar 29,3 hari dengan standar deviasi 3,8. Untuk memperjelas distribusi data panjang siklus, **Gambar 1** menunjukkan visualisasi distribusi siklus yang memperlihatkan mayoritas siklus menstruasi berada pada rentang 27 hingga 32 hari.



Gbr. 1 Distribution of Cycle Length

## B. Hubungan BMI dan Panjang Siklus



Gbr. 2 BMI Vs Cycle Lenght

Sehubungan dengan hubungan antara BMI dan panjang siklus, scatter plot pada Gambar 2 memperlihatkan kecenderungan siklus lebih pendek pada peserta dengan BMI lebih tinggi. Meskipun pola yang muncul tidak sangat signifikan, kecenderungan ini tetap menarik dan layak dianalisis lebih lanjut dalam model prediksi, terutama untuk menguji pengaruh BMI sebagai salah satu faktor prediktor panjang siklus. Rentang BMI berkisar antara 15 hingga 30, dengan median sebesar 21,0.

## C. Model Prediksi Panjang Siklus

Untuk mengevaluasi kemampuan prediksi model dalam menentukan panjang siklus menstruasi, tiga model utama dibandingkan yaitu Decision Tree, CNN, dan LSTM. Evaluasi performa model dilakukan menggunakan metrik Mean Absolute Percentage Error (MAPE) dan Root Mean Square Error (RMSE), yang dirumuskan sebagai berikut:

### 1) Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur rata-rata kesalahan absolut dari prediksi model dalam bentuk persentase. Rumus MAPE ditulis sebagai berikut:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{y_t - \hat{y}_t}{y_t}$$

MAPE memberikan ukuran kesalahan prediksi dalam bentuk persentase, sehingga lebih mudah dipahami dan dibandingkan dalam konteks praktis. Misalnya, jika MAPE dari model adalah 7,5%, maka rata-rata kesalahan prediksi adalah 7,5% dari nilai aktual. MAPE juga berguna karena mudah diinterpretasikan pada berbagai skala, dan dengan nilai persentase ini, pengguna bisa memahami seberapa besar rata-rata error yang dihasilkan oleh model dalam bentuk proporsi yang konsisten.

### 2) Root Mean Square Error (RMSE)

RMSE adalah metrik yang mengukur rata-rata dari kesalahan kuadrat antara nilai aktual dan nilai prediksi. Rumus RMSE adalah sebagai berikut:

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

RMSE memberikan ukuran kesalahan yang dihitung dalam satuan yang sama dengan variabel yang diprediksi. Misalnya,

jika panjang siklus menstruasi diprediksi dalam satuan hari, maka RMSE juga akan dalam satuan hari, yang menjadikannya lebih mudah diinterpretasikan dalam konteks prediksi. RMSE sangat berguna karena menghitung rata-rata dari kesalahan kuadrat, sehingga memberikan bobot lebih pada kesalahan besar (outliers) [10]. Hal ini membuat RMSE menjadi metrik yang sangat sensitif terhadap nilai prediksi yang jauh dari nilai aktual, sehingga sangat cocok untuk kasus di mana kesalahan prediksi besar dianggap lebih penting untuk diminimalkan.

Dalam penelitian ini, penggunaan MAPE dan RMSE memberikan perspektif berbeda dalam menilai performa model. MAPE membantu menilai kesalahan dalam bentuk persentase, yang memudahkan interpretasi dalam skala umum, sedangkan RMSE memberikan penilaian absolut dari kesalahan yang sangat efektif dalam menangkap error besar. Kombinasi kedua metrik ini membantu memberikan penilaian yang lebih komprehensif terhadap model prediksi, memastikan model yang digunakan memiliki error yang minimal baik dari segi absolut (RMSE) maupun dalam skala proporsional (MAPE).

Hasil perbandingan performa dari ketiga model disajikan pada **Tabel 2**, menunjukkan bahwa model LSTM memiliki performa prediksi yang paling tinggi dengan akurasi sebesar 91,3%, RMSE 1,7, dan MAPE 7,5%.

TABEL 2  
PERBANDINGAN KINERJA MODEL PREDIKSI PANJANG SIKLUS

Model	Akurasi (%)	RMSE	MAPE (%)
Decision Tree	85.2	2.3	10.4
CNN	88.9	1.9	8.2
LSTM	91.3	1.7	7.5

Dari hasil analisis, model LSTM menonjol sebagai metode yang paling akurat dalam memprediksi panjang siklus menstruasi. Model ini memiliki tingkat akurasi sebesar 91,3% dengan RMSE sebesar 1,7 dan MAPE sebesar 7,5%, menunjukkan bahwa LSTM mampu memberikan prediksi yang paling stabil dan akurat dibandingkan dengan CNN dan Decision Tree. LSTM, sebagai jenis Recurrent Neural Network (RNN), memiliki keunggulan dalam mengolah data deret waktu yang melibatkan pola temporal yang kompleks [11], yang sesuai dengan sifat data siklus menstruasi yang sangat dipengaruhi oleh waktu dan urutan.

Dalam penelitian sebelumnya, metode Long Short-Term Memory (LSTM) telah terbukti mampu menangkap pola temporal kompleks yang muncul dalam analisis data time series, termasuk data siklus menstruasi. Sebuah studi yang memprediksi harga cabai merah keriting di Yogyakarta menggunakan LSTM berhasil mencapai akurasi tinggi dalam prediksi harga komoditas yang fluktuatif [12]. Hal tersebut menunjukkan bahwa LSTM efektif dalam mengurangi error prediksi pada data yang menunjukkan pola fluktuatif, sejalan dengan penelitian ini yang memperlihatkan performa optimal LSTM dalam konteks prediksi siklus menstruasi. Keunggulan LSTM ini didukung oleh kemampuannya dalam memahami data deret waktu yang bersifat dinamis, menjadikannya lebih akurat dibandingkan dengan metode lain dalam aplikasi pelacakan Kesehatan [13], [14].

CNN, meskipun memiliki akurasi yang baik, berada di peringkat kedua dengan akurasi 88,9% dan MAPE 8,2%. CNN umumnya digunakan dalam analisis citra tetapi juga efektif dalam mengenali pola pada data deret waktu, terutama dalam konteks data yang memiliki struktur spasial atau pola tertentu dalam urutan waktu yang tidak terlalu Panjang [15], [16]. Dalam kasus ini, CNN berhasil menangkap beberapa pola dasar dalam panjang siklus menstruasi, namun belum sebaik LSTM dalam hal ketepatan prediksi.

Model CNN menunjukkan kemampuan yang cukup baik dalam mengenali pola pada data time series, penggunaan model ini dalam penelitian terkait siklus menstruasi masih terbatas. CNN seringkali dipakai untuk klasifikasi gambar [17], namun Rafliansyah et al. (2024) menemukan bahwa model ini juga mampu bekerja dengan baik pada data time series dalam domain non-visual seperti suara dan Kesehatan [18]. Dengan hasil prediksi yang lebih tinggi dibandingkan Decision Tree dalam penelitian ini, CNN layak untuk terus dieksplorasi dalam aplikasi prediksi menstruasi, meskipun demikian performanya belum mampu mengungguli LSTM yang lebih adaptif terhadap pola temporal yang kompleks [19].

Decision Tree memiliki kinerja terendah dengan akurasi 85,2% dan MAPE 10,4%. Algoritma ini dikenal karena interpretabilitasnya yang tinggi, namun kurang optimal pada data deret waktu yang membutuhkan penangkapan pola temporal secara konsisten [20]. Decision Tree tampaknya lebih rentan terhadap variabilitas inherent dalam data siklus menstruasi, sehingga menyebabkan tingkat error yang lebih tinggi dibandingkan model deep learning.

Lebih lanjut, hasil scatter plot BMI terhadap panjang siklus menunjukkan bahwa ada kecenderungan siklus yang lebih pendek pada peserta dengan BMI lebih tinggi, meskipun korelasi ini tidak terlalu signifikan secara statistik dalam dataset ini. Korelasi antara BMI dan panjang siklus sebenarnya sudah didokumentasikan dalam beberapa studi kesehatan reproduksi, di mana BMI yang lebih tinggi sering dikaitkan dengan perubahan hormonal yang dapat mempengaruhi durasi siklus. Dalam penelitian ini, meskipun BMI tidak menjadi prediktor utama dalam model, pengaruhnya tetap layak untuk diteliti lebih lanjut dengan memperkaya data atau menambahkan variabel kesehatan lainnya.

#### IV. KESIMPULAN

Penelitian ini menunjukkan bahwa metode machine learning, khususnya Long Short-Term Memory (LSTM), unggul dalam memprediksi siklus menstruasi dibandingkan dengan Convolutional Neural Network (CNN) dan Decision Tree, dengan akurasi sebesar 91,3%, RMSE 1,7, dan MAPE 7,5%. Hasil ini mengindikasikan bahwa LSTM sangat efektif untuk menangkap pola temporal yang kompleks dalam data siklus menstruasi, yang mencakup variabel seperti panjang siklus, tanggal ovulasi, BMI, dan tingkat stres. Aplikasi dari model ini diharapkan dapat membantu wanita dan tenaga kesehatan untuk memantau kondisi reproduksi dengan lebih akurat dan proaktif, terutama dalam mendeteksi potensi gangguan seperti PCOS dan endometriosis.

Untuk penelitian selanjutnya, disarankan untuk memasukkan variabel tambahan yang mungkin berpengaruh

pada siklus menstruasi, seperti riwayat kesehatan hormonal dan gaya hidup, guna meningkatkan akurasi prediksi. Selain itu, peningkatan pada keamanan data juga perlu mendapat perhatian lebih besar, mengingat pentingnya perlindungan data pribadi dalam aplikasi pelacakan menstruasi. Penggunaan metode hybrid yang menggabungkan kelebihan beberapa algoritma machine learning juga layak dieksplorasi untuk mendapatkan hasil yang lebih optimal dalam prediksi siklus yang beragam dan kompleks.

#### REFERENSI

- [1] K. Li, I. Urteaga, A. Shea, V. J. Vitzthum, C. H. Wiggins, and N. Elhadad, "A generative, predictive model for menstrual cycle lengths that accounts for potential self-tracking artifacts in mobile health data," *arXiv preprint arXiv:2102.12439*, 2021.
- [2] K. Li, I. Urteaga, A. Shea, V. J. Vitzthum, C. H. Wiggins, and N. Elhadad, "A predictive model for next cycle start date that accounts for adherence in menstrual self-tracking," *Journal of the American Medical Informatics Association*, vol. 29, no. 1, pp. 3–11, 2022.
- [3] I. Lestari, M. Akbar, and B. Intan, "Perbandingan Algoritma Machine Learning Untuk klasifikasi Amenorrhoea," *Journal of Computer and Information Systems Ampera*, vol. 4, no. 1, pp. 32–43, 2023.
- [4] T. Thakur, S. Kadam, N. Patil, and C. Achrekar, "Machine Learning in Period, Fertility and Ovulation Tracking Application," *Authorea Preprints*, 2023.
- [5] M. Deverashetti, K. Ranjitha, and K. V Pradeepthi, "Security analysis of menstruation cycle tracking applications using static, dynamic and machine learning techniques," *Journal of Information Security and Applications*, vol. 67, p. 103171, 2022.
- [6] H. Nooraini, U. Salamah, and H. Prasetyo, "The Comparison of Classification of Stress Level Related to Student's Menstrual Cycle Irregularities with Support Vector Machine and Decision Tree Algorithm," in *2022 5th International Conference on Information and Communications Technology (ICOIACT)*, 2022, pp. 133–138. doi: 10.1109/ICOIACT55506.2022.9972141.
- [7] M. A. Faishol, E. Endroyono, and A. N. Irfansyah, "Predict Urban Air Pollution in Surabaya Using Recurrent Neural Network-Long Short Term Memory," *Jurnal Ilmiah Teknologi Informasi*, vol. 18, no. 2, pp. 102–114, 2020.
- [8] R. H. Rafliansyah, B. Rahmat, and C. A. Putra, "Klasifikasi Suara Instrumen Musik Tiup Menggunakan Metode Convolutional Neural Network," *Merkurius: Jurnal Riset Sistem Informasi dan Teknik Informatika*, vol. 2, no. 4, pp. 1–9, 2024.
- [9] A. S. Munir, A. B. Saputra, A. Aziz, and M. A. Barata, "Perbandingan Akurasi Algoritma Naive Bayes dan Algoritma Decision Tree dalam Pengklasifikasian Penyakit Kanker Payudara," *Jurnal Ilmiah Informatika Global*, vol. 15, no. 1, pp. 23–29, 2024.
- [10] U. Lathifah and R. D. Dana, "IMPLEMENTASI METODE LINEAR REGRESSION UNTUK PREDIKSI HARGA PROPERTI REAL ESTATE MENGGUNAKAN RAPIDMINER," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 1129–1137, 2024.
- [11] A. Arwansyah, S. Suryani, H. S. Y. H. SY, A. Ahyuna, U. Usman, and S. Alam, "Model Prediksi Deret Waktu Menggunakan Deep Convolutional LSTM," in *SISITI: Seminar Ilmiah Sistem Informasi dan Teknologi Informasi*, 2024, pp. 21–25.
- [12] A. Dwika and D. Avianto, "Implementasi Algoritma LSTM untuk Prediksi Harga Cabai Merah Keriting di Yogyakarta," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 5, pp. 635–648, Jan. 2024, doi: 10.35870/jimik.v5i1.534.
- [13] A. Wibowo, "Kecerdasan Buatan Gabungan pada Sistem Operasi Bisnis," *Penerbit Yayasan Prima Agus Teknik*, pp. 1–187, 2024.
- [14] N. Yudistira et al., *Prediksi Deret Waktu Menggunakan Deep Learning*. Universitas Brawijaya Press, 2023.
- [15] R. F. Putra et al., *Data Mining: Algoritma dan Penerapannya*. PT. Sonpedia Publishing Indonesia, 2023.
- [16] M. Alfandi, P. Pristiawanto, and A. M. H. Sihite, "Penerapan Metode CNN-LSTM Dalam Memprediksi Hujan Pada Wilayah

- Medan,” *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 6, no. 1, pp. 490–499, 2023.
- [17] I. K. Trisiawan, Y. Yuliza, and S. Attamimi, “Penerapan multi-label image classification menggunakan metode convolutional neural network (cnn) untuk sortir botol minuman,” *Jurnal Teknologi Elektro*, vol. 13, no. 1, pp. 48–54, 2022.
- [18] A. Taherkhani, G. Cosma, and T. M. McGinnity, “A Deep Convolutional Neural Network for Time Series Classification with Intermediate Targets,” *SN Comput Sci*, vol. 4, no. 6, p. 832, 2023.
- [19] S. J. Pipin, R. Purba, and H. Kurniawan, “Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation,” *Journal of Computer System and Informatics (JoSYC)*, vol. 4, no. 4, pp. 806–815, 2023.
- [20] W. D. Febrianti and N. K. J. Najah, “Analisis Klasifikasi Kepuasan Penumpang Maskapai Penerbangan Menggunakan Metode Support Vector Machine, Decision Tree, Dan Random Forest”.