



Pengembangan Model *Deep Learning* LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia

Yohanes Anton Nugroho^{1*}, Hotma Antoni Hutahaean²

^{1,2} Program Studi Program Profesi Insinyur, Fakultas Biosains, Teknologi dan Inovasi, Universitas Katolik Indonesia Atma Jaya, Jakarta, Indonesia

Alamat: Jl. Jenderal Sudirman No. 51, Setiabudi, Jakarta Selatan, DKI Jakarta, 12930

Korespondensi penulis: yohanesanton@uty.ac.id

Abstract. Accurate sales forecasting is essential for stakeholders to make strategic decisions. This study aims to compare the performance of two deep learning models, namely Long Short-Term Memory (LSTM) and Convolutional Neural Network (CNN), in forecasting domestic motorcycle sales produced by AISI member manufacturers. The forecast is based on historical data from January 2021 to December 2024. The model was trained using time series data and the forecasting results for the period January to March 2025 were evaluated using the metrics Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results show that the LSTM model produces lower MAE and MAPE values than CNN, which shows its superiority in providing more accurate and consistent predictions. On the other hand, the CNN model has lower RMSE and MSE values, thus being able to reduce large prediction errors. By comparing the results of LSTM, CNN and actual data forecasting, the LSTM model is more suitable for forecasting motorcycle sales in Indonesia

Keywords: CNN, Deep Learning, Forecasting, LSTM, Motorcycle Sales

Abstrak. Peramalan penjualan yang akurat sangat diperlukan pemangku kepentingan untuk pengambilan keputusan strategis. Penelitian ini bertujuan untuk membandingkan kinerja dua model deep learning, yaitu Long Short-Term Memory (LSTM) dan Convolutional Neural Network (CNN), dalam melakukan peramalan penjualan sepeda motor domestik yang diproduksi oleh produsen sepeda motor di Indonesia yang tergabung dalam AISI. Peramalan dilakukan menggunakan berdasarkan data historis bulan Januari 2021 hingga Desember 2024. Model dilatih menggunakan data time series dan hasil peramalan untuk periode Januari hingga Maret 2025 dievaluasi menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model LSTM menghasilkan nilai MAE dan MAPE yang lebih rendah dibandingkan CNN, yang menunjukkan keunggulannya dalam memberikan prediksi yang lebih akurat dan konsisten. Di sisi lain, model CNN memiliki nilai RMSE dan MSE yang lebih rendah, sehingga mampu menekan kesalahan prediksi besar. Dengan membandingkan hasil peramalan LSTM, CNN dan data aktual, model LSTM lebih sesuai digunakan untuk peramalan penjualan sepeda motor di Indonesia.

Kata kunci: CNN, Deep learning, LSTM, Peramalan, Penjualan sepeda motor

1. LATAR BELAKANG

Peramalan penjualan merupakan suatu fungsi integral yang diaplikasikan dalam pengambilan keputusan strategis berbagai bidang industri, yang melayani berbagai tujuan mulai dari efisiensi operasional hingga pengambilan keputusan strategis. Dimana fungsi utamanya adalah untuk memprediksi volume penjualan di masa depan berdasarkan data historis, tren pasar, dan faktor lain yang mempengaruhi. Dalam lingkungan bisnis yang dinamis, keakuratan prakiraan penjualan memainkan peran penting dalam pengambilan keputusan strategis dan alokasi sumber daya di masa depan (Amir et al., 2023).

Berbagai pendekatan telah digunakan oleh sejumlah peneliti untuk melakukan peramalan, dimana penggunaan metode statistik tradisional hingga dikombinasikan dengan machine learning telah dilakukan (Taparia, Mishra, Gupta, & Kumar, 2023). Deep learning salah satu teknologi transformatif yang digunakan dalam peramalan time series dengan memanfaatkan model-model terbaru untuk meningkatkan akurasi prediksi di berbagai bidang. Deep learning mewakili kemajuan yang signifikan dalam peramalan time series yang menawarkan kemampuan prediksi yang lebih baik di berbagai aplikasi. Beberapa aplikasi yang menonjol dalam peramalan berbasis deep learning adalah Convolutional Neural Networks (CNN) dan Long Short-Term Memory (LSTM), yang memiliki keunggulan menganalisis data yang bergantung waktu dan menangkap pola-pola kompleks.

LSTM merupakan suatu metode turunan Recurrent Neural Network (RNN) atau jaringan saraf tiruan yang dapat digunakan membuat model machine learning (ML) untuk peramalan. LSTM sangat efektif untuk peramalan time series karena kemampuannya untuk menangkap ketergantungan jangka panjang pada data berurutan (Hewamalage, Bergmeir, & Bandara, 2021). Aplikasi LSTM dalam peramalan diantaranya peramalan terkait dengan konsumsi energi (Balraj, Pugalendhi, Sureshkumar, & Vijayasarathi, 2023), harga saham (Ding, Zhang, & Yang, 2023; Ku et al., 2023). Beberapa kelebihan metode ini diantaranya adalah kemampuan untuk melakukan peramalan data non linear dan non stasioner (Taheri, Talebjedi, & Laukkanen, 2021), serta dapat secara efektif menangani prediksi deret waktu multi-langkah (Cheelamanthula, 2022). Dengan demikian pada penelitian ini model dengan peramalan LSTM digunakan dalam pengembangan model peramalan.

CNN merupakan salah satu arsitektur deep learning yang meniru cara manusia dan hewan mengenali pola dalam gambar. Model CNN mampu membangun representasi tingkat rendah di layer awal, kemudian digabungkan untuk menghasilkan representasi yang lebih kompleks pada layer-layer berikutnya (Amini & Ghaemmaghami, 2019), sehingga CNN sangat efektif untuk tugas-tugas yang melibatkan pengenalan pola dalam data visual, termasuk klasifikasi gambar, deteksi objek, dan segmentasi citra.

Penelitian ini mencoba membandingkan keakuratan dari model deep learning LSTM dan CNN dalam melakukan peramalan penjualan sepeda motor domestik yang merujuk pada penjualan sepeda motor yang dijual dan diproduksi di Indonesia oleh produsen pemegang merek sepeda motor yang tergabung dalam Asosiasi Industri Sepeda Motor Indonesia (AISI), yang didalamnya terdapat produsen pemegang merk Honda, Kawasaki, Suzuki, TVS, dan Yamaha. Peramalan dilakukan menggunakan data historis penjualan sepeda motor domestik

bulan Januari 2021 hingga Desember 2024. Sementara peramalan dilakukan untuk durasi tiga bulan, yaitu pada periode Januari 2025 hingga Maret 2025. Evaluasi dari peramalan dilakukan menggunakan matriks evaluasi akurasi mean absolute error (MAE), mean square error (MSE), root mean square error (RMSE), dan mean absolute percentage error (MAPE). Dari hasil peramalan diharapkan dapat diperoleh metode peramalan yang memiliki nilai kinerja peramalan tertinggi, serta relevan dengan pola penjualan. Dengan demikian diharapkan dapat digunakan untuk meramalkan penjualan

2. KAJIAN TEORITIS

LSTM merupakan salah satu model deep learning yang merupakan bagian dari jaringan saraf tiruan atau RNN. Dalam aplikasi peramalan LSTM menjawab tantangan dalam mempelajari ketergantungan jangka panjang pada data berurutan, sehingga sangat efektif untuk peramalan deret waktu (Nejadettehad, Mahini, & Bahrak, 2020; Zhao, Chen, Wu, Chen, & Liu, 2017). LSTM sangat dapat menangani data yang memiliki pola dan urutan non-linear dengan interval dan penundaan yang panjang. Hal ini karena LSTM menyajikan kerangka kerja yang kuat yang mampu mengelola data temporal yang kompleks dan non-linear.

Pengaplikasian model deep learning LSTM antara dalam peramalan time series dilakukan dengan menggunakan sejumlah langkah, diantaranya adalah sebagai berikut:

1. Pemrosesan Data dan rekayasa fitur setelah data deret waktu didapatkan maka selanjutnya dilakukan segmentasi data, Data time series disegmentasi ke dalam urutan yang dapat diproses oleh LSTM, dimana dilakukan pembuatan pasangan input-output di mana inputnya adalah urutan pengamatan di masa lalu, dan outputnya adalah nilai masa depan yang akan diprediksi (Uma Maheshwari, Vallathan, Govindharaju, & Geriyaashakthi, 2023). Selanjutnya dilakukan normalisasi dengan menskalakan data ke rentang standar, sehingga dapat meningkatkan kecepatan konvergensi dan stabilitas model (Rigopoulos, 2022).
2. Konfigurasi arsitektur model LSTM, terdiri dari lapisan input, lapisan LSTM yang mempelajari ketergantungan jangka panjang, lapisan padat yang menghasilkan prediksi akhir, dan lapisan output yang memberikan output peramalan. Beberapa arsitektur dasar LSTM, diantaranya model sederhana (vanilla LSTM) dan stacked LSTM yang menggabungkan lapisan LSTM untuk menangani data yang lebih kompleks dan mengidentifikasi pola jangka panjang (Zhao et al., 2017).

3. Training model dengan beberapa cara, diantaranya hyperparameter tuning (Sushanth et al., 2024), *early stopping* ketika kesalahan validasi mulai meningkat (Yadav et al., 2023), dan teknik regularisasi secara acak selama training (Jin, 2022).
4. Membuat prediksi dengan memvalidasi keefektifan model, diantaranya dengan menggunakan parameter seperti root-mean-square error (RMSE) dan mean absolute percentage error (MAPE), dan mean absolute error (MAE),

CNN adalah suatu algoritma deep learning yang sangat efektif dalam peramalan data deret waktu yang menangkap ketergantungan temporal dan pola kompleks seperti musiman dan efek liburan, bahkan ketika data historis terbatas (Chen, Kang, Chen, & Wang, 2020). Jaringan syaraf tiruan convolutional terdiri dari beberapa lapisan yang dirancang untuk secara otomatis dan adaptif mempelajari hirarki spasial fitur melalui algoritma backpropagation (Yamashita, Nishio, Do, & Togashi, 2018). CNN dapat mengenali pola data yang kompleks, sehingga cocok untuk peramalan deret waktu univariat dan multivariat (Fernández-Navarro, de la Cruz, Gutiérrez, Castaño, & Hervás-Martínez, 2018; Maggiolo & Spanakis, 2019). Hal ini disebabkan karena CNN dapat memproses data berurutan dengan menangkap hirarki spasial dan hubungan antar variabel, sehingga memungkinkan memodelkan ketergantungan yang rumit dalam data deret waktu, baik yang melibatkan variabel tunggal (univariat) atau banyak variabel (multivariat) (Maggiolo & Spanakis, 2019). Dalam menangani data data multivariat, CNN mengubahnya menjadi struktur tiga dimensi untuk menangkap pola temporal dan ketergantungan dalam data (Markova, 2022). Langkah dalam peramalan dengan memanfaatkan CNN diantaranya adalah:

1. Pengumpulan dan prapemrosesan data
2. Merancang arsitektur CNN dengan mempertimbangkan lapisan, yaitu convolutional layers, fungsi aktivasi Rectified Linear Unit (Relu), pooling layers, flatten layer, dan fully connected Layers
3. Kompilasi model dengan melibatkan pemilihan fungsi kerugian, pengoptimal, dan metrik kinerja yang sesuai.
4. Melatih model CNN menggunakan data dengan menggunakan data historis dan divalidasi dengan data yang tidak terlihat untuk memastikan kinerja yang baik (Deng et al., 2019; Kim, Moon, Hwang, & Kang, 2019).
5. Melakukan peramalan, evaluasi dan pengujian dengan menggunakan parameter kinerja model yang dievaluasi menggunakan ukuran seperti RMSE, MAE, dan MAPE untuk memastikan akurasi dan keandalan(Acikgoz, 2022).

3. METODE PENELITIAN

Penelitian ini bertujuan membandingkan kinerja model deep learning LSTM dan CNN dalam meramalkan penjualan sepeda motor di Indonesia tahun 2025. Data yang digunakan merupakan data historis penjualan sepeda motor domestik di Indonesia dari AISI. Adapun data yang digunakan bersifat terbuka dan dapat diakses pada <https://www.aisi.or.id/statistic/>. Data yang digunakan dalam peramalan ini adalah menggunakan data penjualan jumlah unit sepeda motor yang terjual dalam periode waktu Januari 2021 hingga Desember 2024.

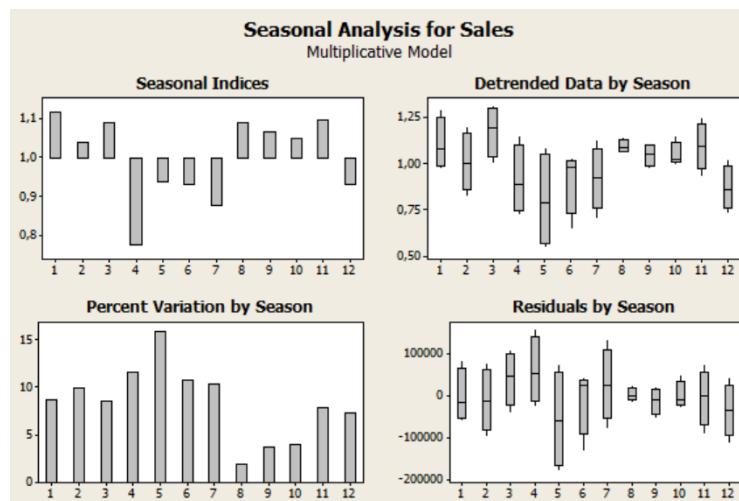
Pengembangan model deep learning dalam penelitian ini dikembangkan menggunakan bahasa pemrograman Python yang dijalankan pada program Jupyter Notebook. Adapun bahasa pemrograman Python library yang digunakan antara lain adalah TensorFlow/Keras untuk implementasi model LSTM dan CNN, NumPy dan Pandas untuk pengolahan data dan analisis statistik, serta Matplotlib dan Seaborn untuk visualisasi hasil peramalan dan evaluasi.

Tahapan dalam penelitian meliputi preprocessing data, dimana dilakukan pengecekan data data yang hilang serta melakukan normalisasi data agar model dapat mempelajari pola dengan lebih efisien. Selanjutnya dilakukan desain model deep learning digunakan untuk memprediksi penjualan sepeda motor, yaitu LSTM dan CNN, dimana model LSTM terdiri dari beberapa lapisan LSTM yang saling terhubung, diikuti oleh lapisan dense untuk menghasilkan peramalan. Sementara untuk model CNN: terdiri dari beberapa lapisan konvolusional diikuti oleh lapisan pooling dan lapisan dense. Lapisan konvolusional berfungsi mengekstrak fitur data time series yang selanjutnya diproses oleh lapisan dense untuk menghasilkan peramalan. Selanjutnya dalam tahap pelatihan digunakan algoritma optimasi Adam (Adaptive Moment Estimation), yang relevan menangani parameter model yang besar dan kompleks. Parameter loss yang digunakan dalam pengujian adalah MSE. Sementara dalam evaluasi kineja ditambahkan beberapa parameter, yaitu MAE, yang mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual, RMSE yang digunakan mengukur akar kuadrat dari rata-rata kesalahan kuadrat antara prediksi dan nilai aktual.

Setelah peramalan selesai dijalankan, dalam model ini dilakukan validasi menggunakan teknik cross-validation untuk memastikan bahwa model yang dihasilkan tidak overfit dan dapat diandalkan untuk prediksi pada data yang belum pernah dilihat sebelumnya. Validasi dilakukan dengan membandingkan hasil peramalan bulan Januari – Maret 2025 dengan data aktual yang sudah dirilis oleh AISI pada periode waktu tersebut.

4. HASIL DAN PEMBAHASAN

Berdasarkan data historis penjualan sepeda motor domestik selama 48 bulan, dilakukan pengolahan data terlebih dahulu menggunakan software Minitab 16. Analisis dekomposisi memecah data time series menjadi komponen yang lebih sederhana dan dapat menganalisis pola musiman, tren, dan residuals. Hasil dekomposisi pada Gambar 1 dengan model multiplicative dengan komponen tren dan musiman menunjukkan bahwa data penjualan yang digunakan memiliki persamaan model multiplicative sebagai berikut $Y_t = 400169 + 3137*t$. Nilai 400169 merupakan estimasi nilai Y saat $t = 0$, sementara 3137 adalah koefisien tren (slope), yang menunjukkan kenaikan yang terjadi pada setiap unit waktu. Dengan demikian dapat disimpulkan terdapat pola data trend dan musiman. Dimana berdasarkan pengolahan terjadi penjualan yang relatif rendah pada periode bulan April hingga Juni dan bulan Desember. Sementara penjualan tertinggi mencapai puncaknya pada bulan Januari.



Gambar 1. Hasil dekomposition analysis

Pengembangan program dengan menggunakan bahasa pemrograman Python dengan menggunakan model LSTM dilakukan dengan menggunakan sejumlah parameter diantaranya adalah menggunakan pendekatan Sequential, dimana ini merupakan metode yang memungkinkan penambahan lapisan (layer) secara berurutan. Model ini menerima input dari satu lapisan dan memberikan output ke lapisan berikutnya secara linear. Penambahan lapisan LSTM pertama dan kedua ditentukan sebanyak 50 unit. LSTM dengan ketentuan lapisan LSTM pertama akan mengembalikan urutan (sequences) outputnya. Time step yang digunakan adalah 1 sehingga dalam model ini hanya ada satu fitur. Lapisan LSTM ke dua adalah 50 unit. Lapisan dense yang digunakan adalah satu, karena menghasilkan satu nilai (prediksi) pada setiap sampel data input. Optimizer yang digunakan adalah menggunakan

algoritma optimasi Adam yang mengadaptasi pembelajaran berdasarkan rata-rata gradien dan kuadrat gradien. Fungsi loss yang digunakan adalah MSE yang mengukur rata-rata kuadrat dari perbedaan antara nilai diprediksi dan nilai aktual.

Sementara itu peramalan dengan metode CNN yang digunakan dalam penelitian ini menggunakan jenis layer Convolution 1 Dimensi yang digunakan untuk mendeteksi *pola lokal* (trend jangka pendek) dalam data penjualan selama 12 bulan terakhir, filter yang digunakan adalah 64 dengan karnel size 3, sehingga setiap filter mengamati window sepanjang 3 waktu berturut-turut. Fungsi aktivasi untuk menambahkan non-linearitas dan mempercepat konvergensi adalah Relu. Flatten layer yang merupakan lapisan dalam neural network digunakan untuk mengubah output dari Conv1D (yang bentuknya 3D) menjadi bentuk 1D. Sementara itu layer dense digunakan fully connected layer untuk menginterpretasikan fitur yang diekstrak dan menyusun representasi yang lebih abstrak dengan ukuran ukuran lapisan tersembunyi sebanyak 64 unit. Dalam proses training digunakan algoritma optimasi Adam dengan nilai loss menggunakan metrik evaluasi akurasi MSE dan jumlah epoch adalah 200 kali pengulangan.

Perbandingan hasil kinerja model peramalan yang diukur dengan menggunakan matrix evaluasi RMSE, MSE, MAE dan MAPE ditunjukkan pada Tabel 1.

Tabel 1. Perbandingan Matrix Evaluasi

Matrik evaluasi	LSTM	CNN
RMSE	59.430.96	55171.58
MSE	3.532.038.518.34	3.043.903.739.79
MAE	43.308.48	53.277.19
MAPE	9.09%	11.06%

Berdasarkan hasil peramalan diatas dapat ditunjukkan bahwa metode peramalan dengan mengambil data bulan Oktober hingga Desember 2024, model CNN memiliki nilai RMSE lebih rendah dibanding LSTM, sehingga berdasarkan data training didapatkan bahwa evaluasi peramalan model CNN akan membuat prediksi yang lebih dekat ke nilai aktual pada saat ada error besar. Model deep learning CNN juga menghasilkan nilai MSE lebih kecil, sehingga menandakan error besar lebih jarang terjadi dalam model CNN dibanding LSTM. Sementara model LSTM memiliki keunggulan nilai MAE lebih rendah, sehingga rata-rata kesalahan absolutnya lebih kecil dibandingkan metode CNN, sehingga peramalan dengan LSTM lebih konsisten dalam menghasilkan prediksi dengan kesalahan kecil-menengah. Sementara itu MAPE LSTM (9.09%) lebih baik dari CNN (11.06%), sehingga kesalahan prediksi LSTM

relatif lebih kecil terhadap nilai aktual. Berdasarkan perbandingan matrix evaluasi dapat ditunjukkan bahwa LSTM dan CNN memiliki kelebihan dan kelemahan, dimana LSTM lebih akurat dalam melakukan peramalan, sementara CNN lebih stabil terhadap outlier/error. Sementara itu kelemahan LSTM adalah rentan terhadap error besar dan error rata-rata lebih besar.

Hasil peramalan yang dihasilkan oleh masing-masing metode selanjutnya dibandingkan dengan hasil penjualan aktual. Pada saat artikel ini ditulis barulah terdapat 2 bulan penjualan, yaitu bulan Januari 2025 dan Februari 2025, sehingga belum terdapat data penjualan untuk bulan Maret 2025. Perbandingan hasil peramalan dengan data aktual penjualan nilainya ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan hasil peramalan dan penjualan aktual

Periode	LSTM	CNN	Penjualan Aktual
Januari 2025	547.602	521.355	560.301
Februari 2025	542.850	481.884	581.277
Maret 2025	540.786	501.328	-

Berdasarkan hasil peramalan model deep learning LSTM dan CNN, terlihat bahwa model LSTM mendapatkan hasil peramalan yang memiliki selisih lebih kecil jika dibandingkan hasil penjualan sepeda motor domestik secara aktual. Hal ini terlihat dari selisih nilai yang diprediksi dengan nilai aktual dari penjualan. Berdasarkan pertimbangan tersebut berdasarkan hasil akurasi rata-rata menggunakan matriks evaluasi MAE ataupun MAPE menunjukkan model deep learning LSTM menunjukkan akurasi yang lebih baik, dibuktikan dengan diperolehnya nilai MAE dan MAPE yang lebih rendah dibanding metode CNN. Kecenderungan metode CNN dalam nilai yang underestimate, dimana nilainya jauh lebih rendah dibandingkan penjualan aktual bulan Januari dan Februari 2025. Model deep learning LSTM menunjukkan kinerja yang lebih baik karena lebih mendekati data aktual. Berdasarkan pertimbangan tersebut, maka model deep learning LSTM lebih seuai dipertimbangkan dalam peramalan penjualan sepeda motor domestik di Indonesia, karena mampu menghasilkan prediksi yang lebih sesuai.

5. KESIMPULAN DAN SARAN

Penelitian ini dilakukan untuk mengevaluasi dan membandingkan kinerja model deep learning LSTM dan CNN dalam peramalan penjualan sepeda motor di Indonesia. Model dilatih menggunakan data historis penjualan dari Januari 2021 hingga Desember 2024 dan digunakan untuk melakukan peramalan penjualan pada periode Januari hingga Maret 2025. Berdasarkan matriks evaluasi akurasi MAE, MSE, RMSE, dan MAPE, didapatkan bahwa model LSTM menghasilkan nilai MAE dan MAPE yang lebih rendah dibandingkan CNN, sehingga model deep learning LSTM lebih konsisten dalam memprediksi nilai aktual secara rata-rata dan relatif. Sementara CNN memiliki nilai RMSE dan MSE lebih rendah, sehingga mengindikasikan kemampuannya mengurangi pengaruh kesalahan besar (outlier) prediksi.

Perbandingan hasil peramalan model deep learning LSTM dan CNN dengan data aktual penjualan menunjukkan bahwa model LSTM mampu menghasilkan prediksi yang lebih mendekati nilai aktual penjualan sepeda motor domestik di Indonesia untuk bulan Januari dan Februari 2025. Dapat disimpulkan dalam peramalan ini, model LSTM mampu mengikuti dan beradaptasi dengan pola penjualan sehingga menghasilkan nilai prediksi lebih akurat dibandingkan CNN. Meskipun demikian, CNN tetap memiliki potensi karena kestabilan prediksi terhadap fluktuasi besar. Dalam penelitian selanjutnya perlu dilakukan pengembangan model hybrid untuk menggabungkan kinerja model LSTM dengan model lainnya.

Pengembangan model deep learning yang diaplikasikan dalam penelitian ini sejalan dengan implementasi praktik keinsinyuran, dimana hal ini mencakup aspek pengolahan data, pemodelan matematis, dan optimasi. Model peramalan sepeda motor domestik diharapkan dapat memberikan dampak berupa rekomendasi bagi pengembangan industri sepeda motor yang diproduksi dan dijual di Indonesia, sehingga semakin memperkuat ketahanan industri nasional.

DAFTAR REFERENSI

- Acikgoz, H. (2022). A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Applied Energy*, 305. <https://doi.org/10.1016/j.apenergy.2021.117912>
- Amini, S., & Ghaemmaghami, S. (2019). Lowering mutual coherence between receptive fields in convolutional neural networks. *Electronics Letters*, 55(6). <https://doi.org/10.1049/el.2018.7671>
- Amir, W. K. H. W. K., Soom, A. B. M., Jasin, A. M., Ismail, J., Asmat, A., & Rahman, R. A. (2023). Sales forecasting using convolution neural network. *Journal of Advanced*

Research in Applied Sciences and Engineering Technology, 30(3).
<https://doi.org/10.37934/araset.30.3.290301>

Balraj, E., Pugalendhi, T., Sureshkumar, M., & Vijayasarathi, K. (2023). Optimized LSTM model for electric load forecasting using deep learning with genetic algorithm. Proceedings of the 7th International Conference on Intelligent Computing and Control Systems, ICICCS 2023. <https://doi.org/10.1109/ICICCS56967.2023.10142580>

Cheelamanthula, K. (2022). Implementation of Long Short Term Memory neural network model for electrical load. Proceedings - 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency, SUMMA 2022. <https://doi.org/10.1109/SUMMA57301.2022.9974046>

Chen, Y., Kang, Y., Chen, Y., & Wang, Z. (2020). Probabilistic forecasting with temporal convolutional neural network. Neurocomputing, 399. <https://doi.org/10.1016/j.neucom.2020.03.011>

Deng, Z., Wang, B., Xu, Y., Xu, T., Liu, C., & Zhu, Z. (2019). Multi-scale convolutional neural network with time-cognition for multi-step short-term load forecasting. IEEE Access, 7. <https://doi.org/10.1109/ACCESS.2019.2926137>

Ding, X., Zhang, L., & Yang, B. (2023). Research on the forecast ability of long short-term memory neural network model. <https://doi.org/10.1117/12.2682465>

Fernández-Navarro, F., de la Cruz, M. A., Gutiérrez, P. A., Castaño, A., & Hervás-Martínez, C. (2018). Time series forecasting by recurrent product unit neural networks. Neural Computing and Applications, 29(3). <https://doi.org/10.1007/s00521-016-2494-2>

Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent neural networks for time series forecasting: Current status and future directions. International Journal of Forecasting, 37(1). <https://doi.org/10.1016/j.ijforecast.2020.06.008>

Jin, C. (2022). Application and optimization of long short-term memory in time series forecasting. 2022 International Communication Engineering and Cloud Computing Conference, CECCC 2022. <https://doi.org/10.1109/CECCC56460.2022.10069825>

Kim, J., Moon, J., Hwang, E., & Kang, P. (2019). Recurrent inception convolution neural network for multi short-term load forecasting. Energy and Buildings, 194. <https://doi.org/10.1016/j.enbuild.2019.04.034>

Ku, C. S., Xiong, J., Chen, Y. L., Cheah, S. D., Soong, H. C., & Por, L. Y. (2023). Improving stock market predictions: An equity forecasting scanner using long short-term memory method with dynamic indicators for Malaysia stock market. Mathematics, 11(11). <https://doi.org/10.3390/math11112470>

Maggiolo, M., & Spanakis, G. (2019). Autoregressive convolutional recurrent neural network for univariate and multivariate time series prediction. ESANN 2019 - Proceedings, 27th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning.

Markova, M. (2022). Convolutional neural networks for forex time series forecasting. AIP Conference Proceedings, 2459. <https://doi.org/10.1063/5.0083533>

Nejadettehad, A., Mahini, H., & Bahrak, B. (2020). Short-term demand forecasting for online car-hailing services using recurrent neural networks. *Applied Artificial Intelligence*, 34(9). <https://doi.org/10.1080/08839514.2020.1771522>

Rigopoulos, G. (2022). A long short-term memory algorithm-based approach for univariate time series forecasting with application to GDP forecasting. *International Journal of Financial Management and Economics*, 5(2). <https://doi.org/10.33545/26179210.2022.v5.i2.139>

Sushanth, T. S., Siddarda, T. S., Sathvika, A., Shruthi, A., Lekha, A. S., & Kumar, T. (2024). Time series forecasting using RNN. 1–5. <https://doi.org/10.55041/IJSREM39164>

Taheri, S., Talebjedi, B., & Laukkanen, T. (2021). Electricity demand time series forecasting based on empirical mode decomposition and long short-term memory. *Energy Engineering: Journal of the Association of Energy Engineering*, 118(6). <https://doi.org/10.32604/EE.2021.017795>

Taparia, V., Mishra, P., Gupta, N., & Kumar, D. (2023). Improved demand forecasting of a retail store using a hybrid machine learning model. *Journal of Graphic Era University*. <https://doi.org/10.13052/jgeu0975-1416.1212>

Uma Maheshwari, L., Vallathan, G., Govindharaju, K., & Geriyaashakthi, D. K. (2023). Forecasting and analysis of IoT data by employing long short-term memory (LSTM) networks. 1st International Conference on Emerging Research in Computational Science, ICERCS 2023 - Proceedings. <https://doi.org/10.1109/ICERCS57948.2023.10434142>

Yadav, D., Sahoo, L., Mandal, S. K., Ravivarman, G., Vijayaraghavan, P., & Prasad, B. (2023). Using long short-term memory units for time series forecasting. 2023 2nd International Conference on Futuristic Technologies, INCOFT 2023. <https://doi.org/10.1109/INCOFT60753.2023.10425756>

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9. <https://doi.org/10.1007/s13244-018-0639-9>

Zhao, Z., Chen, W., Wu, X., Chen, P. C. Y., & Liu, J. (2017). LSTM network: A deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2). <https://doi.org/10.1049/iet-its.2016.0208>