

Performance Comparison of 1D-CNN and LSTM Deep Learning Models for Time Series-Based Electric Power Prediction

Article History:

Received

20 December 2024

Revised

2 January 2025

Accepted

28 January 2025

SUKATMO^{1, 2}, HAPSORO AGUNG NUGROHO², BENYAMIN
HERYANTO RUSANTO², SANTOSO SOEKIRNO¹

¹Departemen Fisika, Universitas Indonesia, Indonesia

²Sekolah Tinggi Meteorologi, Klimatologi, dan Geofisika, Indonesia

Email: sukatmo@ui.ac.id

ABSTRAK

Prediksi daya listrik yang akurat sangat penting untuk efisiensi energi, terutama bagi institusi dalam memenuhi kebutuhan energi yang dinamis. Penelitian ini membandingkan kinerja deep learning 1D-CNN dan LSTM untuk memprediksi daya listrik berbasis time series, menggunakan dataset dari Building Automation System (BAS) gedung STMKG. Metrik evaluasi Mean Squared Error (MSE) dan Mean Absolute Error (MAE) digunakan untuk mengukur akurasi. Hasil penelitian menunjukkan untuk LSTM nilai MSE rata-rata dari 10 percobaan pada proses pengujian $3,35E-04 \pm 0,00013$ dan MAE $0,01312 \pm 0,0079$, sedikit lebih baik dari 1D-CNN yang memiliki nilai MSE rata-rata $4,68E-04 \pm 0,0003$ dan MAE $0,01855 \pm 0,00586$. Walaupun perbedaannya tidak signifikan, 1D-CNN menawarkan keunggulan dalam efisiensi waktu komputasi 63,08s, 1D-CNN lebih cepat sekitar 84.19%.

Kata kunci: prediksi, daya listrik, time series, CNN, LSTM

ABSTRACT

Accurate electrical power prediction is essential for efficient energy management, especially in institutions with dynamic energy needs. This study compares the performance of 1D-CNN and LSTM for time series based electrical power prediction, using a dataset from the Building Automation System (BAS) of STMKG building. The evaluation metrics Mean Squared Error (MSE) and Mean Absolute Error (MAE) are used to measure accuracy. The results show that the LSTM had an average MSE value of $3.35E-04 \pm 0.00013$ and an MAE of 0.01312 ± 0.0079 across 10 trials. This is slightly better than the 1D-CNN, which had an average MSE value of $4.68E-04 \pm 0.0003$ and an MAE of 0.01855 ± 0.00586 . Despite the marginal difference, 1D-CNN provides a computational time efficiency advantage of 63.08s, 1D-CNN is about 84.19% faster.

Keywords: prediction, electrical power, time series, CNN, LSTM

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



1. PENDAHULUAN

Prediksi daya listrik merupakan komponen vital dalam pengelolaan sistem tenaga listrik yang efisien dan handal. Dalam konteks sistem tenaga listrik yang besar dan dinamis, ketepatan prediksi daya listrik sangat berpengaruh terhadap keputusan operasional, perencanaan kapasitas, dan pengelolaan sumber daya energi **(Raharjo, dkk, 2022)**. Oleh karena itu, peningkatan metode prediksi daya listrik sangat penting dalam mencapai tujuan optimalisasi operasional sistem tenaga listrik. Dalam pengelolaan energi, terutama di lingkungan institusi pendidikan seperti gedung Sekolah Tinggi Meteorologi, Klimatologi, dan Geofisika (STMKG) yang memiliki aktivitas operasional dinamis prediksi daya listrik sangat dibutuhkan. Dengan berbagai kegiatan yang berlangsung secara simultan, seperti kuliah, laboratorium, serta kegiatan administrasi, konsumsi energi di gedung STMKG cenderung berfluktuasi sepanjang hari. Pengelolaan energi yang efektif di institusi ini memerlukan prediksi yang akurat terhadap daya listrik untuk menjaga ketersediaan energi yang optimal, mengurangi biaya operasional, dan menghindari potensi kelebihan daya atau pemadaman listrik yang tidak terduga. Daya listrik di gedung STMKG dipengaruhi aktivitas di kampus seperti jadwal perkuliahan, penggunaan laboratorium, dan kegiatan ekstra kurikuler menyebabkan pola konsumsi listrik yang bervariasi, baik menurut hari dalam seminggu maupun jam dalam sehari. Hal ini menambah kompleksitas prediksi daya listrik, yang memerlukan pendekatan canggih untuk mendapatkan hasil prediktif yang akurat dan tepat waktu.

Dalam beberapa tahun terakhir, metode *deep learning* telah menjadi pendekatan yang menjanjikan untuk memprediksi data berbasis *time series* **(Nugroho, dkk, 2023)**. Arsitektur *deep learning Convolutional Neural Networks* (CNN) dan *Long Short-Term Memory* (LSTM) memiliki keunggulan yang berbeda dalam menangani pola data *time series*. 1D-CNN dikenal memiliki performa baik dalam mengenali pola lokal dalam data, memungkinkan model untuk menangkap perubahan pada jangka waktu pendek dengan lebih baik **(Liu, dkk, 2022)**. Sementara itu, model LSTM unggul dalam mempelajari ketergantungan jangka panjang **(Trinh, dkk, 2018)**, sehingga mampu mempertahankan informasi sekuensial yang dapat menjadi prediktor penting untuk data *time series* yang melibatkan pola historis panjang **(Sahoo, dkk, 2019)**.

Namun, masing-masing pendekatan ini juga memiliki kelemahan yang perlu diperhatikan. Model 1D-CNN misalnya, meskipun efektif dalam mengidentifikasi pola lokal, kadang tidak optimal dalam menangkap pola jangka panjang jika hanya menggunakan kernel konvolusi **(Reza, dkk, 2022)**. Sebaliknya, meskipun LSTM dirancang untuk menangani ketergantungan temporal, proses pelatihan dan waktu komputasinya dapat lebih tinggi **(Song, dkk, 2020)**, terutama ketika data memiliki dimensi yang besar dan jumlah waktu pelatihan yang signifikan. Oleh karena itu, mengevaluasi kinerja kedua model ini pada tugas prediksi daya listrik berbasis *time series* sangat penting untuk menentukan pendekatan mana yang lebih unggul dalam hal akurasi dan efisiensi komputasi.

Penelitian ini bertujuan untuk membandingkan kinerja model 1D-CNN dan LSTM dalam prediksi daya listrik berbasis *time series*, dengan fokus pada akurasi, stabilitas, dan efisiensi komputasi. Dalam penelitian ini, kedua model diuji menggunakan parameter yang sepadan dan metrik evaluasi yang sama, yaitu *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE), untuk memastikan hasil perbandingan yang objektif. Selain itu, penelitian ini juga diharapkan dapat memberikan wawasan mengenai efektivitas penerapan teknik *deep learning* dalam menangani permasalahan prediksi daya listrik, serta memberikan panduan dalam memilih model yang paling sesuai berdasarkan karakteristik data yang dihadapi. Prediksi konsumsi daya listrik dapat diterapkan dalam berbagai skala waktu, dari jangka pendek untuk optimalisasi

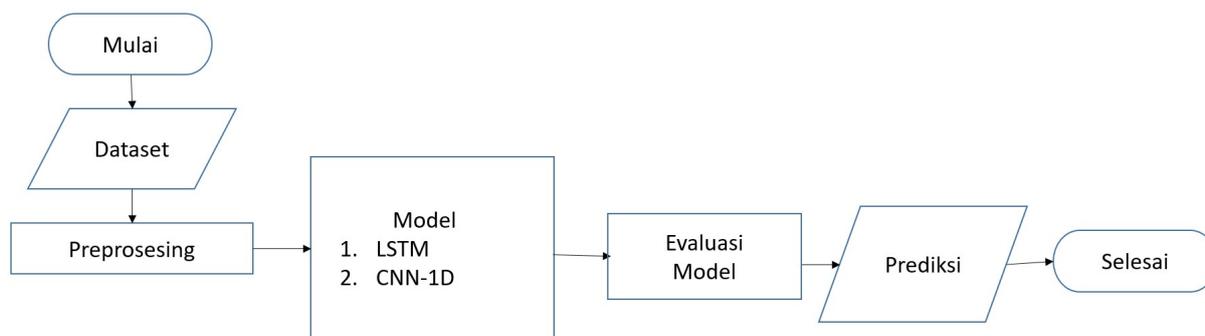
operasional hingga jangka panjang untuk perencanaan infrastruktur energi. Dalam penelitian ini, pendekatan yang digunakan berfokus pada prediksi jangka pendek, yang dapat mendukung manajemen daya harian atau mingguan untuk meningkatkan efisiensi operasional sistem kelistrikan.

2. METODE PENELITIAN

Pada bagian ini akan memberikan gambaran umum mengenai langkah-langkah penerapan model *deep learning*. Fokus utama adalah pada perbandingan antara algoritma 1D-CNN dan LSTM untuk prediksi konsumsi energi listrik. Metode yang digunakan dalam penyusunan dan analisis penelitian ini melibatkan beberapa langkah sistematis.

2.1 Alur Penelitian

Tahapan penelitian dimulai dengan pengumpulan data konsumsi daya listrik yang direkam secara periodik dari sensor daya yang terpasang di gedung STMKG. Data yang diperoleh melalui sistem *Building Automation System* (BAS) ini memuat informasi konsumsi listrik per jam dalam satuan kWh. Alur penelitian ini ditunjukkan seperti pada Gambar 1.



Gambar 1. Alur Penelitian Perbandingan Model 1D-CNN dan LSTM

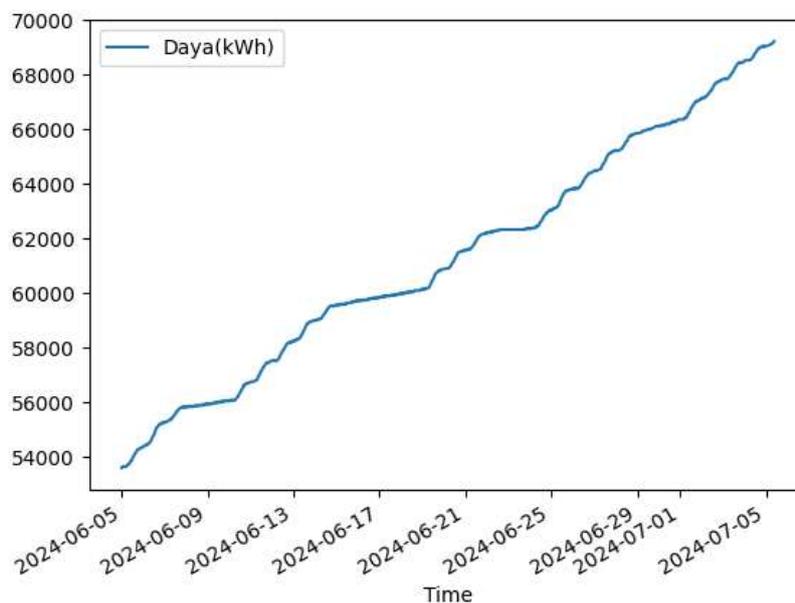
Setelah data terkumpul, dilakukan tahapan *preprocessing* yang mencakup beberapa langkah penting: *data cleansing* untuk menghilangkan anomali dan nilai yang hilang, *parsing waktu* untuk menyelaraskan format waktu, serta normalisasi data menggunakan metode *min-max scaling*. Proses *preprocessing* ini bertujuan untuk memastikan bahwa data yang digunakan dalam pelatihan model memiliki kualitas dan konsistensi yang optimal serta berada dalam rentang waktu (1 bulan) yang seragam. Setelah tahap *preprocessing*, data yang sudah bersih dan siap digunakan akan dimasukkan ke dalam dua arsitektur model yang berbeda, yaitu 1D-CNN dan LSTM, yang keduanya dirancang untuk menangani data *time series*. Kedua model ini dilatih menggunakan data yang telah diproses untuk mempelajari pola konsumsi daya listrik dari waktu ke waktu. Selanjutnya, model yang telah dilatih akan dievaluasi kinerjanya menggunakan metrik evaluasi seperti MSE dan MAE pada data uji. Hasil dari evaluasi ini akan digunakan untuk membandingkan performa antara model 1D-CNN dan LSTM. Setelah model terbaik dipilih, model tersebut diterapkan untuk melakukan prediksi konsumsi daya listrik pada data baru. Penelitian ini berakhir dengan analisis terhadap hasil prediksi serta kesimpulan mengenai efektivitas model dalam melakukan prediksi daya listrik berbasis *time series*.

2.2 Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari sensor pada BAS yang mencatat konsumsi listrik per jam dalam satuan kWh, yang menggambarkan kondisi nyata dari penggunaan energi listrik di gedung secara dinamis dan *real-time*. Data diambil secara kontinu

dalam periode tiga (3) bulan, yaitu dari Juni hingga Agustus 2024. Meskipun jam kerja, hari libur atau perubahan cuaca dapat mempengaruhi konsumsi listrik, penelitian ini menggunakan pendekatan time series univariat, sehingga prediksi didasarkan hanya pada pola historis konsumsi listrik tanpa mempertimbangkan faktor eksternal tersebut.

Secara keseluruhan, dataset ini terdiri dari 729 sampel data yang digunakan untuk melatih dan menguji model prediksi daya listrik. Dalam penelitian ini, dataset dibagi menjadi dua bagian, yaitu data pelatihan dan data uji, untuk mengevaluasi kinerja model secara obyektif. Pembagian ini bertujuan agar model mampu mempelajari pola konsumsi listrik yang ada dalam data pelatihan dan kemudian diuji untuk mengukur kemampuan generalisasi model terhadap data baru. Gambar 2 menunjukkan representasi visual dari dataset yang digunakan dalam penelitian ini.



Gambar 2. Data *Time series* Daya Listrik per Jam

2.3 Preprocessing

Tahap *preprocessing* dalam penelitian ini dilakukan untuk memastikan kualitas data sebelum digunakan dalam model 1D-CNN dan LSTM. Pertama, dilakukan *data cleansing* untuk menghilangkan anomali dan nilai yang hilang, yang dapat memengaruhi akurasi model. Selanjutnya, dilakukan *parsing time* untuk mengonversi format waktu ke dalam representasi yang sesuai, sehingga memudahkan analisis temporal. Untuk memastikan bahwa seluruh fitur berada dalam rentang yang seragam, dilakukan normalisasi data menggunakan *min-max scaler*, yang mengubah skala data ke dalam rentang 0 hingga 1. Normalisasi data menggunakan *min-max scaler* (Izonin, dkk, 2022) dapat didefinisikan dengan Persamaan (1) berikut:

$$x' = \frac{(x-x_{min})}{(x_{max}-x_{min})} \quad (1)$$

Dimana, x' adalah nilai ter-normalisasi, x merupakan nilai asli dari data, sedangkan x_{max} dan x_{min} merupakan nilai maksimum dan minimum dari dataset. Selain itu, untuk meningkatkan pemahaman model terhadap pola temporal yang lebih panjang dan berulang, dataset dibentuk menggunakan *sliding window*. Untuk membentuk dataset menggunakan *sliding window* (Selvin, dkk, 2017), kita mendefinisikan jendela dengan ukuran n dan pergeseran s . Jika

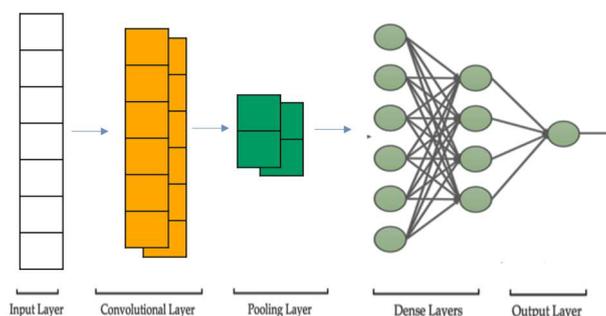
data X dengan panjang N maka dataset baru yang dihasilkan dapat dinyatakan seperti pada Persamaan (2) berikut:

$$X_{new}[i] = [X[i], X[i + 1]], \dots, X[i + n - 1] \quad (2)$$

Dimana $X_{new}[i]$ merupakan *window* ke- i , dan i adalah indeks mulai dari 0 hingga $N-n$. Proses ini juga mencakup pembagian data, di mana 80% dari dataset digunakan untuk pelatihan dan 20% sisanya untuk pengujian, sehingga model dapat dievaluasi secara efektif terhadap performa prediksi.

2.4 Arsitektur Model 1D-CNN

Model 1D-CNN merupakan arsitektur jaringan saraf yang dirancang untuk menangani data berbentuk *time series* atau sekuensial, yang umumnya berupa data dengan dimensi satu seperti sinyal atau data deret waktu. 1D-CNN bekerja dengan menerapkan operasi konvolusi pada data *input* secara sekuensial (**Ishida, dkk, 2024**), yang memungkinkan model untuk mengekstraksi fitur-fitur lokal dari pola temporal dalam data. Dalam arsitektur 1D-CNN, lapisan konvolusi digunakan untuk melakukan perhitungan *filter* (kernel) di sepanjang dimensi waktu (**Zhao, dkk, 2017**), menghasilkan fitur yang mencerminkan pola berulang pada data. Dengan menangkap pola lokal ini, 1D-CNN mampu mengenali variasi atau perubahan dalam data deret waktu (**Dong, dkk, 2023**), yang penting untuk prediksi daya listrik.



Gambar 3. Arsitektur 1D-CNN

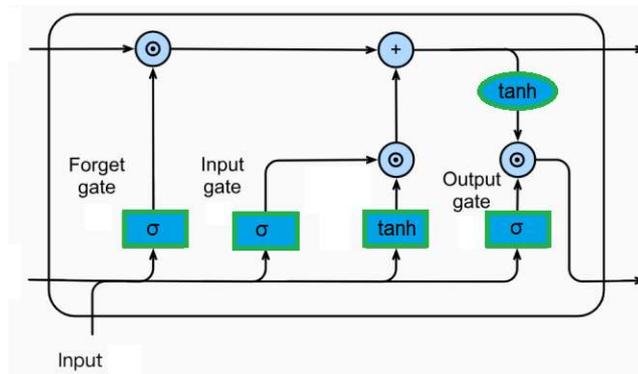
Gambar 3. menunjukkan arsitektur 1D-CNN umumnya terdiri dari beberapa lapisan konvolusi dan *pooling* yang berfungsi untuk menangkap informasi penting dari data. Pada lapisan konvolusi, filter berjalan di sepanjang data, mendeteksi fitur lokal yang signifikan, seperti puncak atau perubahan dalam pola penggunaan listrik. Setelah lapisan konvolusi, lapisan *pooling* digunakan untuk mengurangi dimensi data dan mempertahankan fitur yang paling dominan, sekaligus mengurangi *noise* (**Nugroho, dkk, 2022**). Pada tahap akhir, hasil dari lapisan konvolusi dan *pooling* diteruskan ke lapisan *dense* untuk menghasilkan *output* prediksi (**Fikriansyah, dkk, 2022**). Model 1D-CNN sangat efisien dalam menangkap pola jangka pendek dalam data *time series*, sehingga cocok untuk berbagai aplikasi prediksi berbasis waktu, termasuk prediksi daya listrik.

2.5 Arsitektur Model LSTM

LSTM merupakan jenis jaringan saraf tiruan berbasis *recurrent neural network* (RNN) (**Sherstinsky, 2020**) yang dirancang khusus untuk menangani masalah pada data sekuensial, terutama yang memiliki ketergantungan jangka panjang. Dalam konteks prediksi daya listrik, LSTM menjadi pilihan populer karena kemampuannya dalam mengingat informasi dari *input* sebelumnya dalam jangka waktu yang lama (**Le, dkk, 2019**), sehingga model dapat mengenali pola temporal yang lebih kompleks dalam data daya listrik. LSTM menggunakan mekanisme khusus yang disebut "*gating*" untuk mengatur informasi mana yang perlu

disimpan, diperbarui, atau dihapus, sehingga dapat mengatasi masalah "*vanishing gradient*" yang sering dialami oleh model tradisional. Model LSTM yang digunakan dalam penelitian ini dirancang untuk memprediksi konsumsi daya listrik berdasarkan data *time series*.

Arsitektur LSTM pada Gambar 4 terdiri dari beberapa lapisan berurutan yang saling terhubung, termasuk lapisan LSTM dan lapisan *Dense (Fully Connected)*. Lapisan LSTM berfungsi untuk menangkap pola jangka panjang dan hubungan temporal dalam data, sementara lapisan *Dense* bertindak sebagai lapisan penghubung yang menyaring dan menggabungkan fitur-fitur sebelum menghasilkan prediksi akhir. Struktur arsitektur ini dipilih untuk memberikan fleksibilitas dalam menangkap pola kompleks pada data *time series* yang fluktuatif, sehingga model dapat merespons perubahan konsumsi daya secara akurat.



Gambar 4. Arsitektur Umum LSTM

Setiap blok LSTM juga terdiri dari sel memori beserta tiga gerbang termasuk *Input Gate*, *Forget Gate* (gerbang lupa), dan *Output Gate* yang mengatur aliran informasi ke status selnya (Wang, dkk, 2017). Gerbang lupa menentukan informasi yang dibuang. Gerbang masukan memutuskan informasi yang dimasukkan ke status sel dan gerbang keluaran mengatur informasi keluar dari sel LSTM.

2.6 Metrik Evaluasi Kinerja Model

Dalam penelitian ini, kinerja model 1D-CNN dan LSTM dievaluasi menggunakan dua metrik utama, yaitu MSE dan MAE. MSE adalah salah satu metrik evaluasi yang digunakan untuk mengukur kinerja model dalam memprediksi data numerik. MSE memiliki beberapa karakteristik penting dalam evaluasi model. MSE memberikan penalti lebih besar terhadap kesalahan yang lebih besar karena kesalahan dikuadratkan (Teruna, dkk, 2024). Hal ini menjadikan MSE sensitif terhadap outlier, yang dapat menyebabkan nilai *error* menjadi lebih tinggi jika terdapat anomali dalam data. MSE menghitung rata-rata kuadrat dari selisih antara nilai aktual (y_i) dan nilai prediksi (\hat{y}_i) dengan n merupakan jumlah sampel seperti pada Persamaan (3) MSE sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

MAE merupakan metrik evaluasi yang digunakan untuk mengukur kesalahan rata-rata dalam prediksi model berdasarkan nilai absolut dari selisih antara nilai aktual dan nilai prediksi. Tidak seperti MSE yang mengkuadratkan kesalahan, MAE hanya mengambil nilai absolut dari perbedaan antara nilai aktual dan nilai prediksi. Oleh karena itu, MAE lebih intuitif dalam interpretasi karena menggunakan satuan yang sama dengan data aslinya. Salah satu keunggulan utama MAE adalah ketahanannya terhadap outlier (Anugrahayu, dkk, 2023). MAE tidak mengkuadratkan kesalahan, dampak dari kesalahan besar tidak diperbesar secara

signifikan, sehingga metrik ini lebih mencerminkan rata-rata kesalahan sebenarnya. Namun, kekurangannya adalah MAE tidak memperhitungkan arah kesalahan (positif atau negatif), sehingga tidak memberikan informasi tentang apakah model cenderung overestimate atau underestimate. MAE dapat dihitung menggunakan Persamaan (4) berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

3. HASIL DAN PEMBAHASAN

Dalam mengevaluasi performa kedua model, pelatihan dan pengujian dilakukan sebanyak 10 kali percobaan. Pendekatan ini bertujuan untuk memperoleh nilai rata-rata performa model, sehingga hasil yang diperoleh lebih representatif dan tidak dipengaruhi oleh fluktuasi hasil dari satu percobaan saja. Selain itu, analisis standar deviasi dilakukan untuk mengukur tingkat variasi atau konsistensi performa model dari setiap percobaan, yang penting dalam menilai stabilitas model prediksi. Hal ini memberikan pemahaman yang lebih mendalam mengenai keandalan model dalam berbagai skenario dan kondisi data.

3.1 Proses Pelatihan Model

Pada tahap ini, kedua model *deep learning*, 1D-CNN dan LSTM, dilatih menggunakan parameter yang sesuai dengan karakteristik arsitektur masing-masing, seperti yang ditunjukkan pada Tabel 1 dibawah ini.

Tabel 1. Parameter yang Digunakan dalam Pelatihan

PARAMETER	1D-CNN	LSTM
JUMLAH FILTER	64, 32	-
UKURAN KERNEL	2	-
UNITS	-	50
DROPOUT	0,2	0,2
EPOCHS	50	50
BATCH SIZE	32	32
OPTIMIZER	Adam	Adam

Untuk 1D-CNN, digunakan 64 dan 32 filter dan ukuran kernel sebesar 2 untuk menangkap pola spasial dalam data *time series*, sementara LSTM dirancang dengan 50 unit untuk mengakomodasi ketergantungan temporal jangka panjang. Kedua model diterapkan dengan *dropout* sebesar 0,2, *epoch* sebanyak 50, *batch size* 32, dan *optimizer Adam*, guna menjaga konsistensi dalam pelatihan dan meminimalisir potensi *overfitting*.

Tabel 2 menunjukkan performansi pelatihan model 1D-CNN berdasarkan 10 kali percobaan. Setiap metrik memberikan gambaran mengenai akurasi prediksi dan efisiensi komputasi model selama proses pelatihan. Untuk MSE, nilai berkisar antara 0,0017 hingga 0,0021 dengan rata-rata $0,00182 \pm 0,00013$. Hal ini menunjukkan bahwa model memiliki konsistensi yang baik dalam akurasi prediksi di setiap iterasi, dengan variasi yang sangat kecil berdasarkan standar deviasi. Nilai MSE yang rendah mencerminkan bahwa prediksi model mendekati nilai sebenarnya, menegaskan kemampuan model 1D-CNN dalam meminimalkan kesalahan selama pelatihan. Sementara itu, MAE berada dalam rentang 0,0297 hingga 0,033 dengan rata-rata $0,03071 \pm 0,00126$. Berbeda dengan MSE, MAE memberikan gambaran yang lebih intuitif karena mewakili rata-rata absolut deviasi prediksi terhadap nilai aktual. Rentang nilai yang

sempit dan standar deviasi yang kecil mengindikasikan bahwa model menunjukkan keandalan dan presisi yang baik selama pelatihan.

Sementara itu, waktu yang diperlukan untuk setiap iterasi berkisar antara 8,6 detik hingga 13,7 detik, dengan rata-rata 11,22 detik. Variasi dalam waktu pelatihan ini kemungkinan disebabkan oleh fluktuasi efisiensi komputasi atau penggunaan perangkat keras selama proses pelatihan. Meskipun demikian, waktu pelatihan ini tetap berada dalam batas yang wajar untuk pengaplikasian praktis. Secara keseluruhan, model 1D-CNN menunjukkan performa yang kuat dengan variasi kesalahan yang kecil di seluruh iterasi. Nilai MSE dan MAE yang rendah menunjukkan keandalan model dalam memprediksi, sedangkan waktu pelatihan yang moderat memastikan efisiensi dalam proses pelatihan. Namun, optimalisasi lebih lanjut pada efisiensi komputasi dapat meningkatkan skalabilitas model untuk aplikasi berskala besar.

Tabel 2. Performansi Pelatihan Model 1D-CNN

ITERASI	MSE	MAE	Cost Time
1	0,0019	0,031	11.3s
2	0,0019	0,0322	8.6s
3	0,0019	0,0317	9.6s
4	0,0017	0,0297	9.4s
5	0,0017	0,0298	11s
6	0,0017	0,0298	11.3s
7	0,0017	0,0297	12.7s
8	0,0019	0,0309	11.1s
9	0,0017	0,0293	13.7s
10	0,0021	0,033	13.5s
RATA-RATA	0,00182 ± 0,00013	0,03071 ± 0,00126	11.22s

Tabel 3 menunjukkan performansi pelatihan model LSTM berdasarkan 10 kali percobaan. Nilai rata-rata dan standar deviasi dihitung untuk setiap metrik, memberikan gambaran tentang akurasi dan efisiensi model. Pada metrik MSE, nilai berkisar antara 0,0013 hingga 0,0016 dengan rata-rata $0,00143 \pm 0,00012$. Nilai MSE yang rendah dan variasi kecil menunjukkan bahwa model LSTM mampu meminimalkan kesalahan prediksi selama pelatihan. Hal ini menunjukkan bahwa model berhasil menangkap pola-pola *non-linear* yang ada pada data *time series*, sesuai dengan keunggulan arsitektur LSTM dalam menangani data temporal. MAE memiliki rentang nilai antara 0,0256 hingga 0,0295 dengan rata-rata $0,02728 \pm 0,0013$. Nilai ini lebih intuitif dalam menggambarkan tingkat kesalahan absolut rata-rata prediksi terhadap nilai aktual. Rentang nilai yang sempit menunjukkan konsistensi performa model di setiap iterasi, memperkuat keandalan model dalam melakukan prediksi.

Dari sisi waktu pelatihan, *cost time* berkisar antara 65,7 detik hingga 99,9 detik dengan rata-rata 70,99 detik. Variasi waktu pelatihan ini kemungkinan disebabkan oleh faktor-faktor eksternal, seperti beban komputasi pada perangkat keras. Namun, waktu rata-rata ini tetap dalam batas yang wajar untuk aplikasi deep learning. Secara keseluruhan, model LSTM menunjukkan performa yang stabil dan akurat dalam melakukan pelatihan. Nilai MSE dan MAE yang rendah mengindikasikan kemampuan model dalam menangkap pola data dengan baik. Namun, waktu pelatihan yang relatif lebih tinggi dibandingkan dengan model lain, seperti 1D-CNN, menjadi perhatian untuk efisiensi komputasi.

Tabel 3. Performansi Pelatihan Model LSTM

ITERASI	MSE	MAE	Cost Time
1	0,0013	0,0257	67.3s
2	0,0016	0,0281	65.7s
3	0,0016	0,0295	67.1s
4	0,0014	0,0267	71.7s
5	0,0013	0,0264	87.8s
6	0,0014	0,0266	88.2s
7	0,0015	0,0287	81.3s
8	0,0013	0,0256	69.6s
9	0,0014	0,027	92.6s
10	0,0015	0,0285	99.9s
RATA-RATA	0,00143 ± 0,00012	0,02728 ± 0,0013	70.99s

3.2 Pengujian Model 1D-CNN dan LSTM

Tabel 4 menunjukkan performansi pengujian model 1D-CNN dan LSTM dalam melakukan prediksi daya listrik. Rata-rata dan standar deviasi untuk setiap metrik dihitung untuk menilai akurasi dan konsistensi masing-masing model. Pada model 1D-CNN, nilai rata-rata MSE adalah $4,68E-04 \pm 0,0003$ sedangkan MAE rata-ratanya mencapai $0,01855 \pm 0,00586$. Nilai ini menunjukkan bahwa model 1D-CNN secara konsisten mampu meminimalkan kesalahan prediksi, meskipun terdapat sedikit fluktuasi pada nilai MAE yang tercermin dari standar deviasi yang relatif tinggi. Fluktuasi ini dapat diakibatkan oleh sensitivitas model terhadap pola temporal tertentu dalam data daya listrik. Sementara itu, model LSTM menunjukkan performansi rata-rata MSE sebesar $3,35E-04 \pm 0,00013$ dan MAE $0,01312 \pm 0,0079$. Hasil ini mengindikasikan bahwa model LSTM memiliki tingkat kesalahan yang lebih rendah dibandingkan dengan 1D-CNN, baik pada MSE maupun MAE. Selain itu, standar deviasi yang lebih kecil pada MSE dan MAE menunjukkan stabilitas prediksi yang lebih tinggi dari model LSTM dibandingkan dengan 1D-CNN.

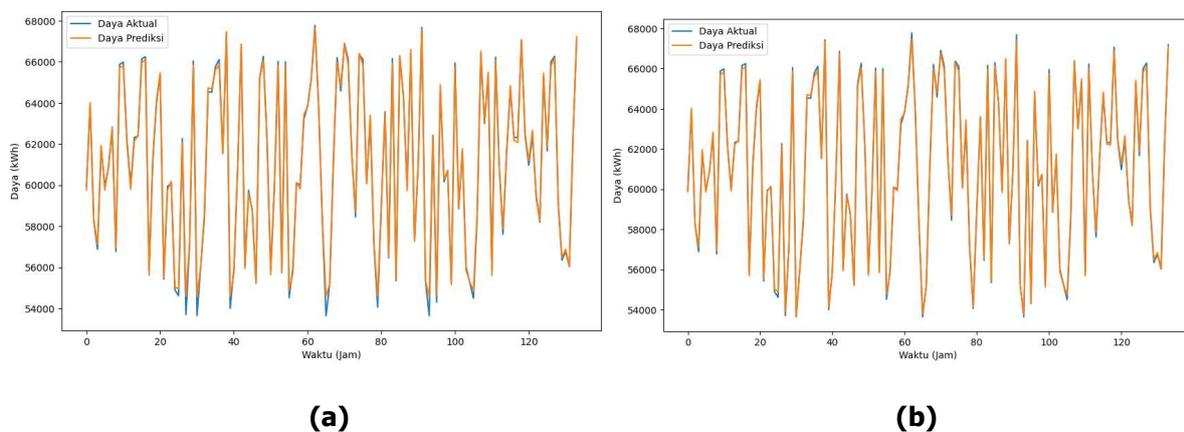
Tabel 4. Performansi Pengujian Model 1D-CNN

ITERASI	1D-CNN		LSTM	
	MSE	MAE	MSE	MAE
1	1,06E-04	0,0281	1,40E-04	0,0094
2	9,06E-04	0,0231	2,43E-04	0,0127
3	9,22E-04	0,0258	2,08E-04	0,0114
4	6,88E-04	0,0208	6,44E-05	0,0067
5	3,39E-04	0,0155	4,99E-04	0,0189
6	2,14E-04	0,0122	7,75E-05	0,0073
7	6,82E-04	0,0202	2,87E-04	0,0138
8	2,36E-04	0,0119	1,19E-04	0,0089
9	3,23E-04	0,0142	1,14E-04	0,0334
10	2,64E-04	0,0137	1,28E-04	0,0087
RATA-RATA	4,68E-04 ± 0,0003	0,01855 ± 0,00586	3,35E-04 ± 0,00013	0,01312 ± 0,0079

Secara keseluruhan, kedua model menunjukkan kinerja yang baik, dengan LSTM yang sedikit lebih unggul dari sisi akurasi. Namun, perlu dicatat bahwa perbedaan performa ini cukup kecil

sehingga dapat dianggap tidak terlalu signifikan dalam konteks aplikasi tertentu. Performa 1D-CNN yang sedikit lebih tinggi dalam MSE dan MAE bisa jadi masih dapat diterima tergantung pada kebutuhan spesifik dari sistem atau aplikasi yang diimplementasikan. Dengan demikian, pemilihan model dapat mempertimbangkan aspek lain seperti efisiensi komputasi yang telah dibahas pada fase pelatihan. Hasil dari fase pelatihan dan pengujian menunjukkan implikasi penting untuk pemilihan model dalam peramalan deret waktu, terutama untuk aplikasi yang mengutamakan efisiensi komputasi dan akurasi prediksi. Model 1D-CNN dan LSTM masing-masing memiliki keunggulan spesifik, yang menunjukkan bahwa pemilihan antara keduanya harus disesuaikan dengan prioritas dari aplikasi yang akan digunakan.

Gambar 5 menunjukkan perbandingan antara grafik daya fungsi waktu model 1D-CNN (a) dan LSTM (b).



Gambar 5. Grafik Prediksi untuk Model (a) 1D-CNN, dan (b) LSTM

Garis biru merepresentasikan daya aktual, sementara garis oranye menunjukkan daya yang diprediksi oleh masing-masing model. Kedua model tampak mengikuti pola fluktuasi data aktual dengan tingkat akurasi yang baik, meskipun terdapat beberapa deviasi di titik-titik tertentu. Hal ini menunjukkan bahwa baik model 1D-CNN maupun LSTM memiliki kemampuan yang cukup dalam menangkap pola data *time series* yang kompleks pada dataset daya listrik yang digunakan. Dalam konteks prediksi konsumsi energi listrik, pemilihan model antara 1D-CNN dan LSTM memiliki implikasi penting berdasarkan kebutuhan akurasi prediksi dan efisiensi waktu. Prediksi konsumsi energi listrik sering kali memerlukan tingkat akurasi yang tinggi karena kesalahan kecil dalam memprediksi dapat berdampak besar pada pengaturan suplai dan distribusi daya, yang pada akhirnya memengaruhi kesetimbangan jaringan listrik. Berdasarkan hasil pengujian, LSTM, yang menunjukkan nilai MSE dan MAE yang sedikit lebih rendah dibandingkan dengan 1D-CNN, dapat dianggap sebagai pilihan yang lebih tepat untuk skenario prediksi konsumsi energi listrik di mana akurasi diutamakan.

Implikasi hasil penelitian untuk manajemen efisiensi energi gedung adalah bahwa pemilihan model harus disesuaikan dengan tujuan operasional yang spesifik. Jika efisiensi komputasi menjadi prioritas, misalnya untuk aplikasi prediksi daya secara *real-time*, model LSTM dapat digunakan karena memberikan hasil yang baik dengan akurasi yang memadai. Namun, jika prediksi daya harus dilakukan dalam waktu singkat atau dalam sistem dengan sumber daya komputasi terbatas, 1D-CNN dapat menawarkan kesetimbangan yang baik antara akurasi dan efisiensi waktu. Dengan menerapkan model yang optimal sesuai kebutuhan, pengelola gedung dapat mengambil keputusan energi yang lebih tepat dan responsif terhadap perubahan pola konsumsi energi listrik, sehingga meningkatkan efisiensi operasional dan keberlanjutan energi gedung.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa model 1D-CNN maupun LSTM memiliki kelebihan masing-masing dalam melakukan prediksi konsumsi energi listrik berbasis data *time series*. Model 1D-CNN memiliki keunggulan dalam hal efisiensi waktu komputasi, yang berguna dalam sistem yang memerlukan prediksi cepat dan respons *real-time*. Dalam pelatihan, 1D-CNN menunjukkan waktu pemrosesan yang lebih cepat dibandingkan dengan LSTM. Sebaliknya, model LSTM menawarkan akurasi yang lebih tinggi, yang sangat penting dalam prediksi daya listrik yang membutuhkan ketepatan prediksi untuk menjaga konsistensi sistem kelistrikan. Walaupun perbedaannya tidak signifikan, 1D-CNN menawarkan keunggulan dalam efisiensi waktu komputasi 63,08s, 1D-CNN lebih cepat sekitar 84.19%. Penelitian selanjutnya, pengembangan dapat difokuskan pada peningkatan performa akurasi 1D-CNN, dengan memodifikasi arsitektur atau melakukan *tuning* pada hiperparameter. Selain itu, penelitian ini belum mengeksplorasi dampak dari penggunaan dataset yang lebih besar. Oleh karena itu, sebagai penelitian lanjutan, eksperimen dengan dataset yang lebih luas dapat dilakukan untuk mengevaluasi apakah penambahan data akan memberikan peningkatan signifikan terhadap akurasi dan stabilitas model prediksi.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) dalam publikasi penelitian ini.

DAFTAR RUJUKAN

- Anugrahayu, M., & Azmi, U. (2023). Stock Portfolio Optimization Using Mean-Variance and Mean Absolute Deviation Model Based On K-Medoids Clustering by Dynamic Time Warping. *Jurnal Matematika, Statistika dan Komputasi*, 20(1), 164-183.
- Dong, K., & Lotfipoor, A. (2023). Intelligent bearing fault diagnosis based on feature fusion of one-dimensional dilated CNN and multi-domain signal processing. *Sensors*, 23(12), 5607.
- Fikriansyah, M. N., Nugroho, H. A., & Sinambela, M. (2022, 8-9 Dec. 2022). *Low Cloud Type Classification System Using Convolutional Neural Network Algorithm*. Paper presented at the 2022 Seventh International Conference on Informatics and Computing (ICIC).
- Ishida, K., Ercan, A., Nagasato, T., Kiyama, M., & Amagasaki, M. (2024). Use of one-dimensional CNN for input data size reduction in LSTM for improved computational efficiency and accuracy in hourly rainfall-runoff modeling. *Journal of Environmental Management*, 359, 120931.
- Izonin, I., Tkachenko, R., Shakhovska, N., Ilchyshyn, B., & Singh, K. K. (2022). A two-step data normalization approach for improving classification accuracy in the medical diagnosis domain. *Mathematics*, 10(11), 1942.

- Le, X.-H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Water*, *11*(7), 1387.
- Liu, L., & Si, Y.-W. (2022). 1D convolutional neural networks for chart pattern classification in financial time series. *The Journal of Supercomputing*, *78*(12), 14191-14214.
- Nugroho, H. A., Hasanah, S., & Yusuf, M. (2022). Seismic Data Quality Analysis Based on Image Recognition Using Convolutional Neural Network. *JUITA: Jurnal Informatika*, *10*(1), 67-75.
- Nugroho, H. A., Subiantoro, A., & Kusumoputro, B. (2023). Performance Analysis of Ensemble Deep Learning NARX System for Estimating the Earthquake Occurrences in the Subduction Zone of Java Island. *International Journal of Technology*, *14*(7), 1517-1526.
- Raharjo, A. B., Ardianto, A., & Purwitasari, D. (2022). Random Forest Regression Untuk Prediksi Produksi Daya Pembangkit Listrik Tenaga Surya. *Briliant: Jurnal Riset dan Konseptual*, *7*(4), 1058-1075.
- Reza, S., Ferreira, M. C., Machado, J. J., & Tavares, J. M. R. (2022). Traffic state prediction using one-dimensional convolution neural networks and long short-term memory. *Applied Sciences*, *12*(10), 5149.
- Sahoo, B. B., Jha, R., Singh, A., & Kumar, D. (2019). Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting. *Acta Geophysica*, *67*(5), 1471-1481.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E., Menon, V. K., & Soman, K. (2017). *Stock price prediction using LSTM, RNN and CNN-sliding window model*. Paper presented at the 2017 international conference on advances in computing, communications and informatics (icacci).
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, *404*, 132306.
- Song, X., Liu, Y., Xue, L., Wang, J., Zhang, J., Wang, J., . . . Cheng, Z. (2020). Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model. *Journal of Petroleum Science and Engineering*, *186*, 106682.
- Teruna, D., & Ardiansyah, T. (2024). Analisis Trend Posisi Kredit Umkm Pada Bank Umum Untuk Skala Menengah Di Indonesia. *Jurnal USAHA*, *5*(1), 107-123.
- Trinh, T., Dai, A., Luong, T., & Le, Q. (2018). *Learning longer-term dependencies in rnns with auxiliary losses*. Paper presented at the International Conference on Machine Learning.

- Wang, J., Zhang, J., & Wang, X. (2017). Bilateral LSTM: A two-dimensional long short-term memory model with multiply memory units for short-term cycle time forecasting in re-entrant manufacturing systems. *IEEE Transactions on Industrial Informatics*, *14*(2), 748-758.
- Zhao, B., Lu, H., Chen, S., Liu, J., & Wu, D. (2017). Convolutional neural networks for time series classification. *Journal of systems engineering and electronics*, *28*(1), 162-169.