

Long Short-Term Memory untuk Prediksi Beban Listrik Jangka Pendek pada Lini Produksi Manufaktur

Martias¹, Sri Watmah², Rian Septian Anwar³

^{1,2,3}Universitas Bina Sarana Informatika

e-mail: ¹martias.mts@bsi.ac.id, ²sriwatmah.wtm@bsi.ac.id, ³rian.ptn@bsi.ac.id

Diterima	Direvisi	Disetujui
01-07-2026	20-07-2026	23-07-2026

Abstrak - Pengelolaan energi listrik pada lini produksi merupakan faktor penting dalam efisiensi biaya operasional dan keberlanjutan industri manufaktur. Beban listrik lini produksi bersifat nonlinier dan fluktuatif karena dipengaruhi pola operasi sif, jadwal produksi, dan perilaku mesin, sehingga sulit diprediksi menggunakan metode statistik konvensional. Penelitian ini menerapkan model deep learning Long Short-Term Memory (LSTM) untuk peramalan beban listrik jangka pendek satu jam ke depan. Data yang digunakan adalah dataset publik ElectricityLoadDiagrams (Trindade, 2015) dari UCI Machine Learning Repository versi agregasi per jam yang memuat 321 pelanggan selama 2012-2014; satu pelanggan dengan profil industri dan autokorelasi harian tinggi (0,984) dipilih sebagai representasi beban lini produksi. Data diproses melalui pembersihan, standardisasi Z-score, penambahan fitur kalender, dan pembentukan sliding window 24 jam. Model LSTM dilatih menggunakan algoritma Adam dan dibandingkan dengan ARIMA serta Multilayer Perceptron (MLP). Hasil pengujian pada 3.946 titik data menunjukkan model LSTM memberikan akurasi terbaik dengan MAPE 6,83%, lebih rendah dibanding ARIMA (7,31%) dan MLP (10,07%), serta koefisien korelasi 0,99 terhadap data aktual. Temuan ini menunjukkan LSTM mampu menangkap ketergantungan temporal beban listrik sehingga dapat mendukung perencanaan produksi, penjadwalan beban, dan efisiensi energi dalam manajemen industri.

Kata Kunci: peramalan beban listrik, LSTM, lini produksi, deep learning, manajemen energi

PENDAHULUAN

Energi listrik merupakan sumber daya utama dalam industri manufaktur. Pada lini produksi, konsumsi listrik menentukan kelancaran operasi mesin sekaligus berkontribusi besar terhadap struktur biaya produksi. Konsumsi listrik sektor industri terus meningkat seiring pertumbuhan kapasitas produksi, sehingga pengelolaan beban listrik yang efisien menjadi kebutuhan strategis untuk menjaga daya saing dan mendukung keberlanjutan.

Di sektor manufaktur, biaya energi listrik dapat mencapai porsi signifikan dari total biaya produksi, terutama pada industri padat energi. Tarif listrik industri yang umumnya menerapkan komponen biaya beban puncak menjadikan pengendalian profil konsumsi sebagai peluang penghematan yang nyata. Dalam kerangka Industri 4.0, ketersediaan data konsumsi beresolusi tinggi dari sistem pemantauan energi membuka peluang penerapan analitik data untuk mengoptimalkan penggunaan listrik pada lini produksi.

Peramalan beban listrik (load forecasting) merupakan instrumen penting dalam perencanaan dan pengendalian energi. Dengan peramalan yang akurat, manajemen industri dapat menyusun jadwal produksi yang efisien, melakukan peak shaving, mengoptimalkan kontrak daya, serta menurunkan risiko denda akibat kelebihan beban (Hyndman & Athanasopoulos, 2018). Namun, beban listrik pada lini produksi memiliki

karakteristik nonlinier dan fluktuatif yang dipengaruhi pola sif kerja, perubahan jadwal produksi, serta perilaku start-stop mesin.

Metode statistik konvensional seperti Autoregressive Integrated Moving Average (ARIMA) telah lama digunakan untuk peramalan deret waktu (Box, Jenkins, Reinsel, & Ljung, 2015). Namun, ARIMA mengasumsikan hubungan linier dan stasioneritas data, sehingga kurang mampu menangkap pola nonlinier kompleks pada beban industri. Keterbatasan ini mendorong pemanfaatan pendekatan machine learning yang lebih adaptif.

Deep learning, khususnya jaringan saraf rekuren, terbukti unggul dalam pemodelan data deret waktu (LeCun, Bengio, & Hinton, 2015; Goodfellow, Bengio, & Courville, 2016). LSTM dikembangkan sebagai solusi struktural atas kegagalan RNN konvensional dalam mempelajari dependensi jangka panjang akibat permasalahan vanishing gradient. Melalui penerapan mekanisme gerbang (gating mechanism), LSTM mampu mengatur aliran informasi dan mempertahankan gradien secara stabil sepanjang proses pelatihan (Sherstinsky, 2020). LSTM disempurnakan (Gers, Schmidhuber, dan Cummins, 2000) mengatasi masalah vanishing gradient melalui mekanisme gerbang yang menyimpan informasi jangka panjang. (Siami-Namini, Tavakoli, dan Siami Namin, 2018) menunjukkan LSTM menurunkan kesalahan secara signifikan dibanding ARIMA, sementara (Kong et al., 2019) dan (Marino,



Amarasinghe, dan Manic, 2016) menerapkannya untuk peramalan beban dengan hasil menjanjikan.

Pada konteks industri, (Wang et al., 2021) mengembangkan model TCN-LightGBM untuk peramalan beban pelanggan industri, dan (Bouktif et al., 2018) mengoptimalkan LSTM untuk peramalan beban listrik. Meskipun demikian, sebagian besar studi berfokus pada beban agregat sistem tenaga atau sektor residensial, sedangkan kajian yang secara khusus mengarah pada beban lini produksi dengan dataset publik yang dapat direplikasi masih terbatas.

Pertanyaan penelitian yang diajukan adalah sejauh mana model LSTM mampu memprediksi beban listrik lini produksi secara akurat, dan apakah kinerjanya lebih baik dibanding pendekatan statistik klasik serta jaringan saraf konvensional. Untuk menjawabnya, penelitian ini melakukan eksperimen terkendali dengan data nyata dan membandingkan tiga model peramalan pada partisi data dan metrik yang sama.

Berdasarkan latar belakang tersebut, penelitian ini menerapkan model LSTM untuk memprediksi beban listrik jangka pendek pada profil pelanggan industri dan membandingkannya dengan ARIMA dan MLP menggunakan data nyata. Kontribusi penelitian ini adalah menyediakan kerangka peramalan beban yang dapat direplikasi serta menelaah implikasinya bagi pengambilan keputusan manajemen industri dalam efisiensi energi pada lini produksi.

LANDASAN TEORI

LSTM merupakan varian recurrent neural network (RNN) yang memiliki sel memori untuk menyimpan informasi pada rentang waktu panjang. Setiap sel LSTM dikendalikan tiga gerbang, yaitu forget gate, input gate, dan output gate, yang mengatur seberapa banyak informasi dipertahankan, diperbarui, dan dikeluarkan. Pada langkah waktu t , dengan masukan x_t dan keadaan tersembunyi sebelumnya h_{t-1} , proses komputasi sel LSTM dinyatakan pada Persamaan (1) hingga (6).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$


Notasi sigma adalah fungsi sigmoid, tanh fungsi tangen hiperbolik, $(\cdot)$ operasi perkalian elemen, W dan b masing-masing matriks bobot dan bias, f_t , i_t , o_t keluaran ketiga gerbang, c_t keadaan sel, dan h_t keadaan tersembunyi. Mekanisme gerbang inilah yang memungkinkan LSTM mempelajari ketergantungan temporal jangka panjang pada data beban listrik.

Pada peramalan beban listrik, ketergantungan temporal muncul dalam bentuk pola harian, mingguan, dan musiman. Kemampuan LSTM mempertahankan keadaan sel lintas banyak langkah waktu membuatnya sesuai untuk menangkap pola berulang tersebut tanpa

perlu menentukan orde model secara eksplisit seperti pada ARIMA. Selain itu, LSTM dapat menerima masukan multivariat sehingga memungkinkan penggabungan informasi beban historis dengan fitur kontekstual seperti waktu, yang sulit diakomodasi model linier.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tahapan akuisisi data, pra-pemrosesan, pelatihan model, dan evaluasi. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Sumber: hasil pengolahan (2025).

Gambar 1. Alur Penelitian

Data Penelitian


Data yang digunakan adalah dataset publik ElectricityLoadDiagrams yang dipublikasikan Trindade, (2015) pada UCI Machine Learning Repository, dalam versi agregasi per jam yang umum dipakai sebagai tolok ukur peramalan deret waktu. Dataset memuat konsumsi listrik 321 pelanggan selama 2012-2014. Satu pelanggan dengan profil konsumsi bertipe industri dan autokorelasi harian tinggi (0,984) dipilih sebagai representasi beban lini produksi. Ringkasan dataset disajikan pada Tabel 1, dan profil beban dua minggu terakhir ditunjukkan pada Gambar 2.

Tabel 1. Deskripsi Dataset Penelitian

Atribut	Keterangan
Sumber	UCI ElectricityLoadDiagrams (versi per jam)
Jumlah pelanggan	321
Periode	2012-2014
Resolusi	1 jam
Total observasi	26.304 titik waktu
Pelanggan terpilih	#313 (profil industri)

Rata-rata beban	+/- 200.529 satuan/jam (kWh)
Autokorelasi harian	0,984

Sumber: Trindade (2015), diolah



Sumber: hasil pengolahan (2025).

Gambar 2. Profil Beban Listrik Pelanggan Industri (dua minggu terakhir)

Pra-pemrosesan Data

Tahap pra-pemrosesan meliputi pembersihan data, standarisasi nilai beban menggunakan Z-score sebagaimana Persamaan (7) dengan mu dan sigma masing-masing rata-rata dan simpangan baku data latih, serta penambahan fitur kalender berupa jam dalam sehari dan hari dalam seminggu yang dikodekan dengan fungsi sinus-kosinus.

$$x' = (x - \mu) / \sigma \quad (7)$$

Selanjutnya dibentuk sliding window, yaitu 24 jam data sebelumnya digunakan untuk memprediksi beban satu jam ke depan. Untuk mempercepat konvergensi, model dilatih memprediksi selisih beban (delta) terhadap jam terakhir. Data dibagi secara berurutan menjadi latih, validasi, dan uji seperti pada Tabel 2.

Tabel 2. Pembagian Data

Subset	Proporsi	Jumlah Sampel
Latih	70%	+/- 18.300
Validasi	15%	+/- 3.900
Uji	15%	3.946

Sumber: hasil pengolahan (2025)

Penambahan fitur kalender bertujuan memberi model informasi eksplisit mengenai posisi waktu suatu observasi, mengingat beban lini produksi sangat dipengaruhi jam kerja dan hari operasional. Pengkodean sinus-kosinus dipilih agar sifat siklik waktu (misalnya jam ke-23 berdekatan dengan jam ke-0) terjaga. Strategi prediksi selisih (delta) membuat target pelatihan lebih stasioner sehingga mempercepat konvergensi dan menstabilkan proses optimisasi.

Arsitektur dan Hyperparameter Model

Model LSTM yang dibangun terdiri atas satu lapis LSTM dengan 32 unit, diikuti lapisan dense sebagai keluaran. Model dioptimasi menggunakan algoritma Adam (Kingma & Ba, 2015) dengan fungsi rugi Mean Squared Error. Konfigurasi hyperparameter ditunjukkan pada Tabel 3.

Tabel 3. Konfigurasi Hyperparameter Model LSTM

Parameter	Nilai
Lapis LSTM	1 (32 unit)
Panjang window	24 jam
Jumlah fitur	5 (beban + kalender)
Target	Selisih beban ternormalisasi
Normalisasi	Z-score
Optimisasi	Adam (lr = 0,005)
Ukuran batch	128
Fungsi rugi	Mean Squared Error
Epoch	69

Sumber: hasil pengolahan (2025)

Prosedur Peramalan

Prosedur peramalan beban listrik menggunakan LSTM diringkas pada Algoritma 1.

Algoritma 1. Prosedur Peramalan Beban Listrik dengan LSTM

- 1) Muat data konsumsi listrik per jam dan pilih pelanggan target dengan profil industri.
- 2) Bersihkan data lalu lakukan standarisasi Z-score berdasarkan statistik data latih.
- 3) Bentuk fitur kalender (jam dan hari) menggunakan pengkodean sinus-kosinus.
- 4) Susun sliding window 24 jam sebagai masukan dan selisih beban jam berikutnya sebagai target.
- 5) Bagi data menjadi latih (70%), validasi (15%), dan uji (15%) secara berurutan.
- 6) Inisialisasi dan latih jaringan LSTM dengan optimisasi Adam serta pemantauan loss validasi.
- 7) Lakukan prediksi pada data uji dan rekonstruksi nilai beban dari selisih.
- 8) Evaluasi kinerja model menggunakan MAE, RMSE, dan MAPE.

Model Pemanding

Dua model pembanding digunakan. Model pertama adalah ARIMA(24,1,0), yaitu model autoregresif orde 24 atas data terdiferensiasi yang dilatih menggunakan metode kuadrat terkecil, mewakili pendekatan statistik klasik. Model kedua adalah Multilayer Perceptron (MLP) dengan satu lapis tersembunyi sebagai baseline jaringan saraf umpan-maju. Ketiga model dilatih dan diuji pada partisi data yang sama agar perbandingan bersifat adil.

Metrik Evaluasi

Kinerja model dievaluasi menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE), sebagaimana Persamaan (8), (9), dan (10). Notasi A_t adalah nilai aktual, F_t nilai prediksi, dan n jumlah data uji.

$$MAE = (1/n) \sum |A_t - F_t| \quad (8)$$

$$RMSE = \sqrt{(1/n) \sum (A_t - F_t)^2} \quad (9)$$

$$MAPE = (100\%/n) \sum |(A_t - F_t) / A_t| \quad (10)$$

Seluruh eksperimen diimplementasikan

menggunakan bahasa pemrograman Python dengan komputasi numerik berbasis NumPy.

HASIL DAN PEMBAHASAN

Karakteristik Data

Profil beban pada Gambar 2 menunjukkan pola harian dan mingguan yang jelas. Beban memuncak pada jam operasional produktif di hari kerja dan menurun pada malam hari serta akhir pekan. Autokorelasi harian sebesar 0,984 menegaskan adanya ketergantungan temporal yang kuat, sesuai dengan kemampuan LSTM dalam memodelkan urutan waktu.

Statistik deskriptif beban pelanggan terpilih disajikan pada Tabel 6. Koefisien variasi sebesar 0,728 mengindikasikan tingkat fluktuasi beban yang tinggi, sementara autokorelasi 24 jam (0,984) dan 168 jam (0,949) yang besar menegaskan kuatnya pola harian dan mingguan. Kombinasi volatilitas tinggi dan ketergantungan temporal kuat inilah yang menjadikan pendekatan nonlinier berbasis memori seperti LSTM relevan untuk data ini.


Tabel 4. Statistik Deskriptif Beban Pelanggan #313

Statistik	Nilai (kWh)
Rata-rata	200.529
Median	174.000
Simpangan baku	146.052
Minimum	0
Maksimum	764.000
Koefisien variasi	0,728
Autokorelasi 24 jam	0,984
Autokorelasi 168 jam	0,949

Sumber: hasil pengolahan (2025)

Proses Pelatihan Model

Kurva nilai loss pelatihan dan validasi ditunjukkan pada Gambar 3. Nilai loss menurun tajam pada epoch awal dan stabil setelahnya. Kurva latih dan validasi yang berdekatan menandakan model tidak mengalami overfitting berarti, sehingga kemampuan generalisasi tetap terjaga.




Sumber: hasil pengolahan (2025).

Gambar 3. Kurva Loss Pelatihan dan Validasi Model LSTM

Hasil Prediksi

Perbandingan beban aktual dengan hasil prediksi LSTM pada data uji ditunjukkan pada Gambar 4. Kurva

prediksi mengikuti pola aktual dengan baik, termasuk pada titik puncak dan lembah beban, dengan koefisien korelasi 0,99. Hal ini menandakan model berhasil mempelajari dinamika beban lini produksi.



Sumber: hasil pengolahan (2025).

Gambar 4. Perbandingan Beban Aktual dan Prediksi LSTM pada Data Uji

Perbandingan Kinerja Model

Hasil evaluasi ketiga model pada 3.946 titik data uji disajikan pada Tabel 5. Model LSTM memperoleh nilai kesalahan terendah pada seluruh metrik, dengan MAE 11.965,8, RMSE 18.848,5, dan MAPE 6,83%, mengungguli ARIMA maupun MLP.

Tabel 5. Perbandingan Kinerja Model pada Data Uji

Model	MAE	RMSE	MAPE (%)
ARIMA(24,1,0)	12.396,6	19.057,1	7,31
MLP	13.753,8	18.969,8	10,07
LSTM	11.965,8	18.848,5	6,83

Sumber: hasil pengolahan (2025). MAE dan RMSE dalam satuan kWh.

Apabila ditinjau dari peningkatan relatif, LSTM menurunkan MAPE sebesar 6,6% dibanding ARIMA dan 32,2% dibanding MLP. Rincian peningkatan akurasi relatif LSTM terhadap kedua model pembandingan pada setiap metrik disajikan pada Tabel 5.

Tabel 6. Peningkatan Akurasi Relatif LSTM terhadap Baseline (%)

Metrik	vs ARIMA	vs MLP
MAE	3,5	13,0
RMSE	1,1	0,6
MAPE	6,6	32,2

Sumber: hasil pengolahan (2025)

Analisis Galat

Sebagai ilustrasi, dengan menurunkan kesalahan rata-rata, perusahaan dapat menetapkan kapasitas daya kontrak yang lebih tepat dan mengurangi cadangan beban berlebih. Peramalan yang akurat satu jam hingga sehari ke depan memberi ruang bagi penyelia produksi untuk menyesuaikan urutan operasi mesin sehingga konsumsi listrik lebih merata sepanjang waktu, yang pada gilirannya menurunkan beban puncak dan biaya energi.

Analisis sebaran galat menunjukkan kesalahan prediksi terbesar cenderung terjadi pada titik transisi beban, yaitu saat mesin mulai dinyalakan di awal sif dan

dimatikan di akhir sif, ketika perubahan beban berlangsung tajam. Pada periode beban relatif stabil, galat model jauh lebih kecil. Pola ini konsisten dengan karakteristik operasional lini produksi dan mengindikasikan bahwa penambahan variabel status produksi berpotensi menurunkan galat pada titik-titik transisi tersebut.

Implikasi Manajerial

Akurasi peramalan yang tinggi dapat diterjemahkan menjadi sejumlah keputusan operasional. Pertama, jadwal produksi dapat disusun agar aktivitas berdaya tinggi tidak menumpuk pada periode beban puncak, sehingga perusahaan menghindari biaya denda kelebihan daya. Kedua, peramalan beban menjadi masukan strategi load shifting, yaitu memindahkan sebagian beban non-kritis ke periode tarif listrik yang lebih murah.

Ketiga, deviasi antara beban aktual dan prediksi dapat berfungsi sebagai indikator dini anomali mesin; lonjakan konsumsi yang menyimpang jauh dari prediksi dapat menandakan penurunan efisiensi atau gangguan peralatan. Dengan demikian, model peramalan berpotensi terintegrasi dengan sistem predictive maintenance pada manajemen industri.

Lebih jauh, integrasi model peramalan ke dalam sistem manajemen energi memungkinkan pemantauan berkelanjutan terhadap efisiensi penggunaan listrik. Indikator kinerja seperti rasio beban aktual terhadap prediksi dapat dijadikan dasar evaluasi efektivitas program efisiensi energi serta bahan pertimbangan dalam audit energi periodik pada fasilitas produksi.

Perbandingan dengan Penelitian Terdahulu

Nilai MAPE sebesar 6,83% yang diperoleh model LSTM berada pada rentang akurasi yang baik untuk peramalan beban tingkat pelanggan individual, yang umumnya lebih sulit diprediksi dibanding beban agregat sistem karena volatilitasnya lebih tinggi. Kong et al. (2019) melaporkan bahwa peramalan beban pada level pelanggan tunggal cenderung menghasilkan galat lebih besar dibanding level agregat, sehingga capaian pada penelitian ini konsisten dengan temuan tersebut.

Selain itu, superioritas LSTM terhadap model statistik dan jaringan saraf umpan-maju selaras dengan hasil Siami-Namini et al. (2018) serta Bouktif et al. (2018). Perbedaan utama penelitian ini terletak pada konteks penerapan, yaitu profil beban industri sebagai representasi lini produksi, serta penggunaan dataset publik sehingga hasil dapat direplikasi dan dibandingkan oleh peneliti lain.

Pembahasan

Keunggulan LSTM dibanding ARIMA disebabkan kemampuannya memodelkan hubungan nonlinier dan menyimpan informasi temporal melalui mekanisme gerbang memori, sedangkan ARIMA terbatas pada asumsi linieritas. Dibanding MLP, LSTM lebih unggul karena MLP tidak memiliki mekanisme memori untuk

merepresentasikan keterurutan waktu secara eksplisit. Temuan ini sejalan dengan Siami-Namini et al. (2018) dan Kong et al. (2019) yang melaporkan superioritas LSTM dalam peramalan deret waktu beban listrik.

Dibandingkan pendekatan TCN-LightGBM yang dikembangkan Wang et al. (2021), model LSTM dalam penelitian ini menawarkan kesederhanaan implementasi dengan tetap mempertahankan akurasi kompetitif. Hal ini menjadikan LSTM pilihan seimbang antara kompleksitas dan kinerja, terutama bagi perusahaan manufaktur yang baru memulai adopsi analitik data untuk manajemen energi dan belum memiliki infrastruktur komputasi berskala besar.

Dari sisi implementasi, pelatihan LSTM membutuhkan komputasi lebih besar dibanding ARIMA karena proses iteratif berbasis gradien. Namun, setelah model terlatih, proses inferensi berlangsung cepat sehingga layak diterapkan untuk peramalan harian maupun jam-an. Keterbatasan penelitian ini adalah penggunaan satu pelanggan industri sebagai proksi beban lini produksi tanpa variabel kontekstual spesifik seperti jumlah unit produk dan status mesin; penggunaan data riil lini produksi beserta variabel tersebut berpotensi meningkatkan akurasi dan generalisasi model lebih lanjut.

Konsistensi antara galat pada data validasi dan data uji menunjukkan model memiliki kemampuan generalisasi yang baik dan tidak sekadar menghafal pola data latih. Meskipun demikian, kinerja model bergantung pada karakteristik beban; pada lini produksi dengan pola yang sangat tidak teratur, akurasi dapat menurun sehingga diperlukan penyetelan ulang hyperparameter dan penambahan fitur yang relevan dengan konteks operasional.

KESIMPULAN

Penelitian ini menerapkan model deep learning LSTM untuk peramalan beban listrik jangka pendek pada profil pelanggan industri menggunakan dataset publik ElectricityLoadDiagrams. Hasil pengujian pada 3.946 titik data menunjukkan LSTM memberikan akurasi terbaik dengan MAE 11.965,8, RMSE 18.848,5, dan MAPE 6,83%, mengungguli ARIMA (MAPE 7,31%) dan MLP (MAPE 10,07%), dengan koefisien korelasi 0,99. Hal ini membuktikan kemampuan LSTM dalam menangkap ketergantungan temporal beban listrik lini produksi.

Secara praktis, model ini dapat dimanfaatkan untuk mendukung perencanaan produksi, penjadwalan beban, dan strategi efisiensi energi dalam manajemen industri. Penelitian selanjutnya direkomendasikan untuk mengintegrasikan variabel eksternal seperti jadwal produksi, jumlah sif, dan suhu lingkungan, menerapkan peramalan multi-langkah (day-ahead), serta menguji model hibrida seperti CNN-LSTM atau LSTM-Attention guna meningkatkan akurasi pada beragam tipe lini produksi.

REFERENSI

- Bouktif, S., Fiaz, A., Ouni, A., & Serhani, M. A. (2018). Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11(7), 1636. <https://doi.org/10.3390/en11071636>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Hoboken, NJ: John Wiley & Sons.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. Cambridge, MA: MIT Press.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). Melbourne: OTexts.
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. In *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*. <https://doi.org/10.48550/arXiv.1412.6980>
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., & Zhang, Y. (2019). Short-term residential load forecasting based on LSTM recurrent neural network. *IEEE Transactions on Smart Grid*, 10(1), 841-851. <https://doi.org/10.1109/TSG.2017.2753802>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Marino, D. L., Amarasinghe, K., & Manic, M. (2016). Building energy load forecasting using deep neural networks. In *Proceedings of the 42nd Annual Conference of the IEEE Industrial Electronics Society (IECON)* (pp. 7046-7051). <https://doi.org/10.1109/IECON.2016.7793413>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network. *Physica D: Nonlinear Phenomena*, 404, 132306.
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2018). A comparison of ARIMA and LSTM in forecasting time series. In *Proceedings of the 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1394-1401). <https://doi.org/10.1109/ICMLA.2018.00227>
- Trindade, A. (2015). *ElectricityLoadDiagrams20112014* [Data set]. UCI Machine Learning Repository. <https://doi.org/10.24432/C58C86>
- Wang, Y., Chen, J., Chen, X., Zeng, X., Kong, Y., Sun, S., Guo, Y., & Liu, Y. (2021). Short-term load forecasting for industrial customers based on TCN-LightGBM. *IEEE Transactions on Power Systems*, 36(3), 1984-1997. <https://doi.org/10.1109/TPWRS.2020.>