

PERBANDINGAN ARSITEKTUR VANILLA, STACKED, DAN BIDIRECTIONAL LONG SHORT-TERM MEMORY UNTUK PREDIKSI PERIODE MUSIM DI SURABAYA

Diana Sinthya Putri, Wahyu Syaifullah Jauharis Saputra, Kartika Maulida Hindrayani

Sains Data, UPN “Veteran” Jawa Timur

Jl. Rungkut Madya, Kec. Gn. Anyar, Surabaya, Jawa Timur

wahyu.s.j.saputra.if@upnjatim.ac.id

ABSTRAK

Indonesia memiliki dua musim utama, namun perubahan iklim global menyebabkan pergeseran pola musim yang tidak menentu. Hal ini berdampak pada berbagai sektor, termasuk agribisnis, transportasi, dan konstruksi. Surabaya, sebagai pusat ekonomi di Jawa Timur, memerlukan prediksi musiman yang akurat untuk mitigasi risiko dan perencanaan strategis. Penelitian ini mengevaluasi kinerja tiga arsitektur *Long Short-Term Memory* (LSTM), yaitu *Vanilla LSTM*, *Stacked LSTM*, dan *Bidirectional LSTM*, dalam memprediksi pola musiman curah hujan di Surabaya. Data yang digunakan berasal dari BMKG Stasiun Meteorologi Maritim Tanjung Perak, mencakup periode 2001-2024. Hasil eksperimen menunjukkan bahwa *Bidirectional LSTM* mencapai nilai MAE terendah sebesar 25,7883, diikuti oleh *Stacked LSTM* dengan MAE 26,5515, dan *Vanilla LSTM* dengan MAE 27,7023. Temuan ini mengkonfirmasi bahwa arsitektur yang lebih dalam dan kompleks, seperti *Stacked LSTM* dan *Bidirectional LSTM*, mampu meningkatkan akurasi prediksi secara signifikan dibandingkan *Vanilla LSTM*.

Kata kunci : *Long short-term memory, prediksi, periode musim, curah hujan*

1. PENDAHULUAN

Indonesia merupakan negara tropis yang hanya memiliki dua musim utama, yaitu musim hujan yang biasanya berlangsung dari bulan Oktober hingga Maret, dan musim kemarau yang umumnya berlangsung dari bulan April hingga September [1]. Namun, perubahan iklim global telah menyebabkan pergeseran pola musim yang semakin tidak menentu. Dampak dari perubahan iklim antara lain perpanjangan atau pemendekan durasi musim, peningkatan intensitas cuaca ekstrem, serta frekuensi hujan dan kekeringan yang ekstrem [2]. Pada Pertemuan Nasional Prediksi Musim Kemarau 2024, Kepala BMKG menyoroti bahwa perubahan iklim di Indonesia terjadi pada tingkat yang belum pernah terjadi sebelumnya. Selain itu, menurut Siaran Pers BRIN (30 Januari 2024), sebagian besar Pulau Jawa, termasuk Jawa Timur, menghadapi risiko suhu maksimum yang lebih tinggi dan suhu minimum yang lebih rendah, terutama di wilayah pesisir. Kondisi ini menjadi tantangan besar dalam berbagai aspek kehidupan, terutama dalam perencanaan cuaca dan mitigasi risiko [3].

Surabaya, sebagai salah satu kota besar yang menjadi pusat perekonomian di Jawa Timur, memiliki peran strategis di berbagai sektor. Kondisi iklim dan pola musim di kota ini memiliki pengaruh yang cukup signifikan terhadap keberlangsungan kegiatan ekonomi, terutama pada sektor-sektor yang sangat bergantung pada kestabilan cuaca, seperti sektor agribisnis, transportasi, dan konstruksi [4]. Prediksi musiman menjadi penting untuk dilakukan mengingat dampak perubahan iklim yang menyebabkan pola cuaca menjadi semakin tidak menentu [5]. Oleh karena itu, pengembangan model prediksi musiman yang akurat menjadi kebutuhan yang mendesak. Salah satu pendekatan inovatif untuk menjawab tantangan ini

adalah dengan memanfaatkan teknologi *machine learning*. *Machine learning* merupakan salah satu cabang dari kecerdasan buatan yang memungkinkan model untuk belajar dan berevolusi berdasarkan pengalaman. Salah satu metode yang digunakan untuk menangani data yang berhubungan dengan waktu adalah *recurrent neural networks* (RNN). LSTM atau *Long Short-Term Memory* yang merupakan varian dari RNN dilengkapi dengan sel memori khusus yang dapat menyimpan informasi penting dari waktu-waktu sebelumnya [6], sehingga cocok digunakan untuk menganalisa data *time series* dan telah terbukti efektif [7], [8], [9].

Beberapa penelitian telah dilakukan dalam upaya memprediksi awal musim, terutama dengan memanfaatkan metode statistik dan teknik kecerdasan buatan seperti yang dilakukan oleh Wati dkk [10] di Ketapang bagian selatan. Penelitian tersebut menggunakan data curah hujan selama 11 tahun dari Stasiun Meteorologi Rahadi Oesman Ketapang dengan metode ARIMA. Hasil yang didapatkan berupa MAPE sebesar 57,08% dan koefisien korelasi sebesar 0,2. Penelitian lain yang memprediksi curah hujan dasarian untuk menentukan awal musim dengan metode *Vanilla RNN* dan LSTM [11] menggunakan data yang diperoleh dari Stasiun Meteorologi Kelas I I Gusti Ngurah Rai dari tahun 2015 sampai dengan tahun 2020. Hasil penelitian yang diperoleh yaitu metode *Vanilla RNN* dengan seleksi fitur memperoleh hasil terbaik dengan nilai R-Squared sebesar 0,6139 dan RMSE sebesar 28,4308. Berdasarkan penelitian-penelitian tersebut terdapat kesenjangan yang dapat dijawab melalui penelitian ini. Seperti, penggunaan metode ARIMA yang kurang mampu menangkap pola nonlinier, serta penerapan *Vanilla RNN* dan LSTM tanpa membandingkan arsitektur yang lebih kompleks seperti *Stacked* dan *Bidirectional LSTM*. Selain itu,

evaluasi performa model dalam penelitian sebelumnya belum dilakukan secara komprehensif dengan jumlah parameter yang sama. Sebagian besar studi juga hanya menggunakan dataset dengan cakupan kurang dari 12 tahun, yang kurang representatif dalam mendeteksi tren perubahan iklim jangka panjang. Terakhir, belum ada penelitian yang secara khusus membahas prediksi musiman di Surabaya, sehingga masih ada peluang untuk mengeksplorasi bagaimana rentang data yang lebih panjang dapat meningkatkan akurasi prediksi.

Oleh karena itu, penelitian ini diharapkan dapat menghasilkan model prediksi musim yang lebih akurat, yang dapat digunakan untuk meningkatkan keandalan prakiraan cuaca dan dapat memberikan kontribusi nyata dalam pengembangan sistem peringatan dini berbasis kecerdasan buatan, yang dapat membantu mengurangi dampak perubahan iklim, khususnya di Surabaya.

2. TINJAUAN PUSTAKA

Dalam penelitian ini, tinjauan pustaka difokuskan pada konsep dasar dan pengembangan model prediksi periode musim, khususnya yang menggunakan arsitektur jaringan atau LSTM.

2.1. Prediksi

Prediksi merupakan aktivitas yang dilakukan oleh seorang untuk memperkirakan peristiwa di masa depan [12]. Saat ini, banyak penelitian terkait kegiatan prediksi yang mengembangkan berbagai metode untuk menentukan hasil analisis yang paling akurat. *Time Series* atau Deret Waktu adalah cabang ilmu yang digunakan dalam statistik yang merujuk pada rangkaian data yang terdiri dari nilai pengamatan yang diukur selama periode waktu tertentu, dengan interval yang seragam. Tujuan model peramalan ini digunakan untuk mengenali pola dari data historis dan menggunakannya sebagai dasar prediksi di masa depan.


2.2. Periode Musim

Periode musim merupakan interval waktu yang menunjukkan perubahan pola cuaca yang berulang. Di Indonesia, musim dibagi menjadi musim hujan dan musim kemarau berdasarkan curah hujan dasarian, yaitu akumulasi curah hujan selama sepuluh hari. Musim kemarau terjadi jika dalam tiga dasarian berturut-turut curah hujan kurang dari 50 mm per dasarian atau totalnya kurang dari 150 mm, dengan syarat dasarian pertama memiliki curah hujan di bawah 50 mm. Sebaliknya, musim hujan terjadi jika dalam tiga dasarian berturut-turut curah hujan mencapai atau melebihi 50 mm per dasarian atau totalnya lebih dari 150 mm, dengan syarat dasarian pertama memiliki curah hujan minimal 50 mm. Awal musim, baik hujan maupun kemarau, dapat terjadi lebih awal, tepat waktu, atau lebih lambat dibanding kondisi normal berdasarkan Curah Hujan Normal 1991-2020. Selain itu, puncak musim ditentukan berdasarkan curah hujan tertinggi pada tiga dasarian

berturut-turut untuk musim hujan dan curah hujan terendah untuk musim kemarau. Jika terdapat minimal tiga dasarian dengan curah hujan 0 mm, maka puncak musim kemarau ditentukan berdasarkan periode tengah dari tiga dasarian tersebut [13].

2.3. Long Short-Term Memory

Salah satu metode pembelajaran mesin yang dirancang untuk menangani data temporal adalah *recurrent neural network* (RNN), yang merupakan jaringan saraf tiruan dengan mekanisme umpan balik yang memungkinkan model untuk memahami pola pada data berurutan seperti deret waktu. Salah satu arsitektur RNN yang lebih canggih adalah *Long Short-Term Memory* (LSTM), yang dirancang untuk menyimpan dan mempertahankan informasi penting dari data sebelumnya dan menangani masalah gradien yang menghilang dalam RNN [14].



Gambar 1. Perbedaan arsitektur RNN dengan LSTM

Gambar 1 menunjukkan bahwa arsitektur LSTM memiliki struktur yang lebih kompleks yang memungkinkannya untuk menyimpan informasi penting dari waktu ke waktu dan membuang informasi yang tidak relevan. Setiap sel LSTM terdiri dari tiga *gate* atau gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, serta *cell state*, yang bekerja sama untuk mengontrol aliran informasi.

Persamaan matematis 1-6 merepresentasikan mekanisme kerja setiap gerbang dalam arsitektur LSTM [15]. Persamaan ini menggambarkan bagaimana setiap gerbang bekerja dalam mengatur aliran informasi melalui sel LSTM, mulai dari pembaruan memori hingga output yang dihasilkan.

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

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

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

$$C_t = f_t \odot (C_{t-1} + i_t \odot \tilde{C}_t) \quad (4)$$

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


$$h_t = o_t \odot \tanh C_t \quad (6)$$

Dari persamaan yang diberikan, variabel x_t menunjukkan *input* pada langkah waktu tertentu, sedangkan h_{t-1} menandakan keadaan tersembunyi yang berasal dari langkah waktu sebelumnya. Simbol σ dan $\tanh$ masing-masing merujuk pada fungsi aktivasi sigmoid dan fungsi tangen hiperbolik. Selain itu, notasi $\odot$ menunjukkan operasi perkalian elemen-bijaksana. Vektor f_t , i_t dan o_t masing-masing berhubungan dengan vektor gerbang *forget*, *input*, dan *output*. Kandidat keadaan sel dilambangkan dengan $\tilde{C}_t$, keadaan sel diwakili oleh C_t , dan keadaan tersembunyi pada langkah waktu yang diberikan

diwakili oleh ht . Desain *Stacked LSTM* dapat secara efektif menangkap pola kompleks dan jangka panjang dalam urutan *input* dengan menggabungkan banyak unit LSTM. Implementasi arsitektur canggih ini memiliki potensi untuk meningkatkan akurasi dan kinerja model digunakan untuk memprediksi [16].

2.4. Vanilla LSTM


Jaringan LSTM lapisan tunggal biasanya dikenal sebagai *LSTM Vanilla* atau model LSTM dasar. *Vanilla LSTM* terdiri dari satu lapisan LSTM, lapisan tersembunyi yang terhubung penuh, dan lapisan keluaran untuk membuat prediksi [17].



Gambar 2. Arsitektur *Vanilla LSTM*


2.5. Stacked LSTM

Vanilla LSTM yang hanya memiliki satu lapisan LSTM terkadang tidak cukup untuk menangkap pola yang lebih kompleks pada data yang berurutan. Oleh karena itu, pengembangan lebih lanjut dilakukan dengan menambahkan lapisan LSTM tambahan pada model tersebut, yang dikenal dengan nama *Stacked LSTM*. Model ini merupakan pengembangan dari model *LSTM Vanilla* yang memiliki beberapa lapisan LSTM tersembunyi dimana setiap lapisannya berisi beberapa sel memori. Lapisan tersembunyi ini membuat model menjadi lebih dalam dan lebih akurat dalam hal pola pembelajaran [18].



Gambar 3. Arsitektur *Stacked LSTM*

2.6. Bidirectional LSTM



Gambar 4. Arsitektur *bidirectional LSTM*

Di sisi lain, *Bidirectional LSTM* memproses data secara berbeda, yaitu secara dua arah, yaitu maju dan mundur. Proses ini berguna untuk meningkatkan pemahaman dan kemampuan model dalam memahami konteks [19].

2.7. Evaluasi Metrik


Untuk mengevaluasi kesalahan antara nilai prediksi dan nilai aktual pada data uji, metrik evaluasi yang digunakan adalah *Mean Absolute Error* (MAE). Metrik evaluasi digunakan untuk mengukur seberapa dekat nilai prediksi rata-rata dengan nilai aktual dalam kumpulan data. Hal ini dihitung dengan mengambil perbedaan absolut antara setiap prediksi dan nilai aktual dan kemudian menghitung rata-rata dari perbedaan tersebut [20]. Arsitektur terbaik adalah yang memiliki nilai MAE paling rendah [21]. Persamaan 7 merupakan formulasi matematis dari metrik evaluasi MAE.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (7)$$

y_i : nilai observasi
 y'_i : nilai prediksi
 n : jumlah data
 i : urutan data dalam data

3. METODE PENELITIAN

Penelitian ini meliputi beberapa tahapan, seperti yang terdapat pada Gambar 5.



Gambar 5. Alur penelitian

Pertama proses akuisisi data melibatkan pengambilan data curah hujan dari dataonline.bmkg.go.id. untuk periode 2001-2024, khususnya dari Stasiun Meteorologi Maritim Tanjung Perak yang berada di wilayah Surabaya. Pemilihan parameter curah hujan didasarkan pada pengaruhnya yang besar terhadap terjadinya musim hujan dan musim kemarau [11]. Kemudian dilanjutkan dengan tahap praproses sebelum data digunakan untuk pemodelan. Proses ini meliputi penanganan *missing value* [22] berupa imputasi data, agregat data berupa pengelompokan data berdasarkan dasarian, karena curah hujan dasarian menjadi acuan dalam penentuan awal musim hujan dan kemarau [11]. Curah hujan

dasarian dihitung dengan menjumlahkan curah hujan yang terjadi selama satu dasarian atau sepuluh hari [23]. Kemudian, *splitting* data bertujuan untuk membagi dataset menjadi tiga subset agar model dapat dilatih, divalidasi, dan diuji secara optimal. Dataset dipecah dengan perbandingan 80:10:10 karena berdasarkan penelitian lain, pemecahan data dengan ketepatan tersebut menghasilkan output yang cukup baik [24], [25], [26], di mana 80% digunakan untuk melatih model, 10% untuk validasi model pada saat proses *training*, dan 10% untuk pengujian performa akhir model. Karena data ini merupakan deret waktu, maka pembagiannya dilakukan secara temporal sehingga data pelatihan mencakup 80% periode sebelumnya, dan data validasi dan pengujian mencakup sisanya. Selain itu, dilakukan juga normalisasi menggunakan MinMax dengan rentang 0-1 agar hasilnya memiliki rentang yang seimbang [27]. Terakhir, pembentukan *sliding window* dimaksudkan untuk menjaga struktur temporal dari data sehingga model nantinya dapat menangkap pola sekuensial dari data [28].

Setelah melalui tahap praproses, data yang telah siap kemudian digunakan dalam proses pemodelan. Pada tahap ini, arsitektur model dibangun sesuai dengan pendekatan yang digunakan. Kemudian, model-model tersebut dikembangkan dan dilatih dengan menggunakan data *training*, sedangkan data validasi digunakan untuk mengoptimalkan kinerja model. Setelah proses pelatihan selesai, model diuji dengan data uji, dan kinerjanya dievaluasi dengan menggunakan metrik seperti *Mean Absolute Error* (MAE).

4. HASIL DAN PEMBAHASAN

4.1. Akuisisi Data

Data yang diperoleh berjumlah 8.674 entri. Data tersebut kemudian dikonversi ke dalam format dasarian, sehingga jumlahnya berkurang menjadi 855 entri sesuai dengan pembagian tiga periode dalam satu bulan.

4.2. Praproses

Selanjutnya, data dibagi dengan perbandingan 80:10:10, di mana 80% data pertama, sebanyak 681 entri, digunakan sebagai data pelatihan, 10% berikutnya, sebanyak 82 entri, dialokasikan untuk data validasi, dan 10% terakhir, sebanyak 83 entri, digunakan sebagai data uji. Untuk memastikan bahwa setiap fitur memiliki skala yang seragam, proses normalisasi diterapkan pada seluruh dataset. Namun, untuk menghindari kebocoran data, *fitting* hanya dilakukan pada data *training*, sedangkan data validasi dan data uji hanya ditransformasi menggunakan skala yang diperoleh dari data *training* [29]. Selanjutnya, untuk menangkap pola temporal yang dipengaruhi oleh tiga harian sebelumnya, digunakan teknik *sliding window* dengan *lag* tiga. Dengan pendekatan ini,

prediksi untuk setiap hari dekadal didasarkan pada informasi dari tiga periode sebelumnya. Sebagai langkah terakhir dalam prapemrosesan, data dikonversi ke dalam format tiga dimensi (3D) agar kompatibel dengan arsitektur LSTM [30]. Struktur ini terdiri dari sampel, yang merupakan jumlah total pengamatan dalam dataset; langkah waktu, yang merepresentasikan jumlah langkah waktu dalam setiap input; dan fitur, yang menunjukkan jumlah variabel yang digunakan dalam setiap periode tertentu.


4.3. Model Development

Pada tahap pemodelan, tiga arsitektur LSTM yang berbeda diuji dengan menggunakan jumlah parameter yang sama untuk menciptakan kondisi yang konsisten dalam eksperimen dan memberikan dasar yang adil untuk perbandingan antara ketiga model, kecuali LSTM *Vanilla*, yang hanya memiliki satu lapisan tanpa dropout, sedangkan LSTM *Stacked* dan *Bidirectional* memiliki dua lapisan dengan 0,2 dropout untuk mencegah *overfitting*. Tabel 1 menyajikan pengaturan parameter yang digunakan dalam penelitian ini.

Tabel 1. Pengaturan parameter

Parameter	Nilai
learning rate	0.001
optimizer	Adam
criterion	mse
epoch	100
batch size	32

Berdasarkan Gambar 6, grafik *loss* dan *value loss* untuk setiap model menunjukkan perbedaan konvergensi dan stabilitas selama proses pelatihan. Pada Gambar 6(a), model LSTM *Vanilla* memiliki penurunan *training loss* yang cukup stabil, namun pada *validation loss* menunjukkan fluktuasi yang cukup signifikan. Hal ini mengindikasikan bahwa model mengalami kesulitan dalam melakukan generalisasi pada data validasi, yang dapat disebabkan oleh kompleksitas model yang lebih rendah dibandingkan dengan arsitektur lainnya. Gambar 6(b), model *Stacked* LSTM menunjukkan *training loss* yang lebih rendah dibandingkan dengan *Vanilla* LSTM, namun *validation loss* masih berfluktuasi meskipun cenderung lebih stabil. Hal ini menunjukkan bahwa model tersebut dapat menangkap pola dengan lebih baik namun masih mengalami kesulitan dalam generalisasi. Gambar 6(c), model *Bidirectional* LSTM memiliki pola *loss* yang mirip dengan *Stacked* LSTM. *training loss* terus mengalami penurunan, namun *validation loss* mengalami fluktuasi yang lebih tinggi dibandingkan dua model lainnya. Hal ini mengindikasikan bahwa model tersebut terlalu kompleks dan berpotensi mengalami *overfitting*, dimana model melakukan *overfitting* pada data *training* dan kurang mampu melakukan prediksi yang baik pada data validasi.



Gambar 6. Grafik loss dan val loss

4.4. Evaluasi Metrik

Setelah model dilatih, hasil evaluasi kinerja dari ketiga arsitektur LSTM dapat dilihat pada Tabel 2, yang menunjukkan perbandingan kinerja model.

Tabel 2. Hasil perbandingan evaluasi

Arsitektur	MAE
Vanilla	27.7023
Stacked	26.5515
Bidirectional	25.7883

Hasil perbandingan evaluasi menunjukkan variasi performa yang tidak terlalu signifikan antara ketiga arsitektur LSTM yang diujikan. Model LSTM *Bidirectional* menunjukkan performa terbaik dengan nilai MAE terendah yaitu 25.7883, diikuti oleh LSTM *Stacked* dengan MAE 26.5515 dan LSTM *Vanilla* dengan MAE 27.7023. Penurunan nilai MAE seiring dengan bertambahnya kompleksitas arsitektur mengindikasikan bahwa model yang lebih dalam dengan mekanisme pemrosesan dua arah dapat menangkap pola data dengan lebih baik dibandingkan dengan *Vanilla* LSTM. *Stacked* LSTM, yang terdiri dari beberapa lapisan LSTM, dapat meningkatkan akurasi daripada *Vanilla* LSTM dengan menangkap pola temporal yang lebih kompleks. Sementara itu, *Bidirectional* LSTM, yang memproses informasi

dalam dua arah (maju dan mundur), memberikan hasil yang paling optimal dengan kesalahan prediksi yang paling rendah.

Selain itu, dilakukan pula pengujian dengan pembagian data yang berbeda, yaitu 70:15:15 dan 60:20:20. Namun, hasil menunjukkan bahwa nilai MAE pada kedua skenario ini lebih tinggi dibandingkan dengan 80:10:10. Pada skenario 70:15:15, diperoleh nilai MAE masing-masing sebesar 29.3932 untuk *Vanilla* LSTM, 28.6503 untuk *Stacked* LSTM, dan 27.3332 untuk *Bidirectional* LSTM. Sementara pada skenario 60:20:20, nilai MAE yang diperoleh lebih tinggi lagi, yaitu 31.2605 untuk *Vanilla* LSTM, 30.9247 untuk *Stacked* LSTM, dan 31.4686 untuk *Bidirectional* LSTM. Hasil ini menunjukkan bahwa proporsi data latih yang terlalu kecil dapat mengurangi kemampuan model dalam mengenali pola dengan baik, sehingga meningkatkan tingkat kesalahan prediksi.

5. KESIMPULAN DAN SARAN

Kesimpulannya, penelitian ini berhasil menunjukkan keefektifan berbagai arsitektur LSTM dalam memprediksi curah hujan musiman di Surabaya. Di antara model-model yang diuji, *Bidirectional* LSTM terbukti menjadi yang terbaik dengan nilai 25.7883, karena mengungguli model *Vanilla* LSTM dan *Stacked* LSTM dengan masing-masing nilai 27.7023 dan 26.5515 dalam hal MAE. Temuan ini mengkonfirmasi hipotesis bahwa pemrosesan dua arah meningkatkan kemampuan model untuk menangkap pola temporal yang kompleks. Untuk meningkatkan akurasi prediksi, penelitian selanjutnya dapat menggunakan dataset dengan rentang waktu yang lebih panjang supaya model dapat belajar lebih baik dari pola musiman yang lebih beragam. Dan untuk memberikan gambaran yang lebih komprehensif mengenai performa model, disarankan untuk menggunakan lebih banyak metrik evaluasi.

DAFTAR PUSTAKA

- [1] Rini. Lukum, Radia. Hafid, and Mahmud. Mahmud, "Pengaruh Perubahan Musim Terhadap Pendapatan Nelayan," *Journal of Economic and Business Education*, vol. 1, no. 1, pp. 115–123, Jan. 2023, doi: <https://doi.org/10.37479/jebe.v1i1.18687>.
- [2] D. Auliya, A. H. Rosandi, and W. T. Subroto, "Analisis Perubahan Iklim terhadap Produktivitas Padi di Jawa Timur," *Diponegoro Journal of Economics*, vol. 13, no. 3, pp. 55–65, Oct. 2024, doi: <https://doi.org/10.14710/djoe.47595>.
- [3] R. Farikhul Firdaus and I. V. Papatungan, "Prediksi Curah Hujan di Kota Bandung Menggunakan Metode Long Short Term Memory," *Jurnal Penelitian Inovatif*, vol. 2, no. 3, pp. 453–460, Nov. 2022, doi: <https://doi.org/10.54082/jupin.99>.

- [4] J. Badriyah, A. Fariza, and T. Harsono, "Prediksi Curah Hujan Menggunakan Long Short Term Memory," *Jurnal Media Informatika Budidarma*, vol. 6, no. 3, pp. 1297–1303, Jul. 2022, doi: <https://doi.org/10.30865/mib.v6i3.4008>.
- [5] T. A. F. Muhammad and M. I. Irawan, "Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang)," *Jurnal Sains Dan Seni ITS*, vol. 12, no. 1, pp. 2337–3520, May 2023, doi: <https://doi.org/10.12962/j23373520.v12i1.106892>.
- [6] C. B. Vennerød, A. Kjærran, and E. S. Bugge, "Long Short-term Memory RNN," May 2021. doi: <https://doi.org/10.48550/arXiv.2105.06756>.
- [7] R. Solgi, H. A. Loáiciga, and M. Kram, "Long short-term memory neural network (LSTM-NN) for aquifer level time series forecasting using in-situ piezometric observations," *J Hydrol (Amst)*, vol. 601, Oct. 2021, doi: <https://doi.org/10.1016/j.jhydrol.2021.126800>.
- [8] M. Mroua and A. Lamine, "Financial time series prediction under Covid-19 pandemic crisis with Long Short-Term Memory (LSTM) network," *Humanit Soc Sci Commun*, vol. 10, no. 1, Dec. 2023, doi: <https://doi.org/10.1057/s41599-023-02042-w>.
- [9] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, and M. Weyrich, "A survey on long short-term memory networks for time series prediction," in *Procedia CIRP*, Elsevier B.V., 2021, pp. 650–655. doi: <https://doi.org/10.1016/j.procir.2021.03.088>.
- [10] E. Wati, Y. Arman, and R. Adriat, "Prediksi Awal Musim Hujan Dan Awal Musim Kemarau Di Ketapang Bagian Selatan Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA)," *Prisma Fisika*, vol. 10, no. 3, pp. 323–331, 2022, doi: <https://doi.org/10.26418/pf.v10i3.58142>.
- [11] Ni Made Meriliana Candra Devi, I Putu Agung Bayupati, and Ni Kadek Ayu Wirdiani, "Prediksi Curah Hujan Dasarian dengan Metode Vanilla RNN dan LSTM untuk Menentukan Awal Musim Hujan dan Kemarau," *Jurnal Edukasi dan Penelitian Informatika*, vol. 8, no. 3, pp. 405–411, Dec. 2022, doi: <https://doi.org/10.26418/jp.v8i3.56606>.
- [12] T. K. Sabila, L. Lelah, and D. Indrayana, "Sistem Prediksi Penjualan di Toko Dasni Menggunakan Metode Double Exponential Smoothing," *Jurnal Ilmiah Komputer Grafis*, vol. 15, no. 2, pp. 305–312, Dec. 2022, doi: <https://doi.org/10.51903/pixel.v15i2.813>.
- [13] "Prakiraan Musim Kemarau Tahun 2024 di Provinsi Jawa Timur," Malang, Mar. 2024. Accessed: Oct. 17, 2024. [Online]. Available: <https://staklim-jatim.bmkg.go.id/index.php/informasi-iklim/buletin-1/buletin-prakiraan-musim-kemarau>
- [14] C. B. Vennerød, A. Kjærran, and E. S. Bugge, "Long Short-term Memory RNN," May 2021. [Online]. Available: <http://arxiv.org/abs/2105.06756>
- [15] A. Khumaidi, R. Raafi, I. Permana Solihin, and J. Rs Fatmawati, "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung," *Jurnal Telematika*, vol. 15, no. 1, pp. 13–18, Dec. 2020, doi: <https://doi.org/10.61769/telematika.v15i1.340>.
- [16] M. Diqi, S. Hasta Mulyani, U. Respati Yogyakarta, J. K. Laksda Adisucipto, and D. Sleman, "Enhancing Weather Prediction Using Stacked Long Short-Term Memory Networks," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 3, pp. 519–530, Sep. 2023, doi: <https://doi.org/10.35957/jatisi.v10i3.5376>.
- [17] P. Bamane and M. Patil, "A comparative study of different LSTM neural networks in predicting air pollutant concentrations," *Indian J Sci Technol*, vol. 13, no. 35, pp. 3664–3674, Sep. 2020, doi: <https://doi.org/10.17485/IJST/v13i35.1276>.
- [18] M. Ma, C. Liu, R. Wei, B. Liang, and J. Dai, "Predicting machine's performance record using the stacked long short-term memory (LSTM) neural networks," *J Appl Clin Med Phys*, vol. 23, no. 3, Mar. 2022, doi: <https://doi.org/10.1002/acm2.13558>.
- [19] J. Amalia, J. Pakpahan, M. Pakpahan, and Y. Panjaitan, "Model Klasifikasi Berita Palsu Menggunakan Bidirectional LSTM Dan Word2Vec Sebagai Vektorisasi," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 4, pp. 3319–3331, Dec. 2022, doi: <https://doi.org/10.35957/jatisi.v9i4.1332>.
- [20] M. F. Almaliki, I. Isnawaty, M. Satyadharma, and H. Hado, "Perbandingan Metode Exponential Smoothing dan Moving Average pada Arus Barang Bongkar," *Jurnal Manajemen Informatika (JAMIKA)*, vol. 14, no. 2, pp. 125–134, Jun. 2024, doi: <https://doi.org/10.34010/jamika.v14i2.12828>.
- [21] A. T. Damaliana, A. Muhaimin, and D. A. Prasetya, "Forecasting The Occupancy Rate of Star Hotels in Bali Using The XGBOOST and SVR Methods," *Journal Of Statistics*, vol. 12, no. 1, pp. 24–33, 2024, doi: <https://doi.org/10.26714/jsunimus.12.1.2024.24-33>.
- [22] M. Riko Anshori Prasetya, A. Mudi Priyatno, and Nurhaeni, "Penanganan Imputasi Missing Values pada Data Time Series dengan Menggunakan Metode Data Mining," *Jurnal Informasi dan Teknologi*, vol. 5, no. 2, pp. 56–62, Jun. 2023, doi: <https://doi.org/10.37034/jidt.v5i1.324>.
- [23] Zakarias Frans Mores Hukom, "Penentuan Awal Musim Hujan Dan Awal Musim Kemarau Lokal Di Perkebunan Teh," *Agrologia*, vol. 10, no. 2,

- pp. 63–68, 2021, doi: <https://doi.org/10.30598/ajibt.v10i2.1425>.
- [24] N. Uly, H. Hendry, and A. Iriani, “CNN-RNN Hybrid Model for Diagnosis of COVID-19 on X-Ray Imagery,” *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, vol. 14, no. 1, pp. 57–67, May 2023, doi: <https://doi.org/10.31849/digitalzone.v14i1.13668>.
- [25] S. Muhartini, A. Sunyoto, D. Anva, and H. Muhammad, “Implementasi Metode Deep Learning CNN Dalam Klasifikasi Tajong (Sarung) Samarinda,” *Jurnal Senopati*, vol. 6, no. 1, pp. 28–41, Oct. 2024, doi: <https://doi.org/10.31284/j.senopati.2024.v6i1.6573>.
- [26] Q. Guo, Z. He, and Z. Wang, “Monthly climate prediction using deep convolutional neural network and long short-term memory,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: <https://doi.org/10.1038/s41598-024-68906-6>.
- [27] P. Palinggik Allorerung, A. Erna, M. Bagussahrir, and S. Alam, “Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit,” *Jurnal Informatika Sunan Kalijaga*, vol. 9, no. 3, pp. 178–191, Sep. 2024, doi: <https://doi.org/10.14421/jiska.2024.9.3.178-191>.
- [28] E. Verianto, “Penerapan LSTM Dengan Regularisasi Untuk Mencegah Overfitting Pada Model Prediksi Tingkat Inflasi di Indonesia,” *Simkom*, vol. 9, no. 2, pp. 195–204, Jul. 2024, doi: <https://doi.org/10.51717/simkom.v9i2.460>.
- [29] Galih Adhi Putratama, Satya Maulana Fahreza, and Yudhistira Rakha Ramandhani, “Evaluasi Komparatif Metode Machine Learning Untuk Memprediksi Perubahan Harga Saham,” *Antivirus : Jurnal Ilmiah Teknik Informatika*, vol. 17, no. 2, pp. 278–285, May 2024, doi: <https://doi.org/10.35457/antivirus.v17i2.2871>.
- [30] X. Wen and W. Li, “Time Series Prediction Based on LSTM-Attention-LSTM Model,” *IEEE Access*, vol. 11, pp. 48322–48331, May 2023, doi: <https://doi.org/10.1109/ACCESS.2023.3276628>.