

PREDIKSI SINGLE-STEP DAN MULTI-STEP DATA CUACA MENGGUNAKAN MODEL LONG SHORT-TERM MEMORY DAN SARIMA

Humasak Tommy Argo Simanjuntak^{*1}, Amelia Lumbanraja², Gabriel Samosir³, Regita⁴

^{1,2,3,4} Institut Teknologi Del, Kabupaten Toba

Email: ¹humasak@gmail.com, ²ameliajal08@gmail.com, ³gafrizsam@gmail.com,

⁴regitapakpahan123@gmail.com

^{*}Penulis Korespondensi

(Naskah masuk: 24 November 2024, diterima untuk diterbitkan: 13 April 2025)

Abstrak

Prediksi deret waktu pada parameter data cuaca adalah proses memprediksi nilai masa depan berdasarkan pola data historis cuaca. Penelitian ini mengatasi kelemahan penelitian sebelumnya seperti data yang terbatas, jangka waktu prediksi, keterbatasan parameter yang digunakan dalam penelitian serta tidak menggunakan parameter eksternal yang tentunya dapat membantu proses prediksi model menjadi lebih akurat. Penelitian ini menggunakan metode Long Short-Term Memory (LSTM) dan Seasonal AutoRegressive Integrated Moving Average (SARIMA) untuk memprediksi parameter cuaca, seperti tekanan udara, suhu, dan kelembaban relatif, dengan pendekatan *single-step* dan *multi-step ahead*. Data bersumber dari BMKG Stasiun Meteorologi Pinangsori, Sibolga, selama 8 tahun, dengan *granularity* per jam dan per hari. Hasil eksperimen menunjukkan bahwa LSTM dan SARIMA, memiliki keunggulan dalam konteks tertentu. Untuk pendekatan *single-step*, model SARIMA lebih baik 49% dari model LSTM untuk prediksi dengan *granularity* data per jam. Namun, untuk *granularity* data per hari, performansi LSTM lebih baik 27% dari model SARIMA. Kemudian untuk pendekatan *multi-step*, SARIMA memberikan performansi yang lebih baik 30% daripada model LSTM untuk data per jam (≤ 24). Sedangkan untuk *granularity* data harian, model LSTM lebih baik 30% pada *step* 30 hari dan lebih baik 27% pada *step* 60 hari. Dan untuk data ekstrem, LSTM lebih baik 47% daripada SARIMA.

Kata kunci: prediksi deret waktu, prediksi cuaca, LSTM, SARIMA.

PRECISION IN FORECASTING: SINGLE-STEP AND MULTI-STEP WEATHER PREDICTIONS WITH LSTM AND SARIMA MODELS

Abstract

Time series prediction of weather data parameters involves forecasting future values based on historical weather patterns. This study addresses the limitations of previous research, such as constrained datasets, short prediction periods, restricted parameters, and the neglect of external factors that could enhance model accuracy. Utilizing Long Short-Term Memory (LSTM) networks and Seasonal AutoRegressive Integrated Moving Average (SARIMA) methods, the research focuses on predicting weather parameters like air pressure, temperature, and relative humidity using both *single-step* and *multi-step* approaches. The data is sourced from the BMKG Pinangsori Meteorological Station in Sibolga, covering an 8-year period with both hourly and daily *granularity*. The experimental findings reveal that LSTM and SARIMA each have their advantages depending on the context. In the *single-step* approach, the SARIMA model outperforms the LSTM model by 49% for predictions based on hourly data. Conversely, for daily data *granularity*, the LSTM model surpasses SARIMA by 27%. In the *multi-step* analysis, SARIMA demonstrates a 30% improvement over LSTM for hourly predictions (up to 24 hours). However, for daily *granularity*, the LSTM model excels, showing a 30% advantage at the 30-day prediction step and a 27% advantage at the 60-day step. Additionally, LSTM significantly outperforms SARIMA by 47% when dealing with extreme data.

Keywords: time series prediction, weather prediction, LSTM, SARIMA

1. PENDAHULUAN (huruf besar, 10pt, tebal)

Kebutuhan masyarakat terhadap informasi mengenai parameter cuaca seperti tekanan, suhu, dan kelembapan semakin hari semakin meningkat

(Suleman & Shridevi, 2022). Informasi mengenai parameter cuaca memainkan peran penting dalam kehidupan manusia terutama untuk keperluan pengambilan keputusan (Torres, et al., 2021). Data


cuaca memiliki dampak yang signifikan dalam berbagai bidang, termasuk pertanian, transportasi, penanggulangan bencana, dan analisis pola iklim (Chandra, et al., 2021).

Parameter data cuaca adalah jenis data deret waktu (*time series*) yang mewakili kumpulan data berurutan yang diperoleh selama interval waktu tertentu, menggambarkan bagaimana data berubah seiring waktu, seperti deret suhu, tekanan, dan kelembaban. Prediksi deret waktu (*time series forecasting*) merupakan komponen krusial dalam analisis data, terutama dalam konteks meteorologi. Memprediksi parameter data cuaca melibatkan analisis data historis untuk membuat prediksi kondisi di masa depan, yang membantu dalam pengambilan keputusan. Kemampuan untuk memprediksi parameter cuaca seperti suhu, tekanan udara, dan kelembapan relatif dengan akurasi tinggi sangat penting bagi berbagai sektor. Pada sektor pertanian, prakiraan iklim yang akurat 3–6 bulan sebelumnya berpotensi memungkinkan petani dan *stakeholder* lain di bidang pertanian membuat keputusan yang dapat mengurangi dampak yang tidak diinginkan atau memanfaatkan iklim sehingga meningkatkan produktivitas dan mata pencarian petani serta potensi keuntungan lebih besar dan ketahanan pangan global (Guido, et al., 2021) (Fathi, et al., 2021) (Pujahari, et al., 2022). Pada sektor lain seperti kesehatan masyarakat (*public health*), prediksi cuaca yang akurat merupakan faktor penting dalam memperkirakan wabah penyakit terkait, seperti malaria, demam berdarah, penyakit pernapasan untuk menyiapkan peringatan dini dan respons perawatan kesehatan (Nguyen, et al., 2022).

Dalam beberapa tahun terakhir, metode prediksi berbasis data deret waktu telah berkembang pesat, dengan fokus pada peningkatan akurasi dan efisiensi. Model statistik tradisional seperti *autoregressive integrated moving average* atau ARIMA (Geetha & Nasira, 2017) (Murat, et al., 2018), *seasonal autoregressive integrated moving average* atau SARIMA (Chen, et al., 2018) (Ray, et al., 2021) (Parasyris, et al., 2022), telah lama digunakan untuk prediksi deret waktu dan terbukti efektif dalam menangani data dengan pola musiman. Namun, dengan meningkatnya kompleksitas dan volume data cuaca, metode berbasis pembelajaran mesin dan *deep learning*, khususnya *recurrent neural networks* (Hewamalage, et al., 2021), *long short-term memory* (Han, et al., 2021) (Chen, et al., 2022) (Teixeira, et al., 2024), telah mendapatkan perhatian lebih karena kemampuannya dalam menangani data non-linier dan menangkap dependensi data jangka panjang. Kemudian, model SFA-LSTM juga diperkenalkan untuk melakukan prakiraan cuaca jangka pendek dengan memodelkan hubungan spasial dan temporal yang kompleks untuk meningkatkan akurasi prediksi yang secara efektif menangkap ketergantungan spasial dalam data meteorologi (Suleman & Shridevi, 2022).

Pada beberapa penelitian sebelumnya, terdapat beberapa kelemahan seperti keterbatasan parameter yang digunakan dalam penelitian, data yang terbatas, dan jangka waktu prediksi yang mencakup hanya 30 hari, serta tidak menggunakan parameter eksternal yang tentunya dapat membantu proses model menjadi lebih baik, dikarenakan pola yang diperoleh akan lebih beragam (Suradhaniwar, et al., 2021). Parameter eksternal yang dimaksud adalah turunan dari parameter tanggal atau representasi periodik dari waktu seperti, penggunaan hari (*day sin*, *day cos*), bulan (*month sin*, *month cos*) dan juga parameter lain yang memiliki hubungan terhadap parameter prediksi. Pendekatan konvensional sering kali menggunakan format waktu dalam bentuk kategori atau numerik, misalnya: hari dalam sebulan (1-31) atau bulan dalam setahun (1-12) tanpa mengubahnya menjadi representasi sirkular. Dengan tidak memasukkan parameter eksternal dalam model, maka terdapat ketergantungan hanya pada nilai data parameter sebelumnya. Hal ini dapat menyebabkan model kesulitan dalam menangkap sifat periodik secara alami, pola musiman tidak tereksploitasi secara optimal, potensi *overfitting* pada model *machine learning*, dan sulit diterapkan pada model yang memerlukan data numerik berkelanjutan. Untuk mengatasi gap tersebut, penggunaan transformasi sinusoidal terhadap waktu dapat meningkatkan kinerja model melalui beberapa cara seperti memperkenalkan representasi sirkular yang konsisten (merepresentasikan waktu sebagai koordinat dalam lingkaran), meningkatkan kemampuan model dalam mendeteksi pola musiman (model dapat lebih mudah mengidentifikasi pola berulang dalam data), mengurangi ketidakseimbangan data numerik dan kategorikal, menghindari *overfitting* (belajar mengenali pola dalam representasi sinusoidal yang lebih generalisasi), peningkatan kinerja model pada Algoritma non-linier (model seperti jaringan saraf tiruan (ANN) dapat lebih mudah menangkap hubungan non-linier dalam data berkat representasi sirkular ini. Oleh karena itu, dengan mengadopsi representasi *day sin*, *day cos*, *month sin*, dan *month cos*, model dapat lebih memahami hubungan temporal yang kompleks, menghasilkan prediksi yang lebih akurat, dan meningkatkan generalisasi ke data baru.

Dalam prediksi deret waktu (*time series forecasting*), terdapat dua pendekatan utama: *single-step ahead* dan *multi-step ahead*. Pendekatan *single-step ahead* memprediksi nilai pada satu langkah waktu berikutnya berdasarkan data historis hingga saat ini (Koutroumbas & Belehaki, 2005). Model dilatih untuk menghasilkan prediksi satu langkah ke depan, dan proses ini diulang untuk setiap langkah waktu berikutnya. Metode ini sering digunakan karena kesederhanaannya dan kemampuannya untuk menghasilkan prediksi yang akurat dalam jangka pendek.



Gambar 1. Metode Penelitian

Sedangkan, pendekatan *multi-step ahead* memprediksi nilai untuk beberapa langkah waktu ke depan secara simultan melalui strategi *recursive*, *direct*, maupun *multiple output* (Cheng, et al., 2006) (Bahrpeyma, 2020) (Zhang, et al., 2022). Pemilihan antara pendekatan *single-step* dan *multi-step* bergantung pada kebutuhan spesifik, kompleksitas data, dan tujuan prediksi.

Berdasarkan penjelasan di atas, penelitian ini melakukan prediksi parameter data cuaca yaitu: tekanan, suhu, dan kelembaban dengan menggunakan pendekatan *single-step* dan *multi-step* pada algoritma LSTM dan SARIMA. Penelitian ini membandingkan performa model LSTM dan SARIMA dalam melakukan prediksi parameter cuaca menggunakan data yang diperoleh dari Badan Meteorologi dan Klimatologi Sibolga. Oleh karena itu, beberapa kontribusi yang dihasilkan melalui penelitian ini adalah:

- i. Penggunaan algoritma LSTM dan SARIMA untuk menemukan model prediksi yang paling efektif untuk variabel suhu, tekanan, dan kelembaban, dalam memahami pola dan tren yang paling krusial untuk meramalkan perubahan iklim dan cuaca.
- ii. Penelitian ini memberikan wawasan dan panduan yang lebih baik tentang efektivitas metode *single-step ahead* dan *multi-step ahead* dalam analisis data *time series*.
- iii. Penelitian ini berpotensi untuk memberikan kontribusi penting tidak hanya dalam bidang ilmu komputer dan analisis data, tetapi juga dalam berbagai bidang lainnya yang terpengaruh oleh perubahan iklim dan cuaca, seperti pertanian dan penerbangan. Dengan memahami dan meramalkan perubahan dalam variabel cuaca, para peneliti dan praktisi dalam bidang ini dapat membuat keputusan yang lebih tepat dan efisien.

Oleh karena itu, penelitian ini diharapkan dapat berkontribusi pada literatur peramalan cuaca, khususnya dalam memahami efektivitas model SARIMA dan LSTM untuk peramalan dengan granularitas per jam maupun per hari serta memberikan panduan bagi praktisi dalam memilih metode yang sesuai berdasarkan kebutuhan spesifik dan karakteristik data yang tersedia.


2. METODE PENELITIAN

Dalam penelitian ini metodologi yang dilakukan terdiri atas 3 bagian besar, yaitu Persiapan Data (*Data Preparation*), Pembangunan Model (*Modelling*), dan Evaluasi (*Model Evaluation*). Selain itu, prediksi dilakukan dengan cara *single-step* dan *multi-step* pada model LSTM dan SARIMA. Detail rancangan penelitian yang dilakukan dapat dilihat pada Gambar 1.

2.1. Dataset

Penelitian ini menggunakan dataset yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), Stasiun Meteorologi Klas III Pinangsori, Sibolga, mulai dari data Januari 2015 sampai dengan November 2021. *Granularity* dataset yang digunakan adalah per jam dan untuk data *granularity* per hari diperoleh melalui nilai rata-rata harian yang diperoleh dari dataset *granularity* per jam. Pemilihan *granularity* ini bergantung pada kebutuhan analisis, pola musiman, serta tujuan prediksi. *Granularity* per jam digunakan untuk menangkap fluktuasi atau variabilitas data cuaca dalam rentang waktu yang lebih detail. Selain itu, *granularity* per jam juga penting untuk aplikasi *real-time* dan pengambilan keputusan cepat, serta mampu memperbaiki akurasi model dalam jangka pendek. Sementara itu, *granularity* per hari digunakan untuk melihat tren global dari data atau analisis perubahan

data cuaca jangka panjang. Selain itu, penggunaan *granularity* per hari juga dapat mengurangi *noise* dalam data, serta mengurangi ukuran dataset sehingga beban komputasi lebih rendah.



Gambar 2. Visualisasi dataset untuk parameter tekanan


Dataset mencakup atribut seperti WMO ID, Tahun (UTC), Bulan (UTC), Tanggal (UTC), Jam (UTC), Arah Angin, Kecepatan Angin, Tekanan, Suhu, dan Kelembaban. Penelitian ini hanya fokus menggunakan tiga parameter data cuaca, yaitu: suhu, tekanan, dan kelembaban. Tekanan diukur dalam hPa (hektopaskal), Suhu diukur dalam Celsius, dan Kelembaban merujuk pada jumlah uap air dalam udara. Gambar 2 menunjukkan visualisasi dataset untuk data tekanan.

2.2. Data Preparation

Data preparation merupakan tahapan yang bertujuan untuk memastikan data siap untuk digunakan dalam analisis. Pada tahapan ini, data parameter cuaca dibersihkan, ditransformasi menjadi bentuk yang lebih mudah dipahami dan siap untuk digunakan ke dalam model. Beberapa tahapan persiapan data yang dilakukan pada penelitian ini adalah pemeriksaan nilai yang hilang (*check missing value*), mengubah format data, penghapusan atribut yang tidak relevan, dan normalisasi data. Format data parameter cuaca menggunakan format *datetime*, yang memungkinkan representasi waktu yang lebih tepat dan analisis yang lebih akurat terkait data berbasis waktu. Sehingga beberapa atribut seperti atribut WMO ID, Tahun (UTC), Bulan (UTC), Tanggal (UTC), dan Jam (UTC), digabungkan dengan membuat atribut baru yang merepresentasikan *datetime*. Pada tahapan ini, normalisasi data menggunakan teknik skala *MinMax* karena terdapat variasi nilai yang beragam, termasuk terdapatnya nilai yang sangat tinggi dan rendah. Normalisasi data dilakukan dengan menggunakan Persamaan (1), sehingga nilai parameter cuaca berada pada rentang 0 hingga 1. Normalisasi data dengan *MinMax* scaling ini juga dilakukan untuk menangani outlier dan data tidak lengkap.

$$X_t = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Gambar 3 berikut ini menunjukkan visualisasi parameter data tekanan (Gambar 2) setelah dilakukan normalisasi data.



Gambar 3. Visualisasi dataset untuk parameter tekanan setelah normalisasi data

2.3. Modelling (Pembangunan Model)


Pada tahap pembangunan model, langkah awal yang dilakukan adalah dengan membagi data. Data dibagi menjadi dua bagian yaitu: pelatihan (*training*) dan pengujian (*testing*) dengan proporsi yang berbeda, yaitu 60:40, 70:30, 80:20, dan 90:10. Tiga fitur yang digunakan terdiri atas suhu, tekanan, dan kelembaban. Model LSTM dan SARIMA baik dengan pendekatan *single-step* dan *multi-step* yang akan dibahas pada subbab berikut.

2.3.1. Long Short Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah arsitektur jaringan saraf yang termasuk dalam keluarga *Recurrent Neural Networks* (RNN). LSTM dirancang khusus untuk menangani masalah *long-term dependencies* dalam data sekuensial, seperti teks, audio, atau *time series*, yang sering gagal diatasi oleh RNN tradisional akibat masalah *vanishing gradient* (Hochreiter & Schmidhuber, 1997). Arsitektur LSTM memiliki beberapa karakteristik utama, yaitu: *Gates* (Pintu Kontrol), *Cell State* (C_t), dan *Hidden State* (h_t). *Gates* terdiri atas 3, yaitu: *Forget Gate* (mengontrol informasi yang dilupakan), *Input Gate* (memutuskan informasi baru yang akan disimpan), dan *Output Gate* (memutuskan bagian dari memori yang digunakan sebagai luaran). *Forget Gate* memungkinkan model untuk secara selektif melupakan informasi yang tidak relevan, termasuk *outlier* atau nilai ekstrem. Sementara *Cell State* merupakan jalur memori utama yang memungkinkan informasi mengalir tanpa banyak modifikasi dari waktu ke waktu, serta menyimpan pola waktu yang lebih stabil. Ketika terjadi lonjakan nilai ekstrem, *cell state* memungkinkan model untuk tetap mempertahankan tren jangka panjang dan mengabaikan perubahan mendadak yang tidak berkelanjutan. Kemudian, *Hidden State* adalah luaran sementara pada setiap langkah waktu yang digunakan untuk keputusan prediktif atau diteruskan ke *layer* berikutnya.

Ketika nilai ekstrem terjadi, gradien dalam model bisa menjadi tidak stabil, sehingga menyebabkan masalah *exploding gradient*. Namun, LSTM mampu menangani masalah *exploding gradients* dengan teknik yang disebut *gradient clipping*, dengan membatasi nilai maksimum gradien.

Gambar 4 berikut ini menunjukkan arsitektur LSTM model yang diterapkan pada data suhu.



Gambar 4. Arsitektur Model LSTM pada data suhu

Hyperparameter model LSTM meliputi *lag*, *n Ahead*, *epochs*, *ukuran batch*, *learning rate*, *n_layer*, dan *optimizer*. Berdasarkan kajian pada beberapa referensi dan peneliti menggunakan metode *random search* dalam memilih kombinasi hyperparameter secara acak dan mencari konfigurasi terbaik, maka pada penelitian ini model LSTM menggunakan algoritma *optimizer* Adam untuk memperbarui bobot atau parameter model pada setiap iterasi selama proses pelatihan. Model LSTM dilatih dengan menggunakan *learning rate* 0,001; nilai *n_head* = {1, 6, 12} untuk data per jam, dan *n_head* = {30, 60} untuk data per hari. Sementara itu, ukuran *batch* (*batch size*) yang digunakan adalah 512.

2.3.2. Seasonal Auto-Regressive Integrated Moving Average (SARIMA)

SARIMA adalah perpanjangan dari model ARIMA (*Auto-Regressive Integrated Moving Average*) yang dirancang untuk menangani data *time series* musiman. Model ini mengintegrasikan komponen musiman ke dalam struktur ARIMA, sehingga cocok untuk data yang memiliki pola berulang pada interval waktu tertentu (Ray, et al., 2021) (Chen, et al., 2018). Parameter SARIMA terbagi atas 2 yaitu komponen ARIMA (p, d, q), yang merupakan *order* dari komponen *auto-regressive* (p), *order differencing* (d), dan *order moving average* (q); dan komponen musiman (P, D, Q, s) yang merupakan *order* dari komponen musiman *auto-regressive* (P), *order differencing* musiman untuk menjadikan data musiman *stasioner* (D), *order* komponen musiman *moving average* (Q), dan musim atau panjang periode musiman (s). Pada penelitian ini, metode Grid Search (*Auto-ARIMA*) digunakan untuk mencoba berbagai kombinasi (p, d, q) dan (P, D, Q, s), lalu memilih kombinasi terbaik dengan menggunakan Bayesian Information Criterion (BIC) yang paling rendah.

Mempertimbangkan parameter yang dimiliki oleh model LSTM dan SARIMA, maka Tabel 1

berikut ini menampilkan rancangan parameter yang digunakan untuk melakukan prediksi suhu, tekanan, dan kelembaban dengan cara *single-step* dan *multi-step*. Setiap parameter tersebut digunakan pada langkah 6 yang terdapat pada Gambar 1, baik untuk LSTM maupun SARIMA model.

2.4. Evaluasi

Penelitian ini menggunakan dua metrik evaluasi, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE), untuk mengevaluasi kinerja LSTM dan SARIMA. RMSE dihitung dengan mengambil akar kuadrat dari rata-rata selisih kuadrat antara nilai yang diharapkan dan nilai yang diperoleh dari model. MAE adalah rata-rata kerugian kesalahan absolut dalam satu set prediksi. Persamaan (2) dan Persamaan (3) menunjukkan kedua metrik kinerja yang digunakan.

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

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

dimana y_i dan $\hat{y}_i$ adalah data yang diamati (data aktual) dan data hasil prediksi. n adalah panjang data yang diamati.

3. HASIL DAN PEMBAHASAN

Pada bab ini, hasil prediksi tekanan, suhu, dan kelembaban menggunakan metode LSTM dan SARIMA dalam pendekatan *single-step* dan *multi-step* untuk granularitas harian dan per jam.

Pada pendekatan *single-step* untuk setiap parameter dengan granularitas per jam, algoritma SARIMA berhasil memprediksi masing-masing parameter dengan tingkat indeks kesalahan yang lebih rendah. Performansi RMSE SARIMA dalam *granularity* per jam baik 49% lebih baik dari LSTM.

Arsitektur LSTM memberikan prediksi yang cukup akurat, meskipun dengan tingkat kesalahan sedikit lebih tinggi dibandingkan dengan SARIMA. Namun, ini berbeda dalam pendekatan satu langkah (*single step*) untuk setiap parameter dengan granularitas per hari, dimana algoritma LSTM lebih unggul dibandingkan SARIMA dengan tingkat indeks kesalahan yang lebih rendah. Performansi RMSE LSTM 27% lebih baik dari SARIMA.

Pada pendekatan *multi-step* dengan interval 6 jam dan 12 jam, SARIMA juga menunjukkan performa model yang lebih baik, ditandai dengan nilai indeks kesalahan yang lebih rendah dibandingkan dengan LSTM, dengan performansi RMSE SARIMA dalam *granularity* per jam adalah 28% lebih baik dari LSTM, dikarenakan SARIMA mampu mendeteksi pola musiman dengan baik menggunakan variabel S (Seasonal) yang memiliki peran penting dalam mendeteksi pola musiman.

Tabel 1. Hyperparameter LSTM dan SARIMA untuk prediksi parameter cuaca

HYPERPARAMETERS DETAILS									
Hyper parameter LSTM	Hourly		Daily		Hyper parameter SARIMA	Hourly		Daily	
	Single step	Multi step	Single step	Multi step		Single step	Multi step	Single step	Multi step
lag	30	30	200	200	lag	30	30	200	200
n Ahead	1	6,12	1	30,60	n Ahead	1	6,12	1	30,60
Epochs	100	100	200	200	p,d,q	1 0 1; 1 1 1;	1 0 1; 1 1 1;	1 0 1; 1 1 1;	1 0 1; 1 1
Batch Size	512	512	512	512	P,D,Q,S	2 0 1	2 0 1	2 0 1	1, 2 0 1
						1 0 1 24; 1	1 0 1 24; 1	1 0 1 24; 1	1 0 1 24; 1
						1 1 12; 2 0	1 1 12; 2 0	1 1 1 12; 2	1 1 12; 2 0
Learning rate	0.001	0.001	0.001	0.001	-	1 15	1 15	0 1	1

Namun, berbeda pada *multi-step* granularitas per hari, di mana LSTM mengungguli SARIMA dalam memprediksi nilai-nilai untuk 30 hari dan 60 hari ke depan dengan performansi RMSE LSTM 22,5% lebih baik dari SARIMA. Hal ini dikarenakan algoritma LSTM memiliki kemampuan untuk mengingat dan mempelajari pola jangka panjang dalam data waktu tertentu.

3.1. Hasil Training

Pada subbab ini, visualisasi grafik pelatihan model *Long Short-Term Memory* (LSTM) pada data BMKG Sibolga disajikan, yang bertujuan untuk memberikan pemahaman bagaimana model LSTM belajar selama proses pelatihan dan memperlihatkan peningkatan kenaikan atau penurunan performa pada setiap epoch. Visualisasi ini memberikan pemahaman visual yang jelas tentang bagaimana model LSTM mengalami pembelajaran untuk setiap epoch dan dapat menjadi landasan untuk menganalisis dan mengevaluasi kinerja model secara lebih rinci dalam penelitian ini.

Pada Gambar 5, jumlah epoch yang digunakan untuk *granularity* per jam adalah 100, dan untuk *granularity* per hari sebanyak 200. Namun faktanya pada saat melakukan *training*, hasil menunjukkan bahwa *training* tidak sampai pada nilai epoch yang diinisialisasi. Hal ini dikarenakan proses *training* menggunakan fungsi *early stopping* yang bertujuan untuk mencegah *overfitting* dan meningkatkan kemampuan generalisasi model, sehingga proses *training* akan berhenti otomatis jika model sudah berada pada titik terbaik.

Gambar 5 menunjukkan nilai hasil pelatihan dan validasi RMSE dan MAE semakin menurun seiring dengan peningkatan jumlah epoch. Khususnya hasil pelatihan pada data tekanan, suhu, dan kelembaban untuk *granularity* jam (a, c, e), model semakin konvergen mendekati 0, yang berarti bahwa model secara bertahap mempelajari pola yang ada dalam data latih dan mampu memberikan prediksi pada data validasi. Pada data tekanan dan kelembaban, model cukup stabil, tetapi ada indikasi *overfitting* karena garis validasi tidak sejajar dengan garis pelatihan setelah titik tertentu. Khusus untuk data suhu, pelatihan menunjukkan konvergensi model lebih

cepat, tetapi *error* akhir lebih tinggi. Pelatihan model LSTM pada data suhu kurang optimal karena tidak memiliki cukup epoch untuk belajar dengan baik, sehingga menunjukkan hasil *underfitting*, dan perlu lebih banyak epoch agar model lebih akurat.

Kemudian, hasil pelatihan pada data tekanan, suhu, dan kelembaban untuk *granularity* hari (b, d, f), menunjukkan pola penurunan *error* serupa dengan grafik per jam tetapi lebih bertahap. Hal ini menunjukkan pelatihan model terhadap data dengan *granularity* per hari lebih optimal. Hasil pelatihan dan validasi lebih sejajar, menunjukkan model lebih baik dalam generalisasi (konvergensi lebih stabil) dan tidak ada indikasi *overfitting* yang signifikan, menjadikannya lebih baik dibandingkan hasil pelatihan untuk *granularity* per jam.

3.2. Hasil Testing untuk Pendekatan Single-Step


Setelah melakukan pelatihan, model LSTM yang terbaik dilatih untuk melakukan prediksi. Gambar 6 menampilkan hasil prediksi *single-step* untuk parameter tekanan, suhu dan kelembaban dengan granularitas per jam dan per hari pada model LSTM dan SARIMA.

Pada prediksi dengan granularitas per jam, model SARIMA menunjukkan performansi yang lebih baik dalam memprediksi semua parameter, baik suhu, tekanan dan kelembaban. Pada parameter suhu, nilai RMSE model SARIMA sebesar 0,0937 dibanding LSTM dengan nilai RMSE sebesar 0,2099. Kemudian untuk parameter tekanan, performansi SARIMA memperoleh RMSE sebesar 0,1030, sedangkan LSTM menghasilkan RMSE sebesar 0,2044. Dan untuk parameter kelembaban, SARIMA menghasilkan RMSE sebesar 0,1190, dan LSTM dengan RMSE sebesar 0,2095. Secara keseluruhan, performansi model SARIMA lebih baik 49% dari model LSTM untuk *single-step* dan granularitas data per jam. SARIMA dengan nilai parameter $p=1$, $d=0$, $q=1$, dan $s=24$ memberikan hasil yang paling optimal dibandingkan dengan parameter lain.

Hal ini terjadi dikarenakan pada data suhu, tekanan dan kelembaban per jam, terdapat pola harian yang berulang setiap 24 jam. Dengan menggunakan *hyperparameter* $s=24$, model SARIMA dapat mengidentifikasi dan memodelkan pola harian ini

dengan baik, sehingga memberikan hasil prediksi yang lebih akurat dan menghasilkan RMSE terkecil


dibandingkan dengan variasi parameter SARIMA lainnya dan algoritma LSTM.



Gambar 5. Hasil *training* data untuk Tekanan, Suhu, dan Kelembaban untuk *granularity* Jam (kiri) dan Harian (kanan). Gambar 5a dan Gambar 5b menampilkan Tekanan, Gambar 5c dan 5d menampilkan Suhu, dan Gambar 5e dan Gambar 5f menampilkan kelembaban.

Sementara untuk data dengan granularitas per hari, LSTM menunjukkan performansi yang lebih baik 27% dibandingkan dengan model SARIMA untuk semua parameter cuaca. Dataset per hari yang digunakan merupakan nilai rata-rata dari pengukuran suhu per jam selama 24 jam. Pada data suhu, LSTM memperoleh nilai RMSE sebesar 0,0455, sedangkan SARIMA sebesar 0,1477. Kemudian, untuk data tekanan, nilai RMSE LSTM adalah 0,0368, sedangkan RMSE SARIMA adalah 0,1680. Dan pada parameter kelembaban, RMSE LSTM adalah 0,0437, sedangkan SARIMA adalah 0,1473. Hal ini

dikarenakan model LSTM memiliki kemampuan menangkap pola jangka panjang yang memungkinkan LSTM untuk mengenali dan mempelajari hubungan yang kompleks antara data yang tersebar dalam jangka waktu yang lebih luas. Suhu, tekanan, dan kelembaban memiliki pola jangka panjang yang kompleks yang dapat lebih baik dipelajari oleh model LSTM daripada model SARIMA yang lebih terfokus pada komponen musiman dan fluktuasi jangka pendek.



Gambar 6. Hasil Prediksi Suhu (a), Tekanan (b), dan Kelembaban (c) model LSTM dan SARIMA pada periode Jam dan Hari untuk *Single-Step*


3.2. Hasil Testing untuk Pendekatan *Multi-Step*


Untuk mendapatkan hasil prediksi yang lebih akurat, model LSTM dan SARIMA juga diuji dengan cara prediksi *multi-step*, dimana prediksi dilakukan untuk beberapa langkah kedepan. Artinya model memperkirakan nilai parameter cuaca pada beberapa waktu ke depan, misalnya pada waktu $t+1$, $t+2$, $t+3$, dan seterusnya berdasarkan nilai cuaca pada waktu sebelumnya. Gambar 7 berikut menunjukkan hasil pengujian untuk prediksi parameter cuaca dengan pendekatan *multi-step*. Sama dengan pengujian untuk *single-step*, model terbaik dari SARIMA adalah model dengan parameter $p=1$, $d=0$, $q=1$, dan $s=24$.

Pengujian menunjukkan bahwa model SARIMA memberikan performansi yang lebih baik daripada model LSTM untuk data per jam (≤ 24 jam) pada semua parameter cuaca, dengan peningkatan sebesar 30% untuk step 6 jam dan peningkatan sebesar 26% untuk step 12 jam. Hal ini berbanding terbalik untuk *step* data harian, dimana


model LSTM lebih baik dibandingkan SARIMA. Pada *step* 30 hari, performansi model LSTM lebih baik 18% dan demikian juga pada *step* 60 hari, performansi LSTM lebih baik sebesar 27% jika dibandingkan dengan model SARIMA. Hal ini menunjukkan bahwa model LSTM merupakan model yang mampu mempelajari hubungan yang kompleks dan pola jangka panjang dalam data. LSTM memiliki kemampuan untuk menangkap dependensi jarak jauh antar data. Sedangkan, model SARIMA adalah model statistik yang biasanya digunakan untuk memprediksi deret waktu yang memiliki komponen musiman. Model SARIMA mempertimbangkan pola musiman dan fluktuasi jangka pendek dalam data.

Secara detail, perbandingan hasil pengujian antara model LSTM dan SARIMA ditunjukkan lebih jelas pada Gambar 8 berikut ini.





Gambar 7. Hasil Prediksi Suhu (a dan b), Tekanan (c dan d), dan Kelembaban (e dan f) model LSTM dan SARIMA pada periode Jam dan Hari untuk *Multi-Step*




Gambar 8. Perbandingan hasil prediksi LSTM dan SARIMA untuk data suhu (a), tekanan (b), dan kelembaban (c) untuk *granularity* jam dan hari

Pada Gambar 8 ditunjukkan bahwa garis biru untuk nilai evaluasi RMSE pada LSTM dan garis merah terputus nilai evaluasi MAE pada LSTM, garis merah untuk nilai evaluasi RMSE pada SARIMA, dan untuk garis merah terputus untuk nilai evaluasi MAE pada SARIMA. Secara keseluruhan, disimpulkan bahwa pada granularitas per jam nilai RMSE dan MAE pada model SARIMA lebih rendah yang ditunjukkan oleh garis berwarna merah dibandingkan dengan model LSTM yang memiliki nilai RMSE dan MAE lebih tinggi yang ditunjukkan oleh garis berwarna biru. Performansi RMSE SARIMA sebesar 0,0919 untuk 6 jam kedepan, dibanding RMSE LSTM sebesar 0,3519. Demikian juga untuk data yang lain, dapat dilihat pada Gambar 8.


3.3. Prediksi Parameter Cuaca untuk data ekstrem

Data ekstrem mengacu pada nilai-nilai data yang secara signifikan berbeda dari sebagian besar data dalam sebuah deret waktu. Data ini biasanya terletak jauh dari rentang normal atau pola yang biasa ditemukan dalam dataset, dan dapat mempengaruhi hasil analisis atau prediksi jika tidak ditangani dengan baik. Ketika prediksi dilakukan pada data ekstrem dengan ukuran data *test* yang sama dan rentang waktu yang serupa, model LSTM dan SARIMA memberikan hasil yang berbeda. Hal ini disebabkan oleh ketergantungan SARIMA pada data musiman yang menunjukkan pola yang jelas pada interval yang teratur. Selain itu, SARIMA membutuhkan data yang lebih *stasioner* untuk mencapai hasil yang optimal.

Sebaliknya, LSTM mampu menangani nilai-nilai ekstrem dengan efektif, seperti yang ditunjukkan *hyperparameter* seperti nilai epoch dan jumlah *layer* neuron. Parameter-parameter ini secara tidak langsung berkontribusi pada kemampuan model LSTM untuk memprediksi pola-pola ekstrem dengan lebih baik.



Gambar 6 Hasil Prediksi LSTM dan SARIMA untuk Tekanan pada kasus data ekstrem



Gambar 7 Hasil Prediksi LSTM dan SARIMA untuk Kelembaban pada kasus data ekstrem

Perbandingan antara LSTM dan SARIMA dalam menangani nilai-nilai ekstrem, ditunjukkan pada Gambar 6 dan Gambar 7. Pada kasus data ekstrem, model LSTM menghasilkan prediksi yang lebih baik pada parameter tekanan dan kelembaban. Pada parameter tekanan, nilai prediksi LSTM 64,17% lebih baik dari SARIMA. Kemudian, pada parameter kelembaban nilai prediksi LSTM 30,65% lebih baik dari SARIMA.

Pada hasil eksperimen menggunakan data per hari, LSTM mampu mengungguli SARIMA dalam pemodelan. Data per hari diturunkan dari data rata-rata per hari untuk *granularity* per jam. Hal ini juga membuat dataset memiliki nilai ekstrem dan *outlier* yang banyak, sehingga pola sulit ditemukan karena variasi dari nilai rata-rata yang di hasilkan perharinya. Ini yang menjadi salah satu keunggulan dari *hyperparameter* LSTM dibanding dengan SARIMA. *Hyperparameter* LSTM yang berdampak pada nilai ekstrem adalah jumlah Epoch dan lapisan neuron, yang membuat LSTM berulang kali mencoba memahami pola data yang ada. Lapisan Neuron pada LSTM adalah representatif terhadap seberapa kompleks model mempelajari pola dalam data. Dan Epoch menunjukkan seberapa sering model dilatih. Sedangkan *hyperparameter* SARIMA, dimana nilai p pada SARIMA bergantung pada seberapa banyak ketergantungan pola pada data masa lalu, dan variable d mengacu pada *order differencing* yang

menunjukkan jumlah kali *differencing*, untuk membuat data menjadi *stasioner*, dan variabel q menunjukkan seberapa banyak residu dari hasil prediksi dan aktual yang digunakan dalam pembelajaran.

4. KESIMPULAN

Penelitian ini melakukan analisis perbandingan antara prediksi dengan pendekatan *single-step* dan *multi-step* menggunakan model *deep learning* LSTM dan SARIMA. Hasil analisis menunjukkan bahwa dalam menangani nilai-nilai ekstrem dan pencilan, LSTM memiliki keunggulan yang signifikan dibandingkan dengan SARIMA, terutama dipengaruhi oleh jumlah epoch dan lapisan neuron dalam LSTM.

Jumlah epoch yang optimal tergantung pada granularitas data, karena menentukan seberapa baik model belajar pola dalam dataset. Lebih banyak epoch diperlukan karena data per jam memiliki lebih banyak variasi dan fluktuasi jangka pendek. Jika jumlah epoch terlalu rendah, model mungkin gagal mengenali pola jangka panjang dalam data. Namun, terlalu banyak epoch dapat menyebabkan *overfitting*, di mana model belajar terlalu detail pada data pelatihan dan tidak dapat digeneralisasi dengan baik ke data baru.

Kemudian, Neuron dalam *hidden layer* menentukan kapasitas model dalam mempelajari fitur kompleks dari data. Pemilihan jumlah neuron yang optimal bergantung pada granularitas data karena mempengaruhi kompleksitas pola yang harus dipelajari oleh LSTM.

Namun, dalam konteks granularitas per jam, SARIMA dengan parameter pdq dan $pdqs$ 1,0,1,1,0,1,24 mampu memberikan prediksi yang lebih baik, seperti yang terlihat dari nilai RMSE dan MAE terendah. Di sisi lain, untuk prediksi pada granularitas per hari, LSTM menunjukkan hasil yang lebih baik.

Berdasarkan eksperimen, SARIMA menunjukkan konsistensi yang lebih baik dalam skor RMSE dan MAE, baik pada basis per jam maupun per hari. Namun, SARIMA memiliki keterbatasan dalam menangani data yang mengandung banyak pencilan (*outliers*) dan pola non-linier, yang disebabkan oleh ketergantungannya yang kuat pada faktor musiman. Sebaliknya, LSTM memiliki kemampuan untuk memahami pola non-linier dan menghasilkan prediksi yang lebih baik dalam kondisi tersebut.

Secara umum, penelitian ini masih memiliki keterbatasan dikarenakan model yang digunakan sangat tergantung pada data historis dan kualitas data. Semakin banyak data historis, maka semakin baik model melakukan prediksi. Kedua model hanya memprediksi berdasarkan pola historis dan tidak dapat menangani perubahan mendadak akibat faktor eksternal yang tidak tersedia dalam data. Misalnya, prediksi suhu menggunakan LSTM atau SARIMA tidak akan memperhitungkan bencana alam

mendadak atau perubahan kebijakan lingkungan. Kemudian, model *time series* sangat bergantung pada kualitas data yang digunakan. Data yang hilang (*missing values*), *outlier*, atau *noise* dapat menyebabkan hasil prediksi yang tidak akurat. Jika data tidak memiliki pola musiman yang kuat, model SARIMA mungkin tidak bekerja dengan baik.

Oleh karena itu, pemilihan algoritma harus disesuaikan dengan spesifikasi dan kondisi data yang tersedia. Penelitian lebih lanjut dapat dilakukan untuk mengeksplorasi modifikasi dan optimisasi kedua metode ini dalam berbagai situasi dan kondisi data yang berbeda. Peneliti juga merekomendasikan melakukan analisis lebih mendalam tentang pengaruh ukuran dataset terhadap kinerja kedua model. Evaluasi dengan menggunakan dataset yang lebih besar atau lebih kecil dapat memberikan wawasan yang lebih jelas tentang kecenderungan dan batasan kinerja dari masing-masing model.

5. DAFTAR PUSTAKA

- BAHRPEYMA, F., 2020. *Multi-step ahead time series prediction*. s.l.:Dublin City University.
- CHANDRA, R., GOYAL, S. & GUPTA, R., 2021. Evaluation of Deep Learning Models for Multi-Step Ahead Time Series Prediction. *IEEE Access*, 31 May, 9, pp. 83105-83123.
- CHENG, H., TAN, P.-N., GAO, J. & SCRIPPS, J., 2006. Multistep-Ahead Time Series Prediction: *Advances in Knowledge Discovery and Data Mining, Lecture Notes in Computer Science*. Berlin: Springer, pp. 765-774.
- CHEN, G., LIU, S. & JIANG, F., 2022. Daily Weather Forecasting Based on Deep Learning Model: A Case Study of Shenzhen City, China. *Atmosphere*, 01 Agustus, 13, pp. 1208.
- CHEN, P. ET AL., 2018. Time Series Forecasting of Temperatures using SARIMA: An Example from Nanjing. *IOP Conf. Series: Materials Science and Engineering*, 07 Agustus, 394, pp. 052024.
- FATHI, M., KASHANI, M. H., JAMEII, S. M. & MAHDIPOUR, E., 2021. Big Data Analytics in Weather Forecasting: A Systematic Review. *Archives of Computational Methods in Engineering*, 28 June, 29, pp. 1247-1275.
- GEETHA, A. & NASIRA, G., 2017. Time-series modelling and forecasting: modelling of rainfall prediction using ARIMA model. *International Journal of Society Systems Science*, 11 Januari, 8(4), pp. 361-372.
- GUIDO, Z. ET AL., 2021. Perceived links between climate change and weather forecast accuracy: new barriers to tools for agricultural decision-making. *Climatic Change*, 24 September, 168(9), pp. 1-20.
- HAN, Z. ET AL., 2021. A Review of Deep Learning Models for Time Series Prediction. *IEEE Sensors Journal*, 15 March, 21(6), pp. 7833 - 7848.
- HEWAMALAGE, H., BERGMEIR, C. & BANDARA, K., 2021. Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions. *International Journal of Forecasting*, 1 Januari, 37(1), pp. 388-427.
- HOCHREITER, S. & SCHMIDHUBER, J., 1997. Long Short Term Memory. *Neural Computation*, 9(8), pp. 1735-1780.
- KOUTROUMBAS, K. & BELEHAKI, A., 2005. One-step ahead prediction of f oF2 using time series forecasting techniques. *Annales Geophysicae*, 22 November, 23(9), pp. 3035-3042.
- MURAT, M., MALINOWSKA, I., GOS, M. & KRZYSZCZAK, J., 2018. Forecasting daily meteorological time series using ARIMA and regression models. *International agrophysics*, 32(2), pp. 253-264.
- NGUYEN, V.-H. ET AL., 2022. Deep learning models for forecasting dengue fever based on climate data in Vietnam. *Neglected Tropical Diseases*, 13 Juni, 16(6), pp. 1-22.
- PARASYRIS, A. ET AL., 2022. Predicting Meteorological Variables on Local Level with SARIMA, LSTM and Hybrid Techniques. *Atmosphere*, 28 May, 13(6), pp. 878.
- PUJAHARI, R. M., YADAV, S. P. & KHAN, R., 2022. Intelligent farming system through weather forecast support and crop production: *Chapter 6 - Intelligent farming system through weather forecast support and crop production*. s.l.:Academic Press.
- RAY, S., DAS, S. S., MISHRA, P. & AL KHATIB, A. M. G., 2021. Time Series SARIMA Modelling and Forecasting of Monthly Rainfall and Temperature in the South Asian Countries. *Earth Systems and Environment*, 17 March, 5, pp. 531-546.
- SULEMAN, M. A. R. & SHRIDEVI, S., 2022. Short-Term Weather Forecasting Using Spatial Feature Attention Based LSTM Model. *IEEE Access*, August, 10, pp. 82456-82468.
- SURADHANIWAR, S., KAR, S., DURBHA, S. S. & JAGARLAPUDI, A., 2021. Time Series Forecasting of Univariate Agrometeorological Data: A Comparative Performance Evaluation via One-Step and Multi-Step Ahead Forecasting Strategies. *Sensors*, 01 April, 21, pp. 2430.
- TEIXEIRA, R., CERVEIRA, A., PIRES, E. J. S. & BAPTISTA, J., 2024. Enhancing Weather Forecasting Integrating LSTM and GA. *Applied Sciences*, 1 July, 14(13), pp. 5769.

TORRES, J. F. ET AL., 2021. Deep Learning for Time Series Forecasting: A Survey. *Big Data*, 5 February, 9(1), pp. 3-21

ZHANG, W. Y., XIE, J. F., WAN, G. C. & TONG, M. S., 2022. Single-step and Multi-step

Time Series Prediction for Urban Temperature Based on LSTM Model of TensorFlow. *In 2021 Photonics & Electromagnetics Research Symposium (PIERS)*, pp. 1531-1535, IEEE.