

Penggunaan Multivariat Model Bidirectional LSTM untuk Prediksi Cuaca: Optimalisasi Waktu Tanam Padi Petani Kabupaten Garut

Haris Awarulloh¹⁾, Diqy Fakhru Shiddieq²⁾, Dwi Nurhayati³⁾

^{1,2,3)} Bisnis Digital S1, Universitas Garut

¹⁾ 24025121076@fekon.uniga.ac.id, ²⁾ diqy@uniga.ac.id, ³⁾ dwinurhayati@uniga.ac.id

ABSTRACT

Climate unpredictability challenges agricultural activities, especially in Garut Regency, where planting schedules often rely on traditional knowledge. This study employs a Bidirectional Long Short-Term Memory (BiLSTM) model to optimize rice planting schedules through multivariate weather forecasting. Meteorological data from BMKG, including average temperature, relative humidity, rainfall, and sunshine duration, were preprocessed and normalized for modeling. The BiLSTM model excelled in predicting key variables, achieving low Mean Absolute Error (MAE) values of 0.73767 for temperature and 5.32157 for humidity, with Root Mean Squared Error (RMSE) values of 0.94146 and 6.57378, respectively. However, rainfall and sunshine duration predictions showed higher MAE values of 4.71795 and 1.07899, reflecting their complex nature. The study aligned weather predictions with rice cultivation criteria, creating an optimized planting calendar to assist farmers. Results highlight the potential of advanced machine learning models to mitigate climate-related agricultural risks and boost productivity. Future research could integrate additional meteorological factors, such as wind patterns and regional climatic indices (e.g., ENSO), while exploring advanced architectures like Attention Mechanism to enhance prediction accuracy. These findings underscore BiLSTM's promise in improving resilience and productivity in climate-sensitive agriculture.

Keywords: Bidirectional LSTM, weather forecasting, rice planting, time series analysis, climate resilience.

I. PENDAHULUAN

Perubahan iklim dan ketidakpastian cuaca menjadi ancaman serius bagi sektor pertanian, khususnya di Kabupaten Garut, di mana sebagian besar petani masih bergantung pada metode tradisional untuk menentukan waktu tanam. Berdasarkan data BPS, luas lahan sawah tadah hujan di Garut mencapai 10.765 hektar pada 2017. Namun, ancaman kekeringan semakin meningkat, dengan sekitar 10.000 hektar lahan sawah terancam mengalami kekurangan air. Hal ini diperparah dengan data BPS yang mencatat penurunan luas panen padi dari 75.951 hektar pada 2022 menjadi 75.648 hektar pada akhir 2023. Ketidakpastian cuaca seringkali menyebabkan kerugian yang signifikan bagi pertanian, baik dalam bentuk hasil panen yang menurun maupun meningkatnya biaya produksi. Kurangnya informasi cuaca yang tepat waktu dan dapat diandalkan merupakan kendala serius terhadap efisiensi operasi perencanaan pertanian. Namun, tidak sepenuhnya dapat menghindari seluruh kerugian pertanian akibat parameter cuaca, tetapi dapat diminimalkan sampai tingkat tertentu dengan menerapkan perubahan melalui informasi prakiraan cuaca yang tepat waktu dan akurat (Linda et al., 2023). Dalam konteks ini, sangat diperlukan suatu teknik prediksi cuaca yang andal untuk membantu petani dalam menentukan waktu tanam yang optimal guna mengurangi risiko ketidakpastian cuaca.

Data awal musim hujan yang diterbitkan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) menjadi acuan untuk menentukan awal musim tanam. BMKG mendefinisikan awal musim hujan sebagai tiga kali dasarian (sepuluh hari) dengan curah hujan lebih dari 50 mm. Data ini menjadi dasar bagi para petani dalam menyusun rencana kegiatan pertanian sehingga mereka dapat menghindari risiko yang ditimbulkan oleh ketidakpastian cuaca. Dalam praktiknya, prediksi waktu tanam yang akurat perlu disiapkan setidaknya dua hingga tiga bulan sebelum musim tanam, agar petani dan pemangku

kepentingan memiliki waktu yang cukup untuk mempersiapkan strategi produksi yang lebih efisien (Surmaini & Syahbuddin, 2016).

Meskipun berbagai pendekatan telah digunakan dalam prediksi cuaca, metode konvensional seperti SARIMA dan *Support Vector Regression* (SVR) memiliki keterbatasan dalam menangani data cuaca yang kompleks dan *non-linear*. SARIMA, misalnya, dapat memprediksi curah hujan harian dengan akurasi yang cukup melalui deteksi *outlier* berbasis analisis musiman oleh Huda et al., (2012). Begitu pula, dalam penelitian oleh Wulan Suci & Irhamah, (2017), penggunaan GA-SVR menghasilkan peningkatan akurasi prediksi curah hujan di Bojonegoro melalui optimasi parameter SVR. Namun, kedua metode ini memiliki keterbatasan dalam mengidentifikasi pola hubungan jangka panjang antar parameter cuaca yang saling terkait dan dalam mendeteksi kompleksitas dinamis dari data cuaca multivariat. Data deret waktu multivariat seringkali memiliki beberapa variabel terikat waktu, dan setiap variabel tidak hanya bergantung pada nilai masa lalunya tetapi juga pada variabel lain (Ju & Liu, 2021).

Dalam upaya menyediakan informasi prediksi yang lebih baik, teknologi peramalan cuaca berbasis *Long Short-Term Memory* (LSTM) menawarkan keunggulan dengan kemampuan memprediksi pola data yang kompleks dan non-linear, yang tidak mampu ditangani oleh metode prediksi konvensional. LSTM merupakan arsitektur RNN buatan yang diusulkan oleh Hochreiter & Schmidhuber (1997).

Penelitian yang sama dilakukan oleh Olivya & Syari (2020) menunjukkan bahwa pemodelan atribut cuaca menggunakan LSTM mampu memberikan hasil prediksi yang sangat akurat. Namun, penelitian tersebut memodelkan setiap atribut cuaca (suhu, curah hujan, dan kelembapan udara) secara terpisah, sehingga memerlukan arsitektur khusus yang disesuaikan dengan karakteristik data masing-masing atribut. Dalam penelitian ini, Penggunaan BiLSTM menawarkan dua keuntungan utama. Pertama, kemampuannya memproses data secara simultan dari dua arah (masa lalu dan masa depan) memungkinkan deteksi pola temporal yang lebih kompleks. Kedua, model ini dapat menangkap dependensi jangka panjang antar parameter cuaca yang lebih kompleks dibandingkan LSTM biasa, sebagaimana diuraikan oleh Patel et al., (2018). Dengan demikian, BiLSTM menjadi pilihan yang lebih unggul untuk meningkatkan akurasi prediksi cuaca, khususnya dalam mendukung penentuan waktu tanam padi yang lebih efisien dan tepat.

Penelitian ini bertujuan untuk memodelkan lima parameter cuaca utama secara simultan dengan model BiLSTM. Melalui penerapan model ini, memungkinkan untuk mengintegrasikan informasi yang lebih lengkap dan relevan mengenai kondisi cuaca yang akan datang dalam satu prediksi yang lebih holistik. Hal ini sangat penting untuk perencanaan pertanian yang efisien, di mana petani tidak hanya memerlukan satu prediksi cuaca, tetapi juga gambaran yang menyeluruh tentang bagaimana berbagai faktor cuaca akan berinteraksi dalam mempengaruhi keberhasilan tanaman mereka. *Output* prediksi multivariat yang seragam ini akan memberikan panduan yang lebih jelas bagi petani untuk mengambil keputusan terkait waktu tanam dan tindakan perlindungan tanaman, sehingga dapat meningkatkan hasil panen dan produksi padi di Kabupaten Garut. Selain itu, pendekatan ini juga dapat menjadi landasan bagi pengembangan solusi berbasis data dalam menghadapi tantangan perubahan iklim di sektor pertanian.

II. TINJAUAN PUSTAKA

Long Short Term Memory (LSTM), sebagai salah satu jenis jaringan saraf tiruan yang khusus dirancang untuk mengatasi masalah urutan data yang panjang dan memiliki ketergantungan jangka panjang, menawarkan solusi yang lebih unggul dalam memprediksi cuaca (Milad et al., 2021). Mekanisme kerja LSTM, yang melibatkan *forget gate*, *input gate*, dan *output gate*, memungkinkan model ini untuk menyaring informasi relevan dari data deret

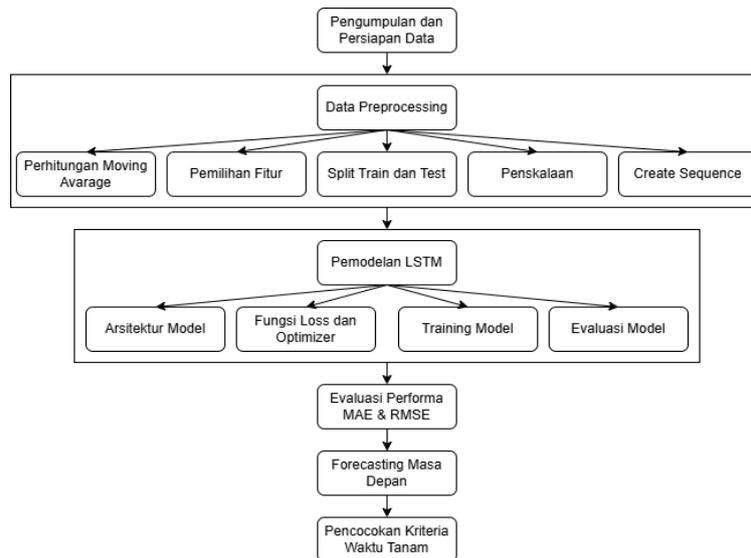
waktu yang kompleks. Dalam prediksi cuaca, LSTM mampu mengatasi tantangan gradien hilang yang sering dialami model RNN tradisional, sehingga memberikan hasil prakiraan yang lebih akurat (Xie et al., 2024). Penggunaan *deep neural networks* untuk mempelajari dinamika data iklim secara menyeluruh menghasilkan prakiraan yang akurat, dengan model yang dibangun berdasarkan informasi cuaca saat ini dan data prakiraan masa lalu yang mengandung kesalahan sebelumnya (Nketiah et al., 2023).

BiLSTM, yang merupakan pengembangan dari LSTM dengan pemrosesan data dua arah (ke depan dan ke belakang), mampu menangkap pola yang lebih kompleks dalam data urutan waktu, seperti data cuaca dengan ketergantungan jangka panjang. Penelitian Zoremsanga et al., (2024) menunjukkan bahwa BiLSTM memiliki keunggulan dalam aplikasi prediksi cuaca, termasuk prediksi curah hujan bulanan. Dengan memprediksi curah hujan bulanan di India menggunakan data dari 1871 hingga 2016 menunjukkan bahwa BiLSTM dapat mencapai RMSE sebesar 240,79, yang lebih baik 8% dibandingkan model RNN satu sel, 4% lebih baik dari model LSTM satu sel, dan 2% lebih baik dari model Stacked LSTM. Hasil ini menggarisbawahi potensi BiLSTM untuk meningkatkan akurasi prediksi dibandingkan model tradisional. Selain itu, Hewage et al., (2021) menemukan bahwa pendekatan berbasis BiLSTM mampu mengurangi error signifikan dalam prediksi parameter cuaca dibandingkan metode tradisional seperti ARIMA atau SVR. Berdasarkan hasil ini, model LSTM terbukti sangat akurat dan memiliki potensi besar dalam prediksi iklim jangka pendek maupun jangka Panjang. Beberapa penelitian tersebut telah menguji variabel dari berbagai sumber untuk menilai dampaknya terhadap kinerja model.

Namun, beberapa tantangan dalam penggunaan BiLSTM termasuk kebutuhan data yang besar, sumber daya komputasi tinggi, serta sensitivitas terhadap kualitas data masukan. Untuk meningkatkan akurasi, penelitian di masa depan dapat mengeksplorasi model hybrid, seperti BiLSTM dengan *Attention Mechanism*, serta integrasi data dari variabel meteorologi tambahan seperti pola angin dan indeks iklim global (ENSO, IOD). Penyesuaian model untuk kondisi lokal, seperti Kabupaten Garut, juga penting untuk menghasilkan kalender tanam yang relevan dan dapat diterapkan secara praktis.

III. METODE PENELITIAN

Metode penelitian ini dimulai dengan mengidentifikasi masalah, kemudian mengumpulkan dataset dalam bentuk xls dari data terbuka BMKG dengan rentang tiga tahun dari Januari 2021 sampai Desember 2023 berjumlah 1094 data. Selanjutnya, tahap persiapan data, *preprocessing* dataset yang sudah dimiliki, penambahan atau pemilihan fitur, pembagian data pelatihan 875 data serta data pengujian 218 data, implementasi LSTM, Evaluasi performa menggunakan MAE dan RMSE dibandingkan dengan nilai *threshold* yang telah ditentukan, prediksi masa depan dan pencocokan model kriteria waktu tanam, berikut merupakan desain dari tahapan penelitian yang dilakukan seperti pada Gambar 1.



Gambar 1. Alur Metode Penelitian

3.1 Pengumpulan dan Persiapan Data

Data yang terkandung dalam berkas ini mencakup tanggal, temperatur rata-rata (Tavg), kelembapan relatif rata-rata (RH_avg), lama penyinaran matahari (ss), curah hujan (RR), dan kecepatan angin rata-rata (ff_avg) seperti pada Gambar 2. Data yang tersedia kemudian diproses melalui serangkaian tahapan pra-pemrosesan untuk memastikan kualitas dan kesiapan data untuk pemodelan.

Kolom 'Tanggal' pada dataset diubah menjadi tipe data *datetime* guna memudahkan analisis temporal dan ekstraksi informasi waktu yang relevan. Fitur waktu yang lebih rinci, seperti kuartal, bulan, tahun, dan hari dalam seminggu, diekstrak untuk menangkap tren musiman dan pola siklus harian yang dapat mempengaruhi variabel cuaca. Nilai-nilai ekstrim pada kolom 'RR' (misalnya 8888.0) yang tidak sesuai dengan nilai curah hujan yang wajar serta nilai kosong pada fitur lainnya digantikan dengan rata-rata bulanan untuk setiap bulan terlihat di Gambar 3.

	Tanggal	Tavg	RH_avg	RR	ss	ff_avg
0	01-01-2021	25.9	84.0	8888.0	0.2	1.0
1	02-01-2021	26.1	81.0	2.4	4.3	1.0
2	03-01-2021	25.6	88.0	NaN	2.0	1.0
3	04-01-2021	25.4	87.0	41.0	2.1	1.0
4	05-01-2021	24.4	90.0	0.2	0.1	1.0
...
1090	27-12-2023	24.3	82.0	8888.0	3.3	0.0
1091	28-12-2023	24.9	79.0	1.7	3.5	0.0
1092	29-12-2023	24.9	83.0	0.7	4.4	1.0
1093	30-12-2023	24.0	88.0	53.0	5.9	0.0
1094	31-12-2023	23.8	86.0	3.0	2.0	0.0

Gambar 2. Sebelum Persiapan

	Tanggal	Tavg	RH_avg	RR	ss	ff_avg	quarter	month	year	dayofweek
0	2021-01-01	25.9	84.0	4.538272	0.2	1.0	1	1	2021	4
1	2021-01-02	26.1	81.0	2.400000	4.3	1.0	1	1	2021	5
2	2021-01-03	25.6	88.0	2.000000	2.0	1.0	1	1	2021	6
3	2021-01-04	25.4	87.0	41.000000	2.1	1.0	1	1	2021	0
4	2021-01-05	24.4	90.0	0.200000	0.1	1.0	1	1	2021	1
...
1090	2023-12-27	24.3	82.0	9.830682	3.3	0.0	4	12	2023	2
1091	2023-12-28	24.9	79.0	1.700000	3.5	0.0	4	12	2023	3
1092	2023-12-29	24.9	83.0	0.700000	4.4	1.0	4	12	2023	4
1093	2023-12-30	24.0	88.0	53.000000	5.9	0.0	4	12	2023	5
1094	2023-12-31	23.8	86.0	3.000000	2.0	0.0	4	12	2023	6

Gambar 3. Setelah Persiapan

3.2 Data Preprocessing

Perhitungan *Moving Average* untuk menghaluskan fluktuasi data yang tidak relevan dan mengurangi *noise*, dilakukan perhitungan *Moving Average* (MA) dengan jendela 7 hari pada fitur-fitur yang relevan, yaitu Tavg, RH_avg, RR, dan ff_avg. Dengan menggunakan *moving average*, data yang diproses akan mencerminkan tren jangka pendek, sehingga dapat memberikan gambaran yang lebih stabil mengenai perubahan parameter cuaca.

Selanjutnya, dilakukan seleksi fitur untuk memastikan hanya fitur-fitur yang relevan yang digunakan dalam pemodelan. Fitur-fitur yang dipilih antara lain adalah Tavg, RH_avg, SS, RR, *quarter*, *month*, Tavg_MA7, RH_avg_MA7, RR_MA7, dan ff_avg yang di tampilkan Gambar 4. Fitur-fitur lain yang tidak relevan atau memiliki pengaruh minimal terhadap prediksi waktu tanam dikeluarkan dari dataset.

Tanggal	Tavg	RH_avg	RR	ss	ff_avg	quarter	month	year	dayofweek	Tavg_MA7	RH_avg_MA7	RR_MA7
2021-01-01	25.9	84.0	4.538272	0.2	1.0	1	1	2021	4	25.900000	84.000000	4.538272
2021-01-02	26.1	81.0	2.400000	4.3	1.0	1	1	2021	5	26.000000	82.500000	3.469136
2021-01-03	25.6	88.0	2.000000	2.0	1.0	1	1	2021	6	25.866667	84.333333	2.979424
2021-01-04	25.4	87.0	41.000000	2.1	1.0	1	1	2021	0	25.750000	85.000000	12.484568
2021-01-05	24.4	90.0	0.200000	0.1	1.0	1	1	2021	1	25.480000	86.000000	10.027654

Gambar 4. Data Setelah *Preprocessing*

Data dibagi menjadi dua set, yaitu data pelatihan (80%) dan data pengujian (20%). Pemisahan ini dilakukan tanpa pengacakan (*shuffle=False*) untuk mempertahankan urutan temporal data, yang krusial dalam prediksi cuaca, di mana urutan waktu mempengaruhi hasil prediksi (Zhao et al., 2024). Seluruh fitur input dan output dinormalisasi menggunakan *MinMaxScaler*, untuk memastikan bahwa setiap fitur berada dalam rentang nilai yang seragam, sehingga mencegah fitur dengan rentang nilai lebih besar mendominasi selama proses pelatihan. Data pelatihan dan pengujian kemudian diubah menjadi urutan dengan panjang *timestep = 30*, yang berarti model memanfaatkan data cuaca selama 30 hari sebelumnya untuk memprediksi nilai parameter cuaca pada hari berikutnya.

3.3 Pemodelan LSTM

Pada tahap ini, *model Bidirectional Long Short-Term Memory* (BiLSTM) digunakan untuk memprediksi parameter cuaca. Sehubungan dengan tujuan untuk prediksi cuaca yang mencari korelasi atau keterhubungan antar fitur untuk menghasilkan prediksi yang akurat BiLSTM mampu menangani beberapa fitur sekaligus (seperti temperatur, kelembapan, curah hujan, dan kecepatan angin), akan lebih mampu menangkap hubungan interdependensi yang lebih kuat antara berbagai faktor cuaca, sehingga meningkatkan akurasi prediksi waktu tanam padi yang lebih tepat.

Model dilatih menggunakan data training yang telah disiapkan sebelumnya. Proses pelatihan ini bertujuan untuk membangun model yang dapat memprediksi parameter cuaca secara akurat dengan memperhatikan ketergantungan jangka panjang antar variabel. Setelah proses pelatihan selesai, model dievaluasi menggunakan data testing untuk memeriksa seberapa baik model memprediksi parameter cuaca. Evaluasi dilakukan dengan melihat nilai *loss* pada data *testing*. Terlihat pada Tabel 1 model menggunakan arsitektur *Sequential* dengan dua lapisan LSTM untuk memprediksi data deret waktu. Model dirancang dengan *timesteps* sebanyak 30, yang berarti setiap *input* mempertimbangkan 30 langkah waktu sebelumnya. Input memiliki sejumlah fitur sebesar *len(input_features)*, sementara *output* memiliki *len(output_features)*. Lapisan pertama adalah LSTM *bidirectional* dengan 60 unit, diikuti oleh lapisan LSTM kedua dengan 60 unit. Untuk mencegah *overfitting*, digunakan *dropout rate* sebesar 0.2 setelah lapisan LSTM. Aktivasi ReLU digunakan untuk lapisan tersembunyi. Model diakhiri dengan *Dense layer* sebagai *output layer* untuk menghasilkan prediksi. Proses pelatihan menggunakan *optimizer* Adam dengan *learning rate* 0.001 dan *loss function* Mean Absolute Error (MAE). Pelatihan dilakukan dengan *batch size* 32 selama 50 *epoch*.

Tabel 1. Parameter Model BiLSTM

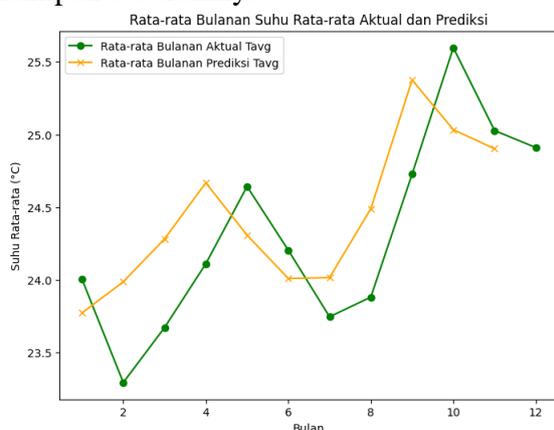
Parameter	Nilai
timesteps	30
n_features_input	len(input_features)
n_features_output	len(output_features)
Model	Sequential
Activation	ReLU
Dense Layer	Output Layer
Learning Rate	0.001
Optimizer	Adam
Loss Function	MAE
Batch Size	32
Epochs	50
LSTM Units	60 (Bidirectional)
LSTM Units (Second Layer)	60
Dropout Rate	0.2

3.4 Evaluasi Performa Model

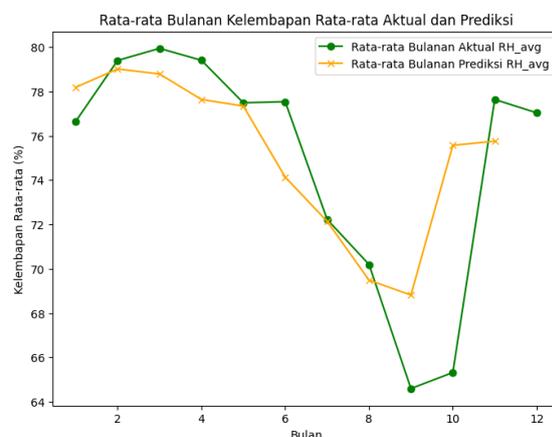
Untuk mengevaluasi kinerja model, dihitung dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). MAE mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual, sementara RMSE mengukur akar dari rata-rata kuadrat selisih antara nilai prediksi dan aktual. Metrik ini digunakan untuk menilai keakuratan model dalam memprediksi nilai parameter cuaca. MAE dan RMSE dibandingkan dengan nilai *threshold* yang telah ditentukan. *Threshold* dihitung sebagai persentase dari rentang data setiap fitur untuk memberikan batasan yang jelas dalam menilai apakah hasil prediksi cukup akurat atau tidak (Malhotra & Sharma, 2021).

3.5 Prediksi Masa Depan

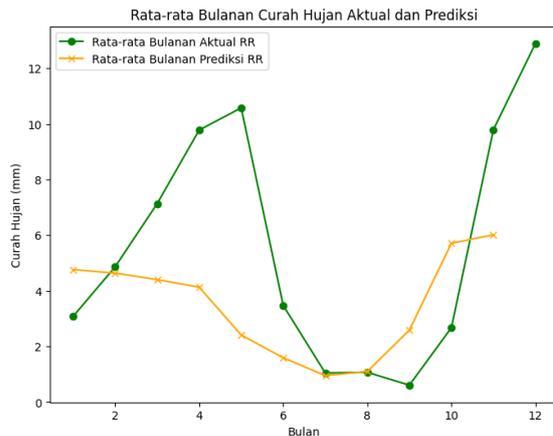
Pada tahap ini, model dan *scaler* yang telah disimpan sebelumnya saat *training* model dimuat kembali untuk digunakan dalam prediksi masa depan. Hal ini memungkinkan model untuk melakukan prediksi cuaca berdasarkan data yang baru. Data cuaca dari tahun 2023 diambil sebagai dasar untuk membuat *sequence* prediksi. Data ini kemudian diproses melalui langkah penskalaan yang sama dengan data *training* agar konsistensi tetap terjaga. Model melakukan prediksi untuk periode Januari hingga November 2024, menghasilkan nilai parameter cuaca yang diprediksi pada periode tersebut. Setelah hasil prediksi dihitung, hasil yang telah dinormalisasi diubah kembali ke skala asli menggunakan *scaler* yang telah disimpan sebelumnya.



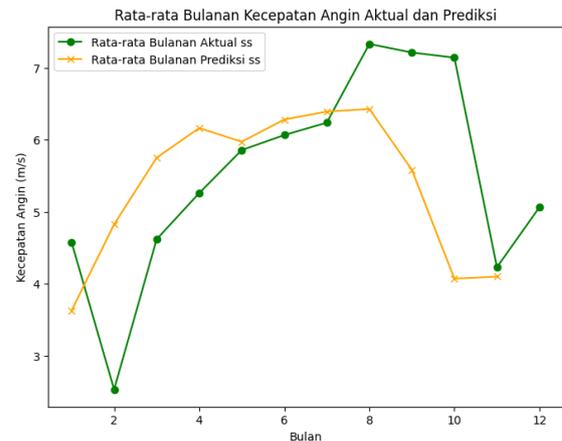
Gambar 5. Aktual vs prediksi Tavg(suhu)



Gambar 6. Aktual vs prediksi RH(kelembapan)



Gambar 7. Aktual vs prediksi RR(curah hujan)



Gambar 8. Aktual vs prediksi ss(sinar matahari)

Grafik perbandingan di atas menggambarkan sejauh mana model BiLSTM dapat menangkap tren umum data cuaca yang sebenarnya rekomendasi untuk perbaikan di bagian Hasil dan Pembahasan yang lengkap dengan metrik evaluasi yang relevan. Pada variabel suhu (T_{avg}) dan kelembapan (RH_{avg}) yang ditunjukkan pada Gambar 5 dan Gambar 6, hasil prediksi menunjukkan kesesuaian yang baik dengan nilai aktual, dengan penyimpangan yang relatif kecil. Namun, pada variabel curah hujan (RR) dan lama sinar matahari (ss) yang ditampilkan pada Gambar 7 dan Gambar 8, prediksi menunjukkan fluktuasi yang lebih besar, mencerminkan tantangan dalam memodelkan faktor-faktor eksternal yang kompleks, seperti pola angin atau fenomena cuaca ekstrem, yang sulit diprediksi secara akurat oleh model.

3.6 Pencocokan Kriteria Waktu Tanam

Pencocokan kriteria tanam merupakan langkah penting dalam penelitian ini untuk menentukan periode waktu optimal penanaman padi berdasarkan hasil prediksi cuaca dari model *Bidirectional Long Short-Term Memory* (BiLSTM). Penentuan waktu tanam yang tepat sangat bergantung pada faktor meteorologi yang mendukung, seperti suhu, kelembapan, curah hujan, dan durasi sinar matahari. Kriteria cuaca yang digunakan dalam penelitian ini adalah Curah Hujan: 4-10 mm per hari, Suhu 18-25°C, Durasi Sinar Matahari 4-9 jam per hari, Kelembaban Relatif: 70-85%. Kriteria ini mencerminkan kondisi yang ideal untuk pertumbuhan padi di wilayah Garut.

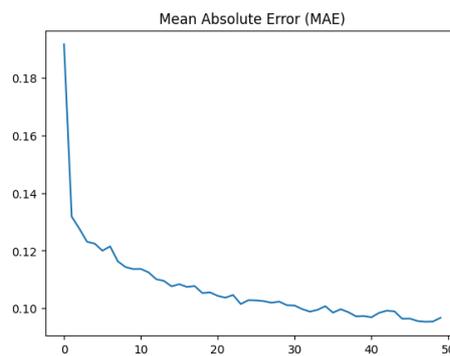
Pencocokan kriteria ini dengan hasil prediksi cuaca dari model BiLSTM bertujuan untuk mengidentifikasi waktu tanam yang optimal, dengan mempertimbangkan faktor cuaca yang mendukung dan sesuai dengan kebutuhan tanaman padi. Kriteria yang diterapkan telah divalidasi dengan Peraturan Menteri Pertanian No. 79/2013, yang merekomendasikan curah hujan yang cukup, suhu yang moderat (25-30°C), durasi sinar matahari yang cukup, dan kelembapan yang ideal (70-85%) untuk mendukung pertumbuhan padi yang optimal. Penerapan kriteria ini memberikan dasar ilmiah yang kuat untuk menentukan waktu tanam yang efektif dan efisien.

IV. HASIL DAN PEMBAHASAN

4.1 Performa Training model

Hasil pelatihan model menunjukkan evaluasi kinerja menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Pada Gambar 9 grafik MAE memperlihatkan penurunan error yang konsisten sepanjang proses pelatihan, mengindikasikan bahwa model semakin baik dalam memprediksi data pelatihan. Nilai *loss* pada data pengujian yang tercatat sebesar 0.0925 menunjukkan kemampuan model dalam

memprediksi dengan akurasi yang baik pada data yang belum pernah dilihat sebelumnya, sehingga memberikan gambaran mengenai seberapa efektif model dalam melakukan generalisasi ke data uji.



Gambar 9. Grafik MAE

4.2 Evaluasi Performa Model

Untuk mengevaluasi performa model, digunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Berdasarkan hasil evaluasi, model menunjukkan performa yang baik dalam memprediksi Tavg dan RH_avg, dengan MAE dan RMSE yang rendah. Namun, untuk variabel ss dan RR, nilai MAE dan RMSE lebih tinggi, menunjukkan ketidaktepatan yang lebih besar dalam prediksi.

Tabel 2. Metrik Evaluasi Model Training

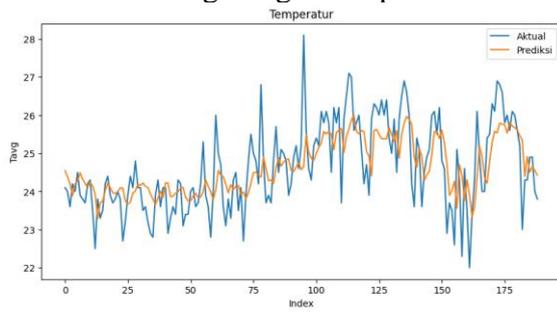
Variabel	MAE	RMSE	Threshold MAE	Threshold RMSE
Tavg (Suhu)	0.73767	0.94146	0.73	1.095
RH_avg (Kelembapan)	5.32157	6.57378	5.0	7.5
RR (Curah Hujan)	4.71795	10.38523	8.5	12.75
ss (Sinar Matahari)	1.07899	1.47148	1.0	1.5

Dari Tabel 2 mendapat hasil Tavg dan RH_avg MAE dan RMSE untuk kedua variabel ini menunjukkan kesalahan yang dapat diterima, mengindikasikan model berhasil memprediksi tren dengan baik. Serta ss dan RR prediksi untuk variabel ini lebih fluktuatif dan memiliki kesalahan lebih tinggi, kemungkinan disebabkan oleh keterbatasan data historis dan kompleksitas faktor yang mempengaruhi kedua variabel tersebut.

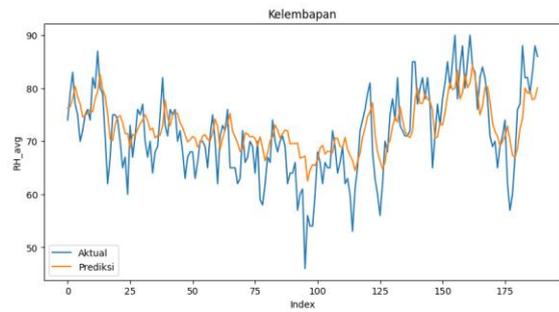
4.3 Visualisasi Training

Bagian ini memvisualisasikan kinerja hasil pelatihan BiLSTM terdapat empat plot yang membandingkan nilai actual vs prediksi untuk masing-masing fitur. Visualisasi kinerja model BiLSTM menunjukkan bahwa prediksi untuk suhu rata-rata (Tavg) memiliki kesesuaian yang baik dengan data aktual, sebagaimana terlihat pada Gambar 10. Hal serupa juga terlihat untuk kelembapan rata-rata (RH) pada Gambar 11. Namun, prediksi untuk curah hujan (RR) pada Gambar 12 dan lama penyinaran matahari (ss) pada Gambar 13 menunjukkan fluktuasi yang lebih besar, mencerminkan tantangan dalam memprediksi variabel dengan kompleksitas tinggi. Hal ini disebabkan oleh sifat stokastik kedua variabel tersebut yang sangat dipengaruhi oleh faktor eksternal, seperti fenomena atmosfer global (El Nino, La Nina) dan variabilitas intra-musiman (Madden-Julian Oscillation), serta keterbatasan resolusi temporal data harian yang digunakan (Hernández-Bedolla et al., 2022). Selain itu, hubungan dinamis antar parameter cuaca yang kompleks dapat menyebabkan model BiLSTM kesulitan untuk sepenuhnya menangkap pola yang relevan. Oleh karena itu,

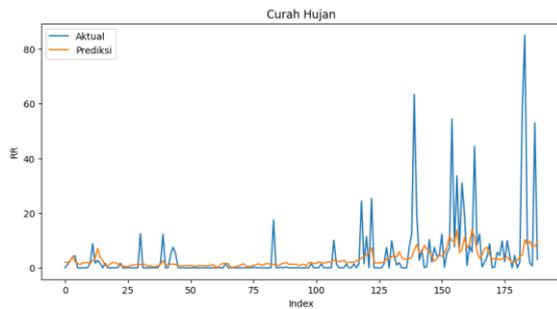
integrasi indeks iklim global atau data cuaca dengan resolusi lebih tinggi dapat menjadi solusi untuk mengurangi error pada variabel ini.



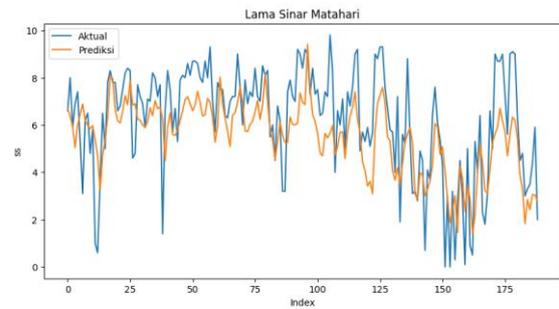
Gambar 10. Aktual vs prediksi Tavg(suhu)



Gambar 11. Aktual vs prediksi RH(kelembapan)



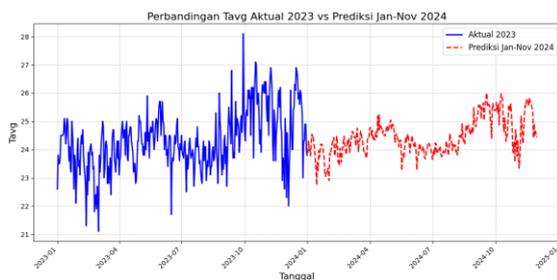
Gambar 12. Aktual vs prediksi RR(curah hujan)



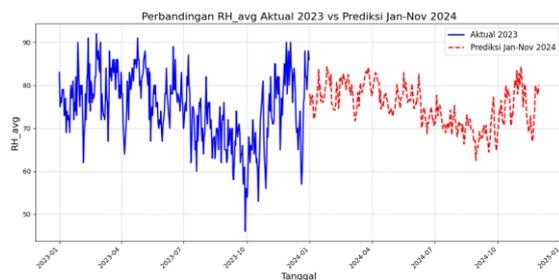
Gambar 13. Aktual vs prediksi ss(sinar matahari)

4.4 Prediksi Masa Depan

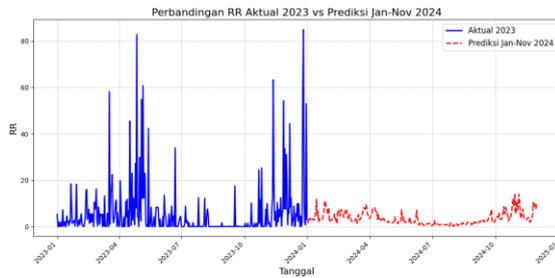
Model BiLSTM berhasil menangkap tren umum pada variabel Tavg (suhu rata-rata) dan RH_avg (kelembapan rata-rata) yang ditunjukkan pada Gambar 14 dan Gambar 15, dengan hasil prediksi yang sesuai dengan data aktual. Namun, untuk variabel ss (lama sinar matahari) dan RR (curah hujan) yang ditampilkan pada Gambar 16 dan Gambar 17, model menunjukkan fluktuasi yang lebih besar dan kurang akurat, kemungkinan karena kompleksitas faktor-faktor yang mempengaruhi variabel ini dan keterbatasan data. Berikut visualisasi dari hasil prediksi bulan Januari sampai November 2024.



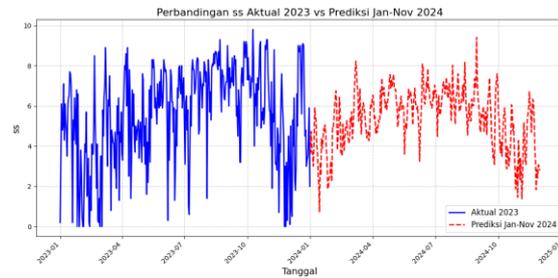
Gambar 14. Aktual 2023 vs prediksi Tavg(suhu) 2024



Gambar 15. Aktual 2023 vs prediksi RH(kelembapan) 2024



Gambar 16. Aktual 2023 vs prediksi RR (curah hujan) 2024



Gambar 17. Aktual 2023 vs prediksi ss (sinar matahari) 2024

Berdasarkan hasil prediksi dan perbandingan antara data aktual tahun 2023 dan prediksi untuk periode Januari-November 2024, model BiLSTM yang diterapkan dalam metode *multivariate time series forecasting* berhasil menangkap tren utama dari variabel 'Tavg' (temperatur rata-rata) dan 'RH_avg' (kelembapan relatif rata-rata) dengan cukup baik. Prediksi untuk kedua variabel ini menunjukkan kecocokan yang signifikan dengan data aktual yang tercatat pada tahun 2023. Namun, untuk variabel 'ss' (lama sinar matahari) dan 'RR' (curah hujan), prediksi menunjukkan fluktuasi yang lebih besar dan kurang akurat. Hal ini kemungkinan disebabkan oleh faktor-faktor kompleks yang memengaruhi kedua variabel tersebut, seperti pola awan, tekanan udara, dan fenomena cuaca ekstrem, yang sulit dimodelkan dengan pendekatan yang ada. Selain itu, faktor eksternal seperti fenomena El Nino atau La Nina, yang dapat mempengaruhi pola cuaca, juga berkontribusi terhadap ketidakakuratan prediksi pada variabel-variabel ini (Sanusi et al., 2021).

Keterbatasan data historis yang digunakan dalam pelatihan model juga menjadi faktor yang mempengaruhi akurasi prediksi. Data yang kurang lengkap atau tidak cukup panjang mungkin tidak sepenuhnya mewakili pola iklim di tahun 2024, terutama jika ada perubahan musiman atau perubahan iklim yang signifikan. Meskipun model BiLSTM memiliki kemampuan untuk menangkap pola yang kompleks dalam data *time series*, prediksi untuk beberapa variabel yang lebih dinamis masih memerlukan perbaikan.

4.6 Pencocokan Kriteria Waktu Tanam

Prediksi cuaca yang dihasilkan oleh model BiLSTM digunakan untuk menyusun kalender tanam berdasarkan kriteria cuaca optimal untuk pertumbuhan padi, seperti curah hujan 4-10 mm per hari, suhu 18-25°C, lama penyinaran matahari 4-9 jam per hari, dan kelembapan 70-85%. Data prediksi diperoleh dari hasil pemodelan dengan dataset meteorologi historis BMKG dan diproses menggunakan logika berbasis aturan untuk mengidentifikasi hari-hari yang memenuhi kriteria tersebut yang ditampilkan pada tabel 3. Kalender tanam ini memberikan panduan waktu tanam yang lebih akurat, sehingga dapat meminimalkan risiko gagal panen akibat ketidakpastian cuaca.

Tabel 3. Kalender Waktu Tanam Padi

Bulan	Tanggal Tanam Padi
Februari	10, 17, 18, 20, 21, 22, 24, 25, 27
Maret	2, 3, 15, 20, 21, 22, 28, 29, 30
April	2,3,9,10,11,13
Mei	7,20
Oktober	19,30
November	6,8,11

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian ini, model BiLSTM yang diterapkan dalam metode *multivariate time series forecasting* mampu memprediksi tren utama dari variabel meteorologi, terutama untuk temperatur rata-rata (Tavg) dan kelembapan relatif rata-rata (RH_avg), dengan akurasi yang baik. Meskipun demikian, prediksi untuk variabel yang lebih fluktuatif, seperti lama sinar matahari (ss) dan curah hujan (RR), masih menunjukkan keterbatasan. Hal ini disebabkan oleh faktor-faktor kompleks yang mempengaruhi variabel-variabel tersebut, seperti pola cuaca yang cepat berubah dan fenomena eksternal seperti El Nino atau La Nina. Prediksi cuaca yang dihasilkan oleh model digunakan untuk menyusun kalender tanam padi yang memberikan panduan waktu tanam optimal bagi petani di Kabupaten Garut. Dengan panduan ini, petani dapat mengurangi risiko gagal panen akibat ketidakpastian cuaca, meningkatkan efisiensi penggunaan air, dan mendukung perencanaan pertanian yang lebih terarah.

5.2 Saran

Untuk meningkatkan akurasi model, perlu ada penambahan data historis yang lebih panjang dan komprehensif. Data yang lebih bervariasi akan membantu model memahami pola musiman dan tren jangka panjang yang lebih baik. Selain itu, pengembangan *feature engineering* dengan menambahkan variabel eksternal seperti data meteorologi regional, indeks iklim (misalnya El Nino Southern Oscillation - ENSO). Pemodelan alternatif, seperti penggunaan teknik berbasis attention juga dapat dipertimbangkan untuk menangkap pola non-linear yang lebih kompleks, BiLSTM (*Bidirectional LSTM*) dan *mechanism attention*. BiLSTM memungkinkan model untuk mengolah informasi baik dari masa lalu maupun masa depan (dua arah), sehingga meningkatkan pemahaman terhadap data waktu. Sementara itu, *attention mechanism* memberikan kemampuan bagi model untuk fokus pada fitur atau data yang paling relevan.

Secara keseluruhan, meskipun model BiLSTM efektif dalam memprediksi tren umum cuaca, untuk meningkatkan akurasi prediksi, terutama pada variabel yang lebih dinamis, perlu dilakukan perbaikan dalam hal data, fitur, dan metode pemodelan.

DAFTAR PUSTAKA

- Hernández-Bedolla, J., Solera, A., Paredes-Arquiola, J., Sanchez-Quispe, S. T., & Domínguez-Sánchez, C. (2022). A Continuous Multisite Multivariate Generator for Daily Temperature Conditioned by Precipitation Occurrence. *Water (Switzerland)*, 14(21). <https://doi.org/10.3390/w14213494>
- Hewage, P., Trovati, M., Pereira, E., & Behera, A. (2021). Deep learning-based effective fine-grained weather forecasting model. *Pattern Analysis and Applications*, 24(1), 343–366. <https://doi.org/10.1007/s10044-020-00898-1>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huda, A. M., Choiruddin, A., Budiarto, O., & Sutikno. (2012). Peramalan Data Curah Hujan Dengan Seasonal Autoregressive Integrated Moving Average (Sarima) Dengan Deteksi Outlier Sebagai Upaya Optimalisasi Produksi Pertanian Di Kabupaten Mojokerto. *Seminar Nasional : Kedaulatan Pangan Dan Energi*.
- Ju, J., & Liu, F. A. (2021). Multivariate time series data prediction based on ATT-LSTM network. *Applied Sciences (Switzerland)*, 11(20). <https://doi.org/10.3390/app11209373>
- Malhotra, R., & Sharma, A. (2021). Threshold benchmarking for feature ranking techniques. *Bulletin of Electrical Engineering and Informatics*, 10(2), 1063–1070. <https://doi.org/10.11591/eei.v10i2.2752>

- Milad, A., Adwan, I., Majeed, S. A., Yusoff, N. I. M., Al-Ansari, N., & Yaseen, Z. M. (2021). Emerging Technologies of Deep Learning Models Development for Pavement Temperature Prediction. *IEEE Access*, 9, 23840–23849. <https://doi.org/10.1109/ACCESS.2021.3056568>
- Nketiah, E. A., Chenlong, L., Yingchuan, J., & Aram, S. A. (2023). Recurrent neural network modeling of multivariate time series and its application in temperature forecasting. *PLoS ONE*, 18(5 May), 1–18. <https://doi.org/10.1371/journal.pone.0285713>
- Olivya, M. I., & Syari, M. (2020). Pemodelan Atribut Cuaca Menggunakan Long Short Term Memory Dalam Perancangan Kalender Tanam. *Teknik Komputer & Jaringan*, 179–183.
- Patel, M., Patel, A., & Ghosh, D. R. (2018). *Precipitation Nowcasting: Leveraging bidirectional LSTM and 1D CNN*. 1–7. <http://arxiv.org/abs/1810.10485>
- Rahman, N., Rahman, M., Baten, M., Hossain, M., Hassan, S., Ahmed, R., Hossain, M., Hossain, A., Aziz, M., Haque, M., Halder, T., Mamun, M., Bhuiyan, M., Khan, M., Chowdhury, A., Qayum, M., Sarkar, M., Salam, M., & Kabir, M. (2021). Weather Forecast Based Rice Advisory Services in Bangladesh. *Bangladesh Rice Journal*, 25(1), 51–74. <https://doi.org/10.3329/brj.v25i1.55179>
- Sanusi, A. R., Taufik, M., & I Putu Santikayasa. (2021). The Use of Weather Research and Forecasting Model to Predict Rainfall in Tropical Peatland: 1. Model Parameterization. *Agromet*, 35(1), 49–59. <https://doi.org/10.29244/j.agromet.35.1.49-59>
- Surmaini, E., & Syahbuddin, H. (2016). Kriteria Awal Musim Tanam: Tinjauan Prediksi Waktu Tanam Padi Di Indonesia. *Jurnal Penelitian Dan Pengembangan Pertanian*, 35(2), 47. <https://doi.org/10.21082/jp3.v35n2.2016.p47-56>
- Weather - 2023 - Hiron - Experiences of co-producing sub-seasonal forecast products for agricultural application in Kenya.pdf*. (n.d.).
- Wulan Suci, K., & Irhamah. (2017). Peramalan Curah Hujan Sebagai Pendukung Vector Regression dan Genetic Algorithm- SVR. *Jurnal Sains Dan Seni ITS*, 6(1).
- Xie, F., Yan, H., Long, Y., Guo, H., Liu, H., & Yu, P. (2024). Weather Prediction Based on Multivariate LSTM Neural Network Model. *Advances in Transdisciplinary Engineering*, 47, 298–303. <https://doi.org/10.3233/ATDE231201>
- Zhao, K., He, Z., Hung, A., & Zeng, D. (2024). *Dominant Shuffle: A Simple Yet Powerful Data Augmentation for Time-series Prediction*. 1–16. <http://arxiv.org/abs/2405.16456>
- Zoremsanga, C., & Hussain, J. (2024). An Evaluation of Bidirectional Long Short-Term Memory Model for Estimating Monthly Rainfall in India. *Indian Journal Of Science And Technology*, 17(18), 1828–1837. <https://doi.org/10.17485/ijst/v17i18.2505>
- Kementerian Pertanian Republik Indonesia. (2019). Pedoman fasilitasi perlindungan lahan pertanian pangan berkelanjutan (PLP2B). Jakarta: Kementerian Pertanian Republik Indonesia.