

Perbandingan Algoritma LSTM dan GRU dalam Prediksi Hasil Panen Padi Pulau Sumatera

Sapto Hadi Riono^{1*}, Risalatul Fathimah Ahmad², Ridho Af Fathir³

^{1,3} Ilmu Komputer, Fakultas Teknologi dan Sains, Universitas PGRI Wiranegara

² Teknologi Pangan, Fakultas Teknologi dan Sains, Universitas PGRI Wiranegara

¹saptoenator@gmail.com*, ²rsf.fathimahh@gmail.com, ³finridho@gmail.com

Abstract

Rice production is a strategic commodity that plays a vital role in maintaining food security in Indonesia. Rice production data, being time-series in nature, is influenced by trends, seasonal patterns, and weather and climate factors; therefore, a prediction model capable of accurately capturing temporal patterns is required. This study aims to compare the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting rice production on the island of Sumatra. The study utilizes secondary data obtained from Statistics Indonesia (BPS), the Meteorology, Climatology, and Geophysics Agency (BMKG), and Kaggle. Preprocessing stages include handling missing data, data normalization, and transformation into a time-series format. The data is then split into training and testing sets using an 80:20 ratio. Model performance is evaluated using Mean Absolute Error (MAE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE). The results indicate that the GRU model outperforms the LSTM model, yielding an MAE of 0.0505, MSE of 0.0075, and RMSE of 0.0868, whereas the LSTM model produces an MAE of 0.0522, MSE of 0.0082, and RMSE of 0.0917. Thus, the GRU model is more effective at capturing the temporal patterns of rice production data and generating more accurate predictions compared to the LSTM model. These findings are expected to serve as a reference for selecting rice production prediction models to support data-driven decision-making in the agricultural sector.

Keywords: time series, LSTM, GRU

Abstrak

Produksi padi merupakan komoditas strategis yang berperan penting dalam menjaga ketahanan pangan di Indonesia. Data produksi padi yang berbentuk deret waktu dipengaruhi oleh tren, pola musiman, serta faktor cuaca dan iklim sehingga diperlukan model prediksi yang mampu menangkap pola temporal secara akurat. Penelitian ini bertujuan membandingkan kinerja model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi produksi padi di Pulau Sumatera. Penelitian menggunakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS), Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), serta Kaggle. Tahap prapemrosesan meliputi penanganan data hilang, normalisasi data, dan transformasi ke dalam format deret waktu. Data kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Kinerja model dievaluasi menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Hasil penelitian menunjukkan bahwa model GRU memberikan kinerja yang lebih baik dibandingkan LSTM dengan nilai MAE sebesar 0,0505, MSE sebesar 0,0075, dan RMSE sebesar 0,0868, sedangkan model LSTM menghasilkan MAE sebesar 0,0522, MSE sebesar 0,0082, dan RMSE sebesar 0,0917. Dengan demikian, model GRU lebih efektif dalam menangkap pola temporal data produksi padi dan menghasilkan prediksi yang lebih akurat dibandingkan LSTM. Hasil penelitian ini diharapkan dapat menjadi referensi dalam pemilihan model prediksi produksi padi untuk mendukung pengambilan keputusan di bidang pertanian berbasis data.

Kata kunci: time series, LSTM, GRU

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Produksi padi adalah salah satu cara penting untuk memastikan keamanan pangan nasional, terutama di Indonesia yang memakan banyak beras sebagai makanan utama sehari-hari. Dalam konteks ini, Pulau Sumatera menjadi salah satu area strategis yang memberikan kontribusi penting terhadap produksi padi secara nasional. Akan tetapi, produksi padi di wilayah ini kerap mengalami kenaikan dari tahun ke tahun yang dipengaruhi oleh berbagai faktor, seperti perubahan cuaca serta luas lahan yang dipanen, [1], serta kondisi iklim pertanian lainnya. Perubahan ini menyulitkan dalam merencanakan produksi secara tepat, sehingga diperlukan cara prediksi yang dapat menangkap pola data secara baik.

Dengan berkembangnya teknologi, metode berbasis *Deep Learning* kini digunakan semakin luas dalam menganalisis data deret waktu, termasuk di bidang pertanian. Hal ini terjadi karena data deret waktu dalam dunia nyata biasanya mengandung kombinasi pola yang bersifat linier dan *non-linier*, sehingga pendekatan yang biasa digunakan sering kali tidak cukup untuk membuat model yang tepat. Untuk mengatasi masalah tersebut, model berbasis jaringan saraf berulang seperti LSTM dan GRU dikembangkan agar dapat lebih maksimal memperoleh dampak jangka panjang dalam data yang berurutan dibandingkan model-model konvensional [2].

Berbagai penelitian terdahulu telah mengkaji penerapan *machine learning* dan *deep learning* untuk

memprediksi hasil pertanian maupun data deret waktu. Penelitian oleh Khaki et al. [3] mengembangkan model *Convolutional Neural Network-Recurrent Neural Network* (CNN-RNN) untuk memprediksi hasil panen dan menunjukkan bahwa pendekatan tersebut mampu memberikan akurasi yang lebih tinggi dibandingkan metode konvensional. Sementara itu, Shastry [4] menerapkan model LSTM pada data hasil panen dan memperoleh hasil yang baik dalam menangkap pola musiman serta ketergantungan jangka panjang. Selain itu, Kamilaris dan Prenafeta-Boldú [5] dalam tinjauan mereka menyimpulkan bahwa metode *deep learning* secara umum memiliki kemampuan yang lebih baik dibandingkan pendekatan konvensional dalam mengolah data pertanian yang kompleks.

Di sisi lain, penelitian mengenai perbandingan arsitektur jaringan saraf berulang menunjukkan bahwa Chung et al. [6] memperkenalkan GRU sebagai pengembangan dari LSTM dengan struktur yang lebih sederhana dan jumlah parameter yang lebih sedikit, sehingga proses pelatihan menjadi lebih efisien tanpa penurunan kinerja yang signifikan. Temuan tersebut didukung oleh penelitian lain yang menunjukkan bahwa model GRU mampu menghasilkan performa prediksi yang kompetitif pada data deret waktu, termasuk data meteorologi, dengan waktu komputasi yang lebih singkat dibandingkan LSTM [7].

Meskipun demikian, sebagian besar penelitian terdahulu berfokus pada prediksi hasil pertanian secara umum, prediksi berbasis citra, atau data meteorologi, sehingga belum secara khusus mengevaluasi kinerja LSTM dan GRU pada prediksi produksi padi di Pulau Sumatera menggunakan data deret waktu produksi padi. Selain itu, penelitian-penelitian tersebut umumnya hanya menerapkan satu model atau belum melakukan perbandingan kinerja kedua model secara komprehensif berdasarkan metrik evaluasi yang sama, seperti MAE, MSE, dan RMSE.

Berdasarkan uraian tersebut, terdapat celah penelitian (*research gap*) berupa belum adanya kajian yang secara komprehensif membandingkan performa model LSTM dan GRU dalam memprediksi produksi padi di Pulau Sumatera menggunakan data deret waktu dari sumber resmi dengan metrik evaluasi yang seragam. Oleh karena itu, penelitian ini dilakukan untuk membandingkan akurasi kedua model tersebut sehingga dapat memberikan rekomendasi model yang paling efektif dalam mendukung pengambilan keputusan di bidang pertanian berbasis data.


Berdasarkan latar belakang yang telah diuraikan, penelitian ini bertujuan membandingkan kinerja model LSTM dan GRU dalam memprediksi produksi padi di Pulau Sumatera menggunakan data deret waktu. Kedua model dipilih karena mampu menangkap ketergantungan temporal dan pola nonlinier yang umum terdapat pada data produksi pertanian. Melalui perbandingan tersebut, penelitian ini diharapkan dapat

mengidentifikasi model yang memberikan hasil prediksi paling akurat.

Evaluasi kinerja model dilakukan menggunakan metrik MAE, MSE, dan RMSE. Selain mengukur akurasi prediksi, penelitian ini juga membandingkan efisiensi proses pelatihan, kompleksitas model, serta kemampuan adaptasi masing-masing model terhadap data uji. Analisis tersebut dilakukan untuk memberikan gambaran yang lebih komprehensif mengenai kelebihan dan keterbatasan model LSTM maupun GRU.

Hasil penelitian ini diharapkan dapat memberikan rekomendasi model *deep learning* yang paling efektif untuk memprediksi produksi padi di Pulau Sumatera. Selain itu, penelitian ini diharapkan menjadi referensi dalam pengembangan sistem prediksi produksi pertanian berbasis kecerdasan buatan dan *deep learning*. Dari sisi penerapan, hasil penelitian ini diharapkan dapat mendukung pemerintah dan pemangku kepentingan dalam menyusun strategi perencanaan produksi serta kebijakan ketahanan pangan yang lebih tepat berbasis data.

2. Metode Penelitian



Gambar 1. Alur Metodologi Penelitian

Pada Gambar 1. Metodologi penelitian (penemuan) yang digunakan dalam studi ini disusun secara sistematis untuk mengembangkan model prediksi produksi padi berbasis data deret waktu. Proses Penemuan dimulai dengan pengumpulan data dari sumber resmi, yang selanjutnya diproses melalui tahap prapemrosesan untuk meningkatkan kualitas data. Tahap ini mencakup penanganan nilai yang hilang, normalisasi, dan transformasi data ke dalam format deret waktu. Setelah itu, dataset dibagi menjadi

data latih dan data uji untuk keperluan pelatihan dan pengujian model. Proses pemodelan dilakukan dengan menggunakan dua pendekatan deep learning, yaitu LSTM) dan GRU, yang dirancang untuk menangkap pola temporal dalam data [8]. Kedua model tersebut kemudian dilatih dan digunakan untuk melakukan prediksi, yang selanjutnya dievaluasi menggunakan metrik kesalahan seperti MAE, MSE, dan RMSE. Hasil evaluasi dari masing-masing model dibandingkan untuk menentukan model dengan kinerja terbaik.

2.1 Pengumpulan Data

Data yang digunakan dalam Penemuan ini merupakan data sekunder yang diperoleh secara online melalui web publikasi Kaggle (<https://www.kaggle.com/datasets/ardikasatria/datasettanamanpadisumatera/>). Dataset ini menggabungkan dua sumber data resmi, yaitu data statistik pertanian dari Badan Pusat Statistik (BPS) dan data iklim yang diambil dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG).

Secara spesifik dataset yang di gunakan mencakup 224 rekaman data observasi. Seluruh data tersebut mempersentasikan kondisi dari delapan provinsi berbeda yang tersebar di pulau Sumatera. Pemilihan data dari wilayah ini relevan, mengingat pulau Sumatera merupakan salah satu Kawasan lumbung padi yang penting bagi ketahanan pangan di Indonesia.

Observasi data yang digunakan memiliki rentang waktu yang panjang, yaitu selama 27 tahun (periode 1993 hingga 2020). Panjangnya deret waktu ini sangat mendukung untuk keperluan analisis tren jangka panjang. Dataset ini juga memuat tujuh fitur utama yang dianalisis, yang rincian lengkapnya disajikan pada Tabel 1. Penggunaan data historis dari instansi-instansi resmi melalui repositori publik ini bertujuan untuk memberikan jaminan yang kuat terhadap validitas dan reliabilitas hasil Penemuan.

Tabel 1. Dataset Penemuan

Nama Fitur	Satuan	Sumber	Deskripsi
Provinsi	-	BPS	Nama provinsi (8 provinsi di Pulau Sumatera)
Tahun	-	BPS	Tahun pencatatan data (1993–2020)
Luas Panen	Hektar (Ha)	BPS	Total area lahan padi yang dipanen per tahun
Produksi (Target)	Ton	BPS	Total hasil produksi padi per tahun (variabel target)
Curah Hujan	mm	BMKG	Rata-rata curah hujan tahunan per Provinsi
Kelembapan	%	BMKG	Rata-rata tingkat kelembapan udara tahunan
Suhu Rata-rata	°C	BMKG	Rata-rata suhu udara tahunan per Provinsi

2.2 Prapemrosesan Data

Prapemrosesan merupakan tahapan yang dilakukan untuk meningkatkan kualitas dan menyiapkan data sebelum digunakan dalam proses pelatihan model. Tahapan ini meliputi penanganan *missing value* dengan teknik imputasi yang sesuai, normalisasi data menggunakan metode *Min-Max Scaling* agar rentang nilai antarvariabel berada pada skala yang seragam, serta transformasi data ke dalam bentuk deret waktu (*time series*). Selanjutnya, data disusun menggunakan metode *sliding window* atau *lag features* untuk membentuk urutan data sebagai masukan (*input*) dan nilai target (*output*) yang akan diprediksi. Data kemudian dibagi menjadi data pelatihan dan data pengujian untuk mengevaluasi kemampuan model dalam melakukan prediksi pada data yang belum pernah dipelajari. Tahapan prapemrosesan tersebut penting dalam penerapan model berbasis *Recurrent Neural Network* (RNN), seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), karena kedua model membutuhkan data dalam bentuk urutan untuk mempelajari pola temporal dan hubungan antarwaktu pada data produksi padi [9].

2.3 Pembagian Data

Dataset dibagi menjadi dua bagian, yaitu data latih dan data uji, dengan rasio 80% dan 20%. Bagian yang memiliki 80% digunakan untuk melatih model, sedangkan bagian yang 20% digunakan untuk mengevaluasi bagaimana baik atau buruk model tersebut bekerja. Jumlah data latih yang lebih besar ini bertujuan agar model bisa lebih baik mempelajari pola, tren, dan karakteristik dari data. Sementara itu, data uji menggunakan 20% sisanya karena jumlah tersebut sudah cukup untuk mengetahui seberapa baik kemampuan model dalam mengenali data yang belum pernah dilihat sebelumnya [9].

Karna data set yang di gunakan merupakan deret waktu (*time series*), maka pembagian dilakukan secara berurutan (*sequential split*) sehingga urutan asli waktu tetap terjaga. Pendekatan *sequential split* dapat mencegah terjadinya kebocoran data (*data leakage*), yang berpotensi menyebabkan overfitting pada model [10].

2.4 Implementasi Model

Penemuan ini menggunakan dua model pembelajaran mesin berbasis jaringan saraf, yaitu LSTM dan GRU. LSTM digunakan untuk memahami hubungan jangka panjang melalui mekanisme sel memori, sedangkan GRU menjadi pilihan lain dengan struktur yang lebih sederhana dan efektif [11]. Model dilatih menggunakan data latih dengan parameter tertentu, kemudian model tersebut digunakan untuk meramalkanhasil pada data uji.

Proses pelatihan model dilakukan dengan menggunakan data latih, dan parameter-parameter yang digunakan diatur ulang melalui proses tuning agar hasil yang diperoleh semakin baik. Implementasi

model mengacu pada pendekatan standar dalam membangun model prediktif yang menggunakan pembelajaran mesin [12].

2.5 Evaluasi Model

Evaluasi kinerja model ini dilakukan untuk mengukur seberapa akurat peramalan yang dihasilkan oleh model dibandingkan dengan data pengamat yang sebenarnya. Pada penelitian ini evaluasi model dilakukan dengan menggunakan tiga metrik kesalahan yang umum digunakan pada analisis regresi dan deret waktu: *MAE*, *MSE*, dan *RMSE* [13]. Kombinasi metrik ini dipilih agar evaluasi mencakup aspek interpretabilitas, sensitivitas terhadap kesalahan besar, dan kesesuaian skala pengukuran.

MAE mengukur rata-rata selisih absolut antara nilai aktual y_i dan prediksi $\hat{y}_i$, sehingga memberikan gambaran langsung tentang besaran kesalahan dalam satuan asli dan relatif tahan terhadap pengaruh penciran. Persamaan *MAE* ditunjukkan pada Persamaan (1):

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

MSE menghitung rata-rata kuadrat selisih dan memberi penalti lebih besar pada kesalahan yang ekstrem; metrik ini berguna ketika kesalahan besar memiliki konsekuensi yang signifikan. Walau satuannya menjadi kuadrat dari unit data asli. Persamaan *MAE* ditunjukkan pada Persamaan (2):

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

RMSE adalah akar kuadrat dari *MSE* sehingga mengembalikan satuan asli sambil mempertahankan kepekaan terhadap outlier. Persamaan *MAE* ditunjukkan pada Persamaan (3):

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

3. Hasil dan Pembahasan

Setelah tahap prapemrosesan data selesai dilakukan, data historis hasil panen padi beserta variabel pendukung yang telah dinormalisasi digunakan sebagai masukan untuk membangun dua model berbasis Recurrent Neural Network (RNN), yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Pada tahap ini, kedua model berhasil dibangun dan dilatih menggunakan data latih yang sama sehingga menghasilkan model yang siap digunakan untuk proses prediksi pada data uji.

Proses pelatihan kedua model dilakukan menggunakan konfigurasi parameter yang sama, yaitu ukuran batch sebesar 16 dan jumlah *epoch* sebanyak 100. Dengan konfigurasi tersebut, proses pelatihan berlangsung hingga seluruh *epoch* selesai dijalankan, sehingga masing-masing model mampu mempelajari pola temporal pada data deret waktu hasil panen padi. Penggunaan parameter yang sama bertujuan agar

perbedaan performa yang diperoleh berasal dari karakteristik arsitektur model, bukan akibat perbedaan pengaturan pelatihan.

Hasil pelatihan menunjukkan bahwa kedua model mampu menghasilkan prediksi terhadap data uji dengan tingkat akurasi yang baik. Berdasarkan hasil evaluasi, model LSTM memperoleh nilai *Mean Absolute Error* (*MAE*) sebesar 0,0522, *Mean Squared Error* (*MSE*) sebesar 0,0082, dan *Root Mean Squared Error* (*RMSE*) sebesar 0,0917. Sementara itu, model GRU menghasilkan nilai *MAE* sebesar 0,0505, *MSE* sebesar 0,0075, dan *RMSE* sebesar 0,0868. Nilai kesalahan yang lebih rendah pada model GRU menunjukkan bahwa model tersebut memiliki kemampuan prediksi yang lebih baik dibandingkan model LSTM pada data hasil panen padi yang digunakan dalam penelitian ini.

Berdasarkan hasil tersebut, dapat diketahui bahwa kedua model berhasil mempelajari pola data deret waktu, namun model GRU memberikan performa yang lebih optimal. Hasil ini menjadi dasar untuk analisis lebih lanjut mengenai perbandingan efektivitas kedua model dalam memprediksi hasil panen padi.

3.1. Perbandingan Arsitektur Model LSTM dan GRU

Dua model pembelajaran mendalam yang digunakan dalam Penemuan ini menerapkan arsitektur bertumpuk yang terdiri dari tiga lapisan berulang. Jumlah unit di setiap lapisan berkurang secara bertahap, yaitu 128 unit di lapisan pertama, 64 unit di lapisan kedua, dan 32 unit di lapisan ketiga. Pola penurunan jumlah unit ini bertujuan agar model dapat mengekstraksi fitur secara bertahap, mulai dari representasi yang lebih kompleks di lapisan awal hingga representasi yang lebih spesifik di lapisan berikutnya, sehingga mampu meningkatkan kemampuan model dalam memahami pola data deret waktu.

Pada lapisan terakhir, kedua model memiliki lapisan Dense yang bertugas sebagai lapisan output untuk menghasilkan nilai prediksi yang terus menerus, sesuai dengan sifat permasalahan regresi, yaitu meramalkan hasil panen padi. Lapisan ini mengubah fitur-fitur yang sudah dipelajari oleh lapisan-lapisan sebelumnya menjadi satu nilai keluaran yang menunjukkan hasil prediksi.

Metode regularisasi menggunakan lapisan *dropout* dengan tingkat *dropout* 20% yang ditempatkan setelah lapisan berulang pertama pada setiap model digunakan untuk meningkatkan kemampuan model untuk menemukan pola baru dan mengurangi kemungkinan terlalu cocok dengan data latihan. Selama pelatihan, lapisan ini secara acak menghilangkan dua puluh persen neuron pada setiap tahap. Ini menghilangkan kebutuhan model untuk *neuron* tertentu. Akibatnya, diharapkan bahwa model dapat memahami representasi data yang lebih kuat dan menghasilkan hasil yang lebih baik ketika digunakan pada data yang belum pernah dilihat sebelumnya.

Walau kedua model memiliki struktur dan parameter yang sama, perbedaannya terletak pada jenis sel berulang yang digunakan. Model LSTM menggunakan tiga pintu, yaitu pintu *input*, pintu *forget*, dan pintu *output*, untuk mengatur aliran informasi dan menjaga ketergantungan yang berlangsung dalam jangka waktu yang lama. Sementara itu, model GRU menggunakan mekanisme yang lebih mudah dengan dua jenis gerbang, yaitu gerbang *update* dan gerbang *reset*, sehingga memiliki jumlah parameter yang lebih sedikit dan proses pelatihan yang lebih efisien. Kesamaan dalam konfigurasi ini memudahkan perbandingan hasil secara objektif, sehingga perbedaan dalam prediksi lebih mencerminkan keunikan masing-masing desain arsitektur, bukan dipengaruhi oleh setting pelatihan. Detail mengenai struktur model LSTM dan GRU disajikan pada Tabel 2 dan Tabel 3.

Tabel 2. Struktur Arsitektur Model LSTM

Layer (type)	Output Shape	Jumlah Parameter
lstm_52 (LSTM)	(None, 1, 128)	69,120
dropout_20 (Dropout)	(None, 1, 128)	0
lstm_53 (LSTM)	(None, 1, 64)	49,408
lstm_54 (LSTM)	(None, 32)	12,416
dense_20 (Dense)	(None, 1)	33

Berdasarkan Tabel 2, model LSTM terdiri atas tiga lapisan *Long Short-Term Memory* dengan jumlah unit masing-masing 128, 64, dan 32, yang disusun secara bertingkat untuk mempelajari pola temporal pada data produksi padi. Lapisan *dropout* sebesar 20% diterapkan setelah lapisan LSTM pertama untuk mengurangi risiko *overfitting*. Selanjutnya, lapisan *Dense* dengan satu *neuron* digunakan sebagai lapisan keluaran untuk menghasilkan nilai prediksi produksi padi. Struktur tersebut menghasilkan jumlah parameter yang dapat dilatih pada setiap lapisan sesuai dengan kompleksitas arsitektur model.

Tabel 3. Struktur Arsitektur Model GRU

Layer (type)	Output Shape	Jumlah Parameter
gru_9 (GRU)	(None, 1, 128)	52,224
dropout_21 (Dropout)	(None, 1, 128)	0
gru_10 (GRU)	(None, 1, 64)	37,248
gru_11 (GRU)	(None, 32)	9,408
dense_21 (Dense)	(None, 1)	33

Berdasarkan Tabel 3, model GRU memiliki tiga lapisan *Gated Recurrent Unit* dengan masing-masing 128, 64, dan 32 unit, diikuti *dropout* sebesar 20% setelah lapisan pertama. Lapisan *Dense* dengan satu *neuron* digunakan untuk menghasilkan nilai prediksi akhir. Dibandingkan dengan model LSTM pada Tabel 2, model GRU memiliki jumlah parameter yang lebih sedikit pada lapisan rekuren. Hal ini menunjukkan bahwa GRU memiliki arsitektur yang lebih sederhana sehingga proses pembelajaran dapat dilakukan dengan kompleksitas komputasi yang relatif lebih rendah, dengan tetap mempertahankan kemampuan dalam mempelajari pola temporal data.

3.2 Perbandingan Metrik Evaluasi

Evaluasi kuantitatif dilakukan dengan menghitung tiga metrik kesalahan standar pada data uji yang belum pernah dilihat oleh model. Hasil lengkap ditampilkan pada Tabel 4.


Tabel 4. Hasil Evaluasi Kinerja Model LSTM dan GRU pada Data Uji

Model	MAE	MSE	RMSE
LSTM	0,0522	0,0082	0,0917
GRU	0,0505	0,0075	0,0868

Berdasarkan hasil pengecekan pada data uji, model GRU terus-menerus menunjukkan hasil prediksi yang lebih baik dibandingkan model LSTM. Nilai ketiga metrik evaluasi tersebut, yaitu MAE, MSE, dan RMSE, semuanya lebih kecil pada model GRU. Model GRU mencapai nilai MAE dengan nilai 0,0505, yang lebih baik dibandingkan model LSTM yang memiliki nilai MAE dengan nilai 0,0522. Hasil ini menunjukkan bahwa rata-rata selisih antara nilai yang diprediksi dan nilai sebenarnya oleh GRU lebih kecil, sehingga tingkat keakuratan prediksi lebih tinggi.


Model GRU menghasilkan nilai 0,0075 pada metrik MSE, sementara model LSTM mendapatkan nilai 0,0082. Nilai MSE yang lebih kecil berarti GRU membuat kesalahan yang lebih sedikit, sehingga model lebih baik dalam mengurangi prediksi yang jauh dari nilai sebenarnya. Temuan ini didukung oleh nilai RMSE, di mana GRU mencapai 0,0868, yang lebih kecil dibandingkan 0,0917 pada LSTM. Karena RMSE memberikan dampak yang lebih berat terhadap kesalahan prediksi yang besar, hasil tersebut menunjukkan bahwa model GRU lebih konsisten dalam membuat prediksi dengan tingkat kesalahan yang tidak terlalu tinggi.

Pola tersebut muncul secara konsisten pada semua metrik evaluasi. Walau perbedaan nilai antara kedua model tidak terlalu besar. Konsistensi ini menunjukkan bahwa model GRU memahami pola waktu data produksi padi lebih baik daripada model LSTM. Arsitektur GRU yang lebih sederhana dengan jumlah parameter yang lebih sedikit akan membuat proses belajar menjadi lebih cepat dan memberikan tingkat kesalahan yang lebih rendah. Namun, ini tidak akan mengurangi kemampuan model untuk memahami hubungan antar data dalam deret waktu [14]. Dengan demikian, dapat disimpulkan bahwa model GRU memiliki kemampuan yang lebih baik untuk memperkirakan hasil panen padi dalam Penemuan ini berdasarkan ketiga metrik penilaian tersebut. Gambar 2 menunjukkan hasil prediksi yang diperoleh dari model LSTM.



Gambar 2. Perbandingan Prediksi vs Aktual Produksi Padi (LSTM)

Keakuratan hasil prediksi dilihat tidak hanya dari nilai evaluasi, tetapi juga dengan membandingkan secara visual nilai sebenarnya dan nilai yang diprediksi pada data uji. Gambar 3 menampilkan hasil prediksi yang diperoleh dari model GRU.



Gambar 3. Perbandingan Prediksi vs Aktual Produksi Padi (GRU)

Pada kedua grafik tersebut, sumbu horizontal menunjukkan urutan indeks dari setiap data uji, sedangkan sumbu vertikal menampilkan nilai produksi padi setelah diubah menjadi bentuk yang lebih sederhana dan mudah dibandingkan. Garis berwarna biru menunjukkan nilai sebenarnya, sedangkan garis berwarna oranye menandai hasil prediksi dari model.

Pada umumnya, kedua model LSTM dan GRU tersebut mampu mengikuti pola perubahan produksi padi dengan cukup baik. Hal ini bisa dilihat dari dekatnya garis prediksi dengan garis aktual di sebagian besar titik yang diamati. Kedua model tersebut berhasil mengidentifikasi tren utama, seperti pola peningkatan dan penurunan produksi yang terjadi sepanjang masa pengamatan. Kemampuan itu menunjukkan bahwa arsitektur RNN berbasis jaringan saraf tiruan efektif untuk memahami hubungan antar waktu dalam data produksi padi yang berbentuk deret waktu.

Terlepas dari itu, hasil visualisasi menunjukkan bahwa kedua model berbeda dalam hal akurasi. Garis prediksi model GRU mengikuti pola data nyata dengan lebih konsisten dan padat dibandingkan model LSTM. Perbedaan tersebut terlihat jelas pada bagian grafik yang mengalami perubahan nilai secara mendadak, seperti pada puncak dan lembah dari fluktuasi produksi. Dalam kondisi tersebut, model LSTM cenderung membuat prediksi yang sedikit lebih jauh dari nilai sebenarnya, sedangkan model GRU tetap bisa menjaga keakuratan prediksi, sehingga hasilnya lebih mendekati nilai sebenarnya.

Berdasarkan hasil temuan secara visual pada Gambar 2 dan 3 sesuai dengan hasil evaluasi kuantitatif yang didapat dari metrik MAE, MSE, dan RMSE. Model GRU mencapai angka MAE dengan nilai 0,0505, MSE dengan nilai 0,0075, dan RMSE dengan nilai 0,0868. Semua nilai tersebut lebih baik dibandingkan model LSTM yang memiliki MAE dengan nilai 0,0522, MSE dengan nilai 0,0082, dan RMSE dengan nilai 0,0917. Nilai kesalahan yang lebih kecil menunjukkan bahwa prediksi yang dibuat oleh model GRU lebih dekat dengan data sebenarnya, sehingga mampu memberikan hasil prediksi yang lebih tepat.

Karakteristik arsitektur model GRU yang lebih sederhana dibandingkan LSTM tampaknya berkontribusi pada keunggulannya dalam Penemuan ini. Berbeda dengan LSTM, GRU hanya menggunakan dua mekanisme gerbang utama, yaitu update dan reset. Struktur yang lebih ringkas mengurangi jumlah parameter yang perlu dipelajari, yang menghasilkan proses pelatihan yang lebih efisien, kebutuhan komputasi yang lebih rendah, dan risiko overfitting dapat diminimalkan. Ini terutama berlaku untuk dataset dengan jumlah data yang relatif terbatas [15].

Kemampuan model untuk menyimpan data masa lalu sangat penting karena karakteristik data produksi padi memiliki ketergantungan antarwaktu, pola waktu, dan perubahan musiman. Dalam hasil Penemuan ini, GRU berhasil memanfaatkan data masa lalu tanpa memperumit model. Kondisi tersebut mempercepat pelatihan, membuat proses belajar lebih stabil, dan meningkatkan kemampuan model untuk meramalkan data baru yang belum pernah dilihat sebelumnya [16].

Adapun berdasarkan hasil Penemuan yang telah dilakukan yang menunjukkan bahwa model GRU mampu memberikan hasil yang cukup baik, bahkan dalam beberapa situasi lebih unggul dibandingkan model LSTM dalam berbagai masalah peramalan deret waktu [17]. Oleh karena itu, berdasarkan analisis visual dan penilaian kuantitatif, model GRU dapat disimpulkan sebagai model yang paling efektif dalam meramalkan produksi padi dalam Penemuan ini karena mampu memberikan prediksi yang lebih tepat, konsisten, dan efisien dibandingkan model LSTM.

4. Kesimpulan

Berdasarkan hasil penelitian, model GRU menunjukkan kinerja yang lebih baik dibandingkan LSTM dalam memprediksi produksi padi di Pulau Sumatera. Hal ini ditunjukkan oleh nilai MAE, MSE, dan RMSE pada GRU yang lebih rendah, yaitu masing-masing 0,0505; 0,0075; dan 0,0868, dibandingkan LSTM sebesar 0,0522; 0,0082; dan 0,0917. Visualisasi hasil prediksi juga menunjukkan bahwa GRU mampu mengikuti pola dan fluktuasi data aktual dengan lebih baik. Meskipun perbedaan kinerja kedua model relatif kecil, GRU memiliki arsitektur yang lebih sederhana dan jumlah parameter yang lebih sedikit sehingga

dapat menjadi alternatif yang efisien untuk peramalan produksi padi.

Kedua model juga mampu mempelajari pola deret waktu dengan baik dan menghasilkan prediksi yang stabil pada data uji. Hasil penelitian ini menunjukkan bahwa pendekatan deep learning, khususnya RNN, berpotensi diterapkan dalam mendukung perencanaan produksi dan pengambilan keputusan di bidang pertanian. Namun, penelitian ini masih terbatas pada penggunaan data historis produksi padi. Penelitian selanjutnya disarankan menambahkan variabel seperti curah hujan, suhu, kelembapan, luas panen, produktivitas lahan, indeks vegetasi, dan faktor sosial-ekonomi, serta membandingkan GRU dan LSTM dengan model lain seperti XGBoost, Transformer, atau TCN untuk memperoleh prediksi yang lebih optimal.

Daftar Rujukan

- [1] Badan Pusat Statistik. (2023). Statistik Indonesia 2023. Jakarta: Badan Pusat Statistik
- [2] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- [3] Khaki, S., Wang, L., & Archontoulis, S. V. (2020). A CNN-RNN framework for crop yield prediction. *Frontiers in Plant Science*, 10, 1750.
- [4] Shastry, S., Hegde, S., & Shenoy, P. D. (2020). Time series forecasting for crop yield prediction using LSTM neural networks. *International Journal of Advanced Science and Technology*, 29(5), 1332–1340.
- [5] Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
- [6] Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*
- [7] Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2nd ed.). California: O'Reilly Media.
- [8] D. DN, Cahyo., A. Sunyoto. 2025. Analisis Perbandingan Klasifikasi dalam Data Mining pada Prediksi Hujan dengan menggunakan Algoritma LSTM dan GRU. *Jurnal Sains dan Informatika*. Vol 11:1 (40-49). Informatika, Fakultas Sains dan Komunikasi Visual, Universitas Cendekia Mitra Indonesia, Yogyakarta, Indonesia.
- [9] Food and Agriculture Organization. (2022). *Rice Market Monitor*. Rome: FAO Official Website
- [10] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Cambridge: MIT Press.
- [11] Hawali, M. L., & Walid. (2025). Pemilihan Neuron LSTM dan LSTM Bayesian Optimization Untuk Prediksi Curah Hujan Bulanan Berbasis Iklim. *Jurnal FASILKOM*, 15(2), 376–382
- [12] Hochreiter, S., & Schmidhuber, J. (1997). Long-Short-Term-Memory. *Neural Computation*, 9(8), 1735–1780.
- [13] Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). Melbourne: Monash University.
- [14] Jeong, J. H., Resop, J. P., Mueller, N. D., Fleisher, D. H., Yun, K., Butler, E. E., Timlin, D. J., Shim, K. M., Gerber, J. S., & Reddy, V. R. (2016). Random forests for global and regional crop yield predictions. *PLoS ONE*, 11(6), e0156571.
- [15] M. A. Sholeh., & R. Hidayat. 2022. Perbandingan Model Lstm Dan Gru Untuk meramalkan Harga Minyak Goreng Di Indonesia. *Edusaintek: Jurnal Pendidikan, Sains dan Teknologi*. Volume 9 Issue 3. Pages 800 – 811
- [16] Yulianto, F. C., & Latifah, N. (2024). Peramalan Penjualan Laptop Menggunakan Metode Long Short-Term Memory (LSTM). *Jurnal FASILKOM*, 14(2). <https://doi.org/10.37859/jf.v14i2.7337>
- [17] Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.