



Prediksi Hasil Panen Padi di Provinsi Bali Menggunakan Metode CNN-LSTM Berdasarkan Data Citra Satelit

Florentina Detrin Dhema^{1*}, Ni Luh Putu Ika Candrawengi²

^{1,2} Universitas Pendidikan Nasional, Indonesia

Email: *florentinadetrin@gmail.com¹, ikacandrawengi@undiknas.ac.id

Korespondensi penulis: florentinadetrin@gmail.com

Abstract. Rice production in Bali Province continues to face pressure due to land conversion and variations in agroecological conditions across districts, necessitating an accurate harvest prediction system as a basis for food planning. This study aims to develop a rice yield prediction model using a CNN-LSTM architecture that integrates Landsat 8 satellite imagery, CHIRPS rainfall data, and BPS Bali Province production data for the period 2018–2025. The data were processed through a series of preprocessing stages and modeled using three CNN-LSTM architecture scenarios evaluated with RMSE and MAE metrics. The results show that Scenario 1 achieved the best performance with an RMSE of 2,567.99, MAE of 1,853.56, and an error percentage of 33.96%. The model was generally able to follow the production trend patterns of rice across all nine districts/cities in Bali Province, although deviations remained under extreme fluctuation conditions. This study demonstrates the potential of integrating remote sensing data and CNN-LSTM architecture in supporting a more adaptive and accurate agricultural prediction system.

Keywords: CHIRPS; CNN-LSTM; Landsat 8; Remote Sensing; Rice Yield Prediction.

Abstrak. Produksi padi di Provinsi Bali terus menghadapi tekanan akibat alih fungsi lahan dan variasi kondisi agroekologi antar kabupaten, sehingga diperlukan sistem prediksi hasil panen yang akurat sebagai dasar perencanaan pangan. Penelitian ini bertujuan membangun model prediksi hasil panen padi menggunakan arsitektur CNN-LSTM yang mengintegrasikan data citra satelit Landsat 8, data curah hujan CHIRPS, dan data produksi BPS Provinsi Bali periode 2018–2025. Data diproses melalui serangkaian tahapan prapemrosesan dan dimodelkan menggunakan tiga skenario arsitektur CNN-LSTM yang dievaluasi dengan metrik RMSE dan MAE. Hasil pengujian menunjukkan bahwa Skenario 1 menghasilkan performa terbaik dengan RMSE 2.567,99, MAE 1.853,56, dan persentase error 33,96%. Model secara umum mampu mengikuti pola tren produksi padi di seluruh sembilan kabupaten/kota di Provinsi Bali, meskipun masih terdapat deviasi pada kondisi fluktuasi ekstrem. Penelitian ini membuktikan potensi integrasi data penginderaan jauh dan arsitektur CNN-LSTM dalam mendukung sistem prediksi pertanian yang lebih adaptif dan akurat.

Kata kunci: CHIRPS; CNN-LSTM; Landsat 8; Penginderaan Jauh; Prediksi Hasil Panen Padi..

1. LATAR BELAKANG

Padi sebagai komoditas pangan, secara khusus memainkan peran kunci sebagai penghasil beras dan sumber pangan pokok bagi lebih dari 270 juta penduduk Indonesia (Budiman & Santu, 2024). Total produksi padi nasional pada tahun 2024 mencapai sekitar 53,14 juta ton/ Gabah Kering Giling (GKG), mengalami penurunan sebesar 838,27 ribu ton dibandingkan produksi tahun 2023 yang mencapai 53,98 juta ton GKG (Badan Pusat Statistik, 2025). Hal ini menunjukkan bahwa sektor pertanian padi di Indonesia masih menghadapi ketidakstabilan akibat berbagai faktor seperti perubahan iklim, serangan organisme pengganggu tanaman, dan kondisi geografis yang beragam di tiap wilayah produksi (Hakim et al., 2025).

Provinsi Bali sebagai salah satu daerah penghasil padi di Indonesia bagian timur juga menghadapi berbagai tantangan dalam menjaga kestabilan produksinya. Berdasarkan data BPS Provinsi Bali tahun 2023, luas panen padi di Bali mencapai 108.847 Ha dengan rata-rata produktivitas 5,84 ton/ha yang masih berfluktuasi antar kabupaten maupun antar musim tanam (Putri, 2025). Perubabhan lahan sawah menjadi lahan non-pertanian di Bali tergolong cukup tinggi, terutama di wilayah yang berkembang secara drastis seperti Kabupaten Badung, Gianyar, dan Denpasar, di mana banyak lahan pertanian berubah menjadi kawasan pariwisata, perumahan, dan infrastruktur komersial (Putri Rangkuti et al., 2025). Penurunan luas lahan produktif ini secara langsung berdampak pada kapasitas produksi padi daerah dan mengancam keberlanjutan ketahanan pangan lokal (Rusmana, 2025; Rhizky & Singgih, 2023).


Berbagai metode telah diterapkan dalam penelitian sebelumnya untuk memprediksi hasil panen padi, di antaranya pendekatan *Artificial Neural Network* (ANN) menerapkan variabel iklim berupa curah hujan, suhu, dan kelembaban (Setiawan Cahyono & Muhammad Imron Rosadi, 2025). Adapun regresi linear tradisional untuk memodelkan hubungan antara luas tanam atau panen dengan hasil produksi padi (Sulistya et al., 2024; Wibawa & Wibisana, 2024). Meskipun pendekatan-pendekatan tersebut memberikan hasil prediksi yang cukup memuaskan, penerapannya masih terbatas pada pemanfaatan data numerik deret waktu. Model yang ada belum memanfaatkan informasi kondisi vegetasi serta karakteristik spasial lahan pertanian yang dapat diperoleh dari citra satelit, belum sepenuhnya merepresentasikan variasi kondisi lahan dan tanaman di setiap wilayah secara komprehensif (Nuraini et al., 2025; Trisadi et al., 2025).

Seiring perkembangan teknologi penginderaan jauh, pemanfaatan citra satelit berperan penting dalam memantau kondisi lahan dan vegetasi, mengidentifikasi perubahan tutupan lahan, serta mendukung analisis produktivitas tanaman secara spasial dan temporal (Ziyana Cholidah, 2024; Kusuma et al., 2025). Citra satelit Landsat 8 mampu menyediakan informasi kondisi permukaan bumi, termasuk kesehatan vegetasi dan karakteristik lahan, secara konsisten dalam cakupan wilayah yang luas untuk pemantauan jangka panjang (Tatisina et al., 2020; Trisadi et al., 2025). Selain itu, data curah hujan dari *Climate Hazards Group InfraRed Precipitation with Station* (CHIRPS) dengan resolusi spasial sekitar 5 kilometer dan resolusi temporal harian hingga bulanan mampu merekam variasi iklim secara konsisten dalam rentang waktu yang panjang (Suryanto et al., 2023).

Arsitektur hibrida *Convolutional Neural Network - Long Short-Term Memory* (CNN-LSTM) hadir sebagai pendekatan yang relevan untuk mengatasi keterbatasan tersebut. CNN berperan mengekstraksi fitur spasial dari citra satelit, sedangkan LSTM memodelkan

ketergantungan temporal antar periode pengamatan (Rajpoot & Chandrakar, 2025). Studi di Distrik Mahabubabad, Telangana, membuktikan arsitektur ini mampu menurunkan RMSE hingga 25% dibandingkan metode pembelajaran mesin klasik pada tanaman padi (Pvs & M, 2025). Penelitian ini hadir dengan mengusulkan pemodel prediksi hasil panen padi melalui integrasi data citra menggunakan arsitektur CNN-LSTM, dengan wilayah studi kasus di Provinsi Bali, yang diharapkan mampu menangkap keragaman kondisi lahan antar kabupaten secara lebih luas.

2. METODE PENELITIAN



Gambar 1. Alur Penelitian

Metode penelitian ini disusun secara sistematis untuk menggambarkan tahapan-tahapan yang dilakukan dalam proses penelitian, mulai dari pengumpulan data, prapemrosesan data, pembangunan model, hingga evaluasi hasil prediksi.

Pengumpulan Data

Pengumpulan data bersumber dari tiga sumber utama yaitu citra satelit Landsat 8, data curah hujan CHIRPS, dan data panen padi BPS Provinsi Bali. Pengolahan citra diawali dengan penetapan *Region of Interest* (ROI) menggunakan *shapefile* batas administratif Bali, dilanjutkan dengan *masking* area sawah dan penerapan masker awan melalui band QA_PIXEL untuk memastikan kualitas piksel. Dari citra periode 2018–2025, diekstraksi dua fitur utama secara bulanan per kabupaten, yaitu NDVI sebagai indikator kondisi vegetasi dan luas lahan sawah aktif dalam satuan hektar. Data curah hujan CHIRPS diagregasi dari resolusi harian ke bulanan dan di-*resample* agar selaras secara spasial dengan data Landsat 8. Ketiga fitur tersebut NDVI, luas lahan sawah, dan curah hujan diekstraksi melalui *Google Earth Engine* sebagai variabel input model CNN-LSTM, sementara data produksi padi bulanan per kabupaten dari BPS dalam satuan ton GKG digunakan sebagai variabel target.

Prapemrosesan Data

Data yang telah terkumpul selanjutnya melewati serangkaian tahapan pra-pemrosesan sebelum dapat digunakan dalam pembangunan model prediksi. Tahapan ini meliputi penggabungan dataset, pembersihan data, normalisasi, pembagian data latih dan uji, serta penerapan teknik sliding window. Keseluruhan proses ini bertujuan untuk memastikan dataset yang masuk ke model sudah bersih, konsisten, dan tersusun dalam format yang sesuai untuk pelatihan CNN-LSTM..

a. Penggabungan Dataset

Dataset dari Google Earth Engine dan data panen BPS digabungkan menggunakan pendekatan *spatio-temporal alignment* berdasarkan dua kunci waktu (bulan dan tahun) serta wilayah (nama kabupaten). Hasilnya adalah satu tabel terintegrasi yang memuat empat variabel utama NDVI, luas lahan sawah, curah hujan, dan produksi panen aktual untuk setiap kabupaten di Provinsi Bali secara bulanan selama 8 tahun.

b. Pembersihan Data

Data yang telah digabungkan melalui proses pembersihan untuk menjamin kualitas dan konsistensinya. *Missing value* ditangani dengan interpolasi linier untuk mempertahankan pola temporal, atau *mean imputation* jika data yang hilang relatif sedikit. Nilai *outlier* yang berada di luar rentang normal seperti NDVI di luar kisaran -1 hingga 1 dihapus atau disesuaikan, dan duplikasi data juga dieliminasi agar setiap kombinasi waktu dan wilayah hanya diwakili oleh satu entri yang valid.

c. Normalisasi Data

Seluruh fitur dinormalisasi menggunakan *Min-Max Normalization* dengan rentang nilai 0 hingga 1. Langkah ini diperlukan karena NDVI, luas lahan sawah, dan curah hujan memiliki skala dan satuan yang sangat berbeda. Tanpa normalisasi, fitur berskala besar berpotensi mendominasi pelatihan dan meredam kontribusi fitur lainnya.

d. Pembagian Data

Dataset yang akhir berjumlah 837 data secara keseluruhan, yang kemudian dibagi menjadi dua bagian sesuai dengan periode waktu masing-masing. Sebanyak 621 data dibagi secara kronologis menjadi (74%) digunakan sebagai data latih (training set) yang mencakup periode Januari 2018 hingga Desember 2023, sedangkan 216 data sisanya (26%) digunakan sebagai data uji (testing set) yang mencakup periode 2024 sampai 2025. Pembagian tanpa pengacakan ini penting untuk menjaga integritas temporal, mengingat data deret waktu memiliki ketergantungan antar periode. Data uji sepenuhnya dipisahkan

dari proses pelatihan agar evaluasi mencerminkan kemampuan generalisasi model yang sesungguhnya.

e. Sliding Window

Teknik *sliding window* diterapkan untuk membentuk sekuens temporal sebagai masukan model CNN-LSTM. Jendela waktu digeser secara bertahap sepanjang deret waktu, di mana setiap posisi menghasilkan satu sampel berisi riwayat T bulan untuk memprediksi produksi bulan berikutnya. Penelitian ini menguji tiga variasi ukuran window (3, 6, dan 12 bulan), dan ukuran optimal dipilih berdasarkan nilai RMSE dan MAE terkecil. Output akhir proses ini berupa tensor berformat **(N, T, F)** jumlah sampel, panjang window, dan jumlah fitur yang menjadi struktur masukan resmi bagi model.

Pemodelan CNN-LSTM

Model CNN-LSTM dibangun dengan memanfaatkan keunggulan masing-masing komponen, di mana CNN berperan mengekstraksi pola spasial dari data citra satelit seperti pola vegetasi dan variasi spektral, sementara LSTM bertugas mengenali ketergantungan temporal jangka panjang antar periode tanam sehingga kombinasi keduanya mampu mengoptimalkan prediksi hasil panen padi. Pada lapisan konvolusi, CNN mengekstraksi pola lokal antar fitur dari data deret waktu berformat tensor **(N, T, F)** menggunakan operasi konvolusi yang dirumuskan sebagai berikut:

$$h_t = \text{ReLU}(W_c \times x_t + b_c) \quad (1)$$

keterangan:

h_t = Output atau hasil aktivasi pada waktu ke-t

ReLU = Fungsi aktivasi Rectified Linear Unit

X_t = Data masukan pada waktu t

W_c = Bobot filter konvolusi

B_c = Bias.

Fungsi aktivasi ReLU diterapkan untuk memperkenalkan non-linearitas agar model mampu menangkap hubungan kompleks antar fitur. Selanjutnya, lapisan Max Pooling mereduksi dimensi feature map dengan mempertahankan nilai maksimum dari setiap jendela pooling, menjadikan model lebih fokus pada pola signifikan sekaligus meminimalkan risiko overfitting. Output CNN kemudian diteruskan ke lapisan LSTM yang memodelkan ketergantungan temporal melalui mekanisme gating, yaitu forget gate, input gate, dan output gate, yang secara matematis dirumuskan sebagai berikut:

a. Forget get

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

b. Input Gate

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

c. Candidate Cell State

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

d. Cell State

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

e. Output Gate

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

f. Hidden State

$$h_t = O_t \cdot \tanh(C_t) \quad (7)$$

Keterangan:

x_t = Masukan pada waktu ke-t

h_{t-1} = Hidden state pada waktu sebelumnya

C_{t-1} = Cell state sebelumnya

W = Bobot (weight)

b = Bias

σ = Aktivasi sigmoid

$\tanh$ = Aktivasi *hyperbolic tangent*

Melalui mekanisme ini, model mampu mengingat pola musiman yang relevan sekaligus melupakan informasi yang tidak diperlukan. Pada tahap akhir, output LSTM diteruskan ke lapisan Dense yang menghasilkan satu nilai numerik prediksi produktivitas padi dalam satuan ton per hektar, dengan fungsi *loss Mean Squared Error* (MSE) sebagai acuan optimasi selama pelatihan model.

Evaluasi

Setelah pelatihan selesai, model CNN-LSTM dievaluasi menggunakan data pengujian dengan dua metrik utama yang saling melengkapi, yaitu RMSE dan MAE. RMSE digunakan untuk mendeteksi kesalahan prediksi yang ekstrem karena lebih sensitif terhadap penyimpangan besar dari nilai aktual, yang dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Dimana:

$RMSE = \text{Root Mean Square Error}$

$N = \text{Total data pengamatan}$

$y_i = \text{Nilai aktual pada data}$

$\hat{y}_i = \text{Nilai hasil prediksi model}$

$(y_i - \hat{y}_i)^2 = \text{Kuadrat selisih antara nilai aktual dan prediksi}$

Sementara MAE menghasilkan gambaran rata-rata kesalahan prediksi secara keseluruhan tanpa memberikan bobot lebih pada kesalahan besar, yang dirumuskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \hat{y}_i| \quad (9)$$

Dimana:

$MAE = \text{Mean Absolute Error}$

$N = \text{Jumlah Data}$

$y_i = \text{Nilai aktual pada data}$

$\hat{y}_i = \text{Nilai hasil prediksi}$

Kombinasi kedua metrik ini memungkinkan penilaian performa model secara menyeluruh, baik dari sisi konsistensi prediksi secara umum maupun kemampuannya dalam menghindari kesalahan prediksi yang ekstrem pada data hasil panen padi.

3. HASIL DAN PEMBAHASAN

Bagian ini akan memaparkan data kuantitatif yang diperoleh dari pembangunan model CNN-LSTM.

Hasil Pemodelan CNN-LSTM

Penelitian ini merancang tiga skenario arsitektur CNN-LSTM dengan tingkat kompleksitas yang berbeda untuk menemukan konfigurasi model yang paling optimal dalam memprediksi produksi padi per kabupaten di Provinsi Bali. Skenario 1 menggunakan satu lapisan Conv1D dengan 64 filter, satu lapisan LSTM 128 unit dengan *Dropout*, dan dua lapisan Dense (32 dan 1 unit), dengan total 104.193 parameter. Skenario 2 merupakan arsitektur paling ringan dengan satu lapisan Conv1D 80 filter, satu lapisan LSTM 100 unit tanpa *Dropout*, dan dua lapisan Dense (32 dan 1 unit), dengan total 77.185 parameter. Skenario 3 adalah arsitektur paling kompleks dengan dua lapisan Conv1D bertingkat (128 dan 64 filter), dua lapisan LSTM (128 dan 64 unit) dengan *Dropout*, dan dua lapisan Dense (64 dan 1 unit), dengan total 172.481 parameter. Hasil pemodelan dari setiap skenario ditampilkan pada gambar berikut:

Model: "sequential_1"

Layer (type)	Output Shape	Param #
conv1d_1 (Conv1D)	(None, 5, 64)	1,216
max_pooling1d_1 (MaxPooling1D)	(None, 5, 64)	0
lstm_1 (LSTM)	(None, 128)	98,816
dropout_1 (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 32)	4,128
dense_3 (Dense)	(None, 1)	33

Total params: 104,193 (407.00 KB)
Trainable params: 104,193 (407.00 KB)
Non-trainable params: 0 (0.00 B)

Model: "sequential_2"

Layer (type)	Output Shape	Param #
conv1d_2 (Conv1D)	(None, 5, 80)	1,520
max_pooling1d_2 (MaxPooling1D)	(None, 5, 80)	0
lstm_2 (LSTM)	(None, 100)	72,400
dense_4 (Dense)	(None, 32)	3,232
dense_5 (Dense)	(None, 1)	33

Total params: 77,185 (301.50 KB)
Trainable params: 77,185 (301.50 KB)
Non-trainable params: 0 (0.00 B)


Model: "sequential_3"

Layer (type)	Output Shape	Param #
conv1d_3 (Conv1D)	(None, 4, 128)	3,584
max_pooling1d_3 (MaxPooling1D)	(None, 4, 128)	0
conv1d_4 (Conv1D)	(None, 3, 64)	16,448
max_pooling1d_4 (MaxPooling1D)	(None, 3, 64)	0
lstm_3 (LSTM)	(None, 3, 128)	98,816
dropout_2 (Dropout)	(None, 3, 128)	0
lstm_4 (LSTM)	(None, 64)	49,408
dropout_3 (Dropout)	(None, 64)	0
dense_6 (Dense)	(None, 64)	4,160
dense_7 (Dense)	(None, 1)	65

Total params: 172,481 (673.75 KB)
Trainable params: 172,481 (673.75 KB)
Non-trainable params: 0 (0.00 B)

Gambar 2. Hasil 3 Skenario Pemdoelan CNN-LSMT

Perbedaan kompleksitas ini dirancang untuk menguji apakah penambahan lapisan dan parameter secara signifikan meningkatkan kemampuan model dalam menangkap pola spasial dan temporal data produksi padi. Untuk mengevaluasi proses pelatihan dan menentukan titik konvergensi optimal, setiap model CNN-LSTM divisualisasikan melalui grafik *loss function* yang menampilkan perbandingan training *loss* dan validation *loss* pada setiap *epoch*. Grafik *loss function* dapat dilihat pada gambar berikut:



Gambar 3. Grafik Loss Funtion Tiga Model CNN-LSTM

Ketiga model menunjukkan tren penurunan *loss* yang konsisten dan berhasil mencapai konvergensi. Model final yang digambar urutan pertama menghasilkan pelatihan paling stabil dengan *training loss* dan *validation loss* yang berdekatan menunjukkan epoch ke-67 tanpa indikasi *overfitting*. Model Variasi 2 konvergen lebih cepat dengan kurva validasi yang lebih fluktuatif akibat tidak adanya *Dropout*. Skenario 3 menunjukkan *validation loss* yang konsisten berada di bawah *training loss*, yang merupakan efek wajar dari mekanisme *Dropout* yang aktif selama pelatihan.

Hasil Pengujian Model

Masing-masing model tersebut dibuatkan pengujian RMSE dan MAE, untuk melihat seknario mana yang akan digunakan. Hasil pengujiaannya disajikan pada tabel berikut ini:


Tabel 1. Hasil Pengujian 3 Model CNN-LSTM

No	Skenario	RMSE	MAE	Presentase Error
1.	Model 1	2567.99	1853.56	33.96 %
2.	Model 2	2775.45	2084.51	38.19 %
3.	Model 3	2972.49	2246.79	41.17


Skenario 1 menghasilkan performa terbaik dengan RMSE 2.567,99, MAE 1.853,56, dan persentase error 33,96%. Hasil ini menunjukkan pola terbalik antara kompleksitas arsitektur dan performa model skenario dengan parameter terbanyak justru menghasilkan error tertinggi, sedangkan skenario dengan kompleksitas menengah memberikan hasil terbaik. Selisih antara RMSE dan MAE yang tidak terlalu jauh pada Skenario 1 dibandingkan skenario lainnya juga mengindikasikan bahwa Skenario 1 memiliki distribusi kesalahan yang lebih stabil dan merata, bukan hanya baik secara rata-rata tetapi juga lebih konsisten dalam menghindari kesalahan yang sangat besar..

Perbandingan Plot Aktual dan Hasil Prediksi


Hasil prediksi model CNN-LSTM dari skenario terbaik divisualisasikan dalam bentuk grafik perbandingan antara nilai aktual dan nilai prediksi produksi padi untuk periode data uji Juli 2024 hingga Desember 2025 pada seluruh sembilan kabupaten/kota di Provinsi Bali yang ditampilkan pada gambar berikut ini:




Gambar 4. Hasil Perbandingan di Kab. Klungkung dan Karangasem




Gambar 5. Hasil Perbandingan di Kab. Jemberana



Gambar 6. Hasil Perbandingan di Kab. Buleleng dan Bangli



Gambar 7. Hasil Perbandingan di Kota Denpasar dan Kab. Badung



Gambar 8. Hasil Perbandingan di Kab. Tabanan dan Gianyar

Hasil visualisasi perbandingan nilai aktual dan prediksi pada periode Juli 2024 hingga Desember 2025 menunjukkan bahwa model CNN–LSTM Skenario 1 secara umum mampu mengikuti pola tren dan fluktuasi produksi padi di seluruh sembilan kabupaten/kota di Provinsi Bali. Kabupaten Tabanan, Gianyar, Badung, dan Jembrana menunjukkan hasil yang relatif baik, meskipun model mengalami kesulitan pada titik-titik lonjakan produksi yang ekstrem. Kabupaten Buleleng, Karangasem, dan Klungkung mencatat deviasi lebih besar pada bulan-bulan tertentu, sementara Kabupaten Bangli dan Kota Denpasar yang berskala produksi lebih kecil menunjukkan pola prediksi yang cukup mengikuti tren tetapi model sesekali menghasilkan prediksi yang melampaui nilai aktual. Khususnya untuk Kota Denpasar, rendahnya luas lahan sawah aktif yang tersisa akibat pesatnya alih fungsi lahan menjadikan variasi produksi bulanannya sangat tidak stabil dan sulit diprediksi berdasarkan pola historis, karena sedikit saja perubahan pada luas tanam atau kondisi lahan akan berdampak proporsional besar terhadap total produksi. Secara keseluruhan, deviasi yang terjadi umumnya disebabkan oleh fluktuasi ekstrem yang dipengaruhi faktor-faktor seperti anomali cuaca, serangan hama, atau perubahan luas tanam yang tidak tercermin dalam fitur model.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil membangun model prediksi hasil panen padi di Provinsi Bali menggunakan arsitektur CNN-LSTM berbasis integrasi data citra satelit Landsat 8, data curah hujan CHIRPS, dan data produksi BPS. Dari tiga skenario yang diuji, Skenario 1 menghasilkan performa terbaik dengan RMSE 2.567,99, MAE 1.853,56, dan persentase error 33,96%,

membuktikan bahwa arsitektur yang lebih sederhana belum tentu kalah dibanding yang lebih kompleks. Model secara umum mampu mengikuti pola tren produksi padi di seluruh sembilan kabupaten/kota di Provinsi Bali, meskipun masih terdapat deviasi pada titik fluktuasi ekstrem yang dipengaruhi faktor anomali cuaca, serangan hama, dan perubahan luas tanam.

Untuk meningkatkan akurasi model, penelitian selanjutnya disarankan menambahkan parameter input yang lebih beragam seperti data suhu udara, kelembaban tanah, indeks vegetasi tambahan seperti EVI atau LSWI, serta data serangan organisme pengganggu tanaman (OPT). Eksplorasi arsitektur *deep learning* lain yang canggih juga dapat dipertimbangkan untuk menangkap pola temporal secara lebih efektif, serta perluasan wilayah studi ke provinsi lain guna meningkatkan kemampuan generalisasi model.

DAFTAR REFERENSI

- Badan Pusat Statistik. (2025). *Luas Panen dan Produksi Padi di Indonesia 2024 (Angka Tetap)* (No. 15/02/Th. XXVIII, 3 Februari 2025). Badan Pusat Statistik. <https://www.bps.go.id/id/pressrelease/2025/02/03/2414/pada-2024--luas-panen-padi-mencapai-sekitar-10-05-juta-hektare-dengan-produksi-padi-sebanyak-53-14-juta-ton-gabah-kering-giling--gkg--.html>
- Budiman, N. D., & Santu, L. (2024). KAJIAN STRATEGI DAN KEBIJAKAN PEMERINTAH INDONESIA DALAM MENCAPAI TARGET SWASEMBADA BERAS. *JURNAL PERTANIAN CEMARA*, 21(2), 125–136. <https://doi.org/10.24929/fp.v21i2.3888>
- Hakim, D. R., Rahmiwati, A., Flora, R., & Novrikasari. (2025). Menjelajahi Dinamika Pangan di Era Perubahan Iklim Terhadap Dampak di Indonesia dan Proyeksi Masa Depan: A Systematic Review. *Ranah Research : Journal of Multidisciplinary Research and Development*, 7(3), 1703–1720. <https://doi.org/10.38035/rj.v7i3.1411>
- Nuraini, D., Violina, D., Anamisa, D. R., Khotimah, B. K., Jauhari, A., & Mufarroha, F. A. (2025). Prediksi Hasil Panen Padi dengan Metode Multiple Linear Regression dan Particle Swarm Optimization untuk Meningkatkan Produksi Padi di Madura. *JUSIFOR : Jurnal Sistem Informasi Dan Informatika*, 4(1), 1–8. <https://doi.org/10.70609/jusifor.v4i1.5857>
- Putri, N. (2025). Faktor Penentu Alih Fungsi Lahan Sawah di Tingkat Rumah Tangga Petani dan Wilayah di Provinsi Bali. *Journal of Industrial and Syariah Economics*, 3(1), 29–39. <https://doi.org/10.63321/jise.v3i1.131>
- Putri Rangkuti, S., Pratama, A., & Putra Fhonna, R. (2025). PREDIKSI PRODUKSI BERAS UNTUK MENDUKUNG KETAHANAN PANGAN DI KABUPATEN ACEH UTARA MENGGUNAKAN METODE SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 7136–7143. <https://doi.org/10.36040/jati.v9i4.14456>

- Pvs, G., & M, A. (2025). Yield Estimation of Paddy and Maize Crops in Mahabubabad District Using Sentinel-2 Data with a Hybrid Convolutional Neural Network-Lstm Model. *International Journal of Environmental Sciences*, 11(7s), 1218–1227. <https://doi.org/10.64252/g1ef4252>
- Rajpoot, S., & Chandrakar, O. (2025). A hybrid CNN-LSTM deep learning framework for enhanced crop yield prediction using spatial-temporal agricultural data. *International Journal of Statistics and Applied Mathematics*, 10(12S), 01–09. <https://doi.org/10.22271/math.2025.v10.i12Sa.2200>
- Rusmana, I. P. E. (2025). Pengembangan Kapasitas Subak dalam Menghadapi Tantangan Pertanian Modern dan Perubahan Iklim di Bali. *Jurnal Abdimas Kartika Wijayakusuma*, 6(2), 1. <https://doi.org/10.26874/jakw.v6i2.540>
- Setiawan Cahyono & Muhammad Imron Rosadi. (2025). Penerapan Artificial Neural Network untuk Prediksi Produksi Padi di Sumatera. *Jurnal Informatika Polinema*, 11(4), 487–494. <https://doi.org/10.33795/jip.v11i4.7727>
- Sulistya, Y. I., Musdholifah, A., Sapuletea, C., Br Bangun, E. T., Hamda, H., Anjani, S., & Septiadi, A. D. (2024). Prediction and Analysis of Rice Production and Yields Using Ensemble Learning Techniques. *ILKOM Jurnal Ilmiah*, 16(2), 115–124. <https://doi.org/10.33096/ilkom.v16i2.1948.115-124>
- Suryanto, J., Amprin, & Anisum. (2023). VALIDASI CURAH HUJAN HARIAN CHIRPS PRECIPITATION SATELLITE PRODUCT DI PROVINSI KALIMANTAN BARAT. *Jurnal Ilmiah Rekayasa Pertanian Dan Biosistem*, 11(1), 73–88. <https://doi.org/10.29303/jrpb.v11i1.442>
- Tatisina, N. N., Siahaya, W. A., & Haumahu, J. P. (2020). Transformasi Indeks Vegetasi Citra LANDSAT 8 OLI untuk Pemetaan Musim Tanam pada Lahan Sawah di Kabupaten Buru, Provinsi Maluku. *JURNAL BUDIDAYA PERTANIAN*, 16(2), 197–205. <https://doi.org/10.30598/jbdp.2020.16.2.197>
- Ziyana Cholidah, N. N. (2024). Pemanfaatan Penginderaan Jauh Untuk Pemetaan Alih Fungsi Lahan Sawah di Kabupaten Nganjuk. *Jurnal Geosains Dan Remote Sensing*. <https://doi.org/10.23960/jgrs.ft.unila.203>
- Kusuma, K., et al. (2025). Pengembangan *conceptual design* pengelolaan air di perkebunan kelapa sawit (Studi kasus PT XYZ Kalimantan Timur). *Flora: Jurnal Kajian Ilmu Pertanian dan Perkebunan*, 2(3). <https://doi.org/10.62951/flora.v2i3.467>
- Trisadi, D., et al. (2025). Long-term monitoring of shoreline changes in Cilacap Regency, Central Java, based on Landsat 8 imagery (2016–2025). *International Journal of Mechanical, Electrical and Civil Engineering*, 2(4). <https://doi.org/10.61132/ijmecie.v2i4.354>
- Wibawa, A. C., & Wibisana, H. (2024). Mapping shoreline changes in the Situbondo coastline for a period of 10 years using Landsat 8 satellite image data. *International Journal of Mechanical, Electrical and Civil Engineering*, 1(4). <https://doi.org/10.61132/ijmecie.v1i4.44>
- Rhizky, M. A., & Singgih, M. (2023). Mengoptimalkan hasil panen padi menggunakan metode *goal programming* dengan pengaplikasian nutrisi PGPR: Studi kasus Desa Pappungan, Kecamatan Kanigoro, Kabupaten Blitar. *Jurnal Kendali Teknik dan Sains*, 1(3). <https://doi.org/10.59581/jkts-widyakarya.v1i3.609>