

PREDIKSI CURAH HUJAN HARIAN KABUPATEN MANOKWARI BERBASIS LONG SHORT-TERM MEMORY

Elohansen Padang¹, Aries A. Subgan², Kwasti K. Kardiputra³, Tobias T Tukan⁴

^{1,2,3,4} Program Studi Fisika, FMIPA, Universitas Papua

e.padang@unipa.ac.id

ABSTRACT:An accurate daily rainfall prediction in tropical regions such as Manokwari Regency, West Papua Province, is critically important yet challenging due to high rainfall variability and complex climatic influences, including ENSO, IOD, and orographic effects. This study develops a Long Short-Term Memory (LSTM) model for daily rainfall prediction in Manokwari Regency, utilizing bias-corrected historical data from BMKG (2020-2024) and reanalysis ERA5 ECMWF Data (2005-2024) through Random Forest correction. Four LSTM architectures (Vanilla LSTM, Stacked LSTM, Hybrid CNN-LSTM, and Bidirectional LSTM (BiLSTM)) were evaluated with optimized hyperparameters (window size 30/60 days, batch size 32/64, learning rate 0.001), assessed using root mean squared error (RMSE) and mean absolute error (MAE) metrics. Results demonstrate that the BiLSTM model with two layers (64-32 nodes) and 60-day window size achieved superior performance (RMSE 10.55 mm/day, MAE 6.49 mm/day) compared to other architectures. While the LSTM model effectively captured seasonal rainfall patterns, deviations occurred during extreme events, potentially due to limitations in modeling long-term rainfall dynamics. These findings suggest LSTM's strong potential for early warning systems and water resource management in high-variability rainfall regions.

Keywords: prediction, rainfall, LSTM, Manokwari Regency

PENDAHULUAN

Curah hujan merupakan salah satu variabel penting dalam siklus hidrologi. Curah hujan berpengaruh dalam ketersediaan air, pertanian, ekosistem, kehidupan manusia, serta mitigasi bencana seperti banjir dan kekeringan (Satyamurty dkk., 2010). Curah hujan dengan variabilitas yang tinggi dapat menyebabkan terjadinya bencana seperti tanah longsor, banjir, bahkan kekeringan, sehingga prediksi yang akurat menjadi sangat penting dalam rangka mitigasi risiko (World Meteorological Organization [WMO], 2021). Pada wilayah beriklim tropis, seperti Indonesia, variabilitas curah hujan sangat dipengaruhi oleh fenomena El Niño-Southern Oscillation (ENSO) dan Indian Ocean Dipole

(IOD) sehingga membutuhkan pemahaman yang mendalam untuk memperoleh prediksi curah hujan yang akurat (Cahyarini & Henrizan, 2018).

Kabupaten Manokwari, Papua Barat, memiliki karakteristik curah hujan yang unik karena sangat dipengaruhi oleh pola muson yang umum di Indonesia (As-syakur dkk., 2013) dan efek orografis lokal yang disebabkan oleh keberadaan Pegunungan Arfak. Gugusan pegunungan ini memaksa udara lembab naik akibatnya terjadi pendinginan dan kondensasi sehingga meningkatkan curah hujan di wilayah ini (Harjupa dkk., 2021). Data Historis curah hujan harian di Kabupaten Manokwari menunjukkan fluktuasi yang signifikan dengan intensitas tinggi pada bulan Desember- Maret (BMKG, 2023) berpotensi memicu

bencana hidrometeorologis seperti banjir dan tanah longsor (Mondiana dkk., 2022). Namun demikian, studi tentang prediksi curah hujan di kabupaten ini masih terbatas, terutama dengan menggunakan pendekatan kecerdasan buatan (AI).

Prediksi curah hujan tradisional umumnya berbasis metode statistik seperti regresi linear dan ARIMA (*Autoregressive Integrated Moving Average*) cukup efektif untuk prediksi curah hujan jangka pendek namun kurang optimal untuk prediksi jangka panjang karena kompleksitas pola hujan (Ramli dkk., 2019). Kemudian, model prediksi berbasis Fisika, seperti WRF (*Weather Research and Forecasting Model*), dan ECMWF (*European Centre for Medium-Range Weather Forecasts*), mensimulasikan proses atmosfer melalui persamaan matematis (Herjazi dkk., 2013). Disisi lain, pendekatan terkini memanfaatkan kecerdasan buatan (AI), khususnya Long Short-Term Memory (LSTM). Model ini memiliki kemampuan untuk menangkap hubungan nonlinear antar variabel cuaca dengan lebih akurat (Asanjan dkk., 2018). Dalam prediksi curah hujan, model LSTM telah terbukti lebih akurat dibanding metode tradisional karena kemampuannya untuk memproses pola kompleks dari data cuaca (Asanjan dkk., 2018; Kim dkk., 2017).

Beberapa penelitian yang telah mengaplikasikan model LSTM untuk prediksi curah di berbagai wilayah Indonesia, seperti di Jawa dan Sumatera (Badriyah dkk., 2022; Sudriani dkk., 2019). Akan tetapi, untuk wilayah Papua Barat, khususnya Kabupaten Manokwari, masih sangat jarang bahkan belum ada. Oleh karena itu, pada penelitian ini akan dikembangkan model LSTM untuk memprediksi curah hujan harian di Kabupaten Manokwari

dengan memanfaatkan data historis BMKG dan data reanalysis ERA5 ECWMF. Empat varian arsitektur LSTM, yaitu Vanilla LSTM, Stacked LSTM, Hybrid CNN-LSTM, dan Bidirectional LSTM akan diuji kemampuannya sebagai model prediksi curah hujan harian di Kabupaten Manokwari. Hasil penelitian ini diharapkan dapat menjadi referensi bagi para pemangku kebijakan dalam melakukan perencanaan mitigasi bencana dan manajemen sumber daya air.

METODE PENELITIAN

Data dan Prapemrosesan Data

Penelitian ini dilakukan untuk prediksi curah hujan harian di Kabupaten Manokwari, Provinsi Papua Barat. Data curah hujan diperoleh dari dua sumber berbeda, yaitu: Pertama, data curah hujan harian dari BMKG (Badan Meteorologi, Klimatologi, dan Geofisika). Data ini diperoleh untuk periode tahun 2020 hingga 2024 dan digunakan sebagai data observasi atau data acuan. Data dapat diperoleh secara online melalui situs: <https://dataonline.bmkg.go.id/>. Kedua, data curah hujan harian dari ECWMF (*European Centre for Medium-Range Weather Forecasts*). Data ini mencakup periode yang lebih panjang, yaitu dari tahun 2005 hingga 2024 dan akan digunakan sebagai prediktor dalam pemodelan. Data curah hujan harian ECMWF ini merupakan hasil reanalisis ERA5. Reanalisis sendiri merupakan rekonstruksi kondisi atmosfer, daratan, dan laut dalam suatu periode waktu tertentu dengan menggabungkan data observasi dari berbagai sumber menggunakan model atmosfer modern dan asimilasi data. Data dapat diperoleh secara online melalui situs: <https://cds.climate.copernicus.eu>.

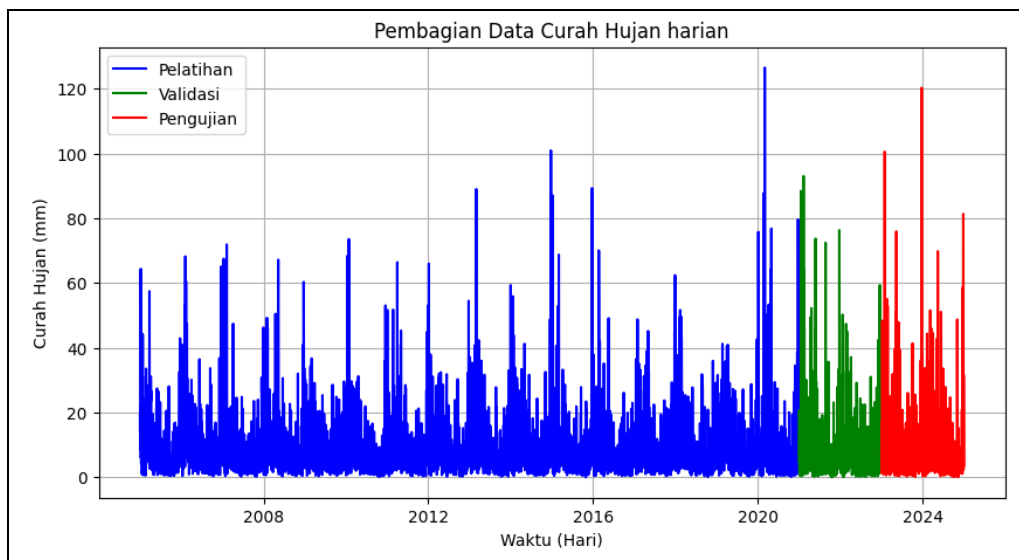
Sebelum digunakan dalam pemodelan, data curah hujan harian dari ECWMF dikoreksi terlebih dahulu menggunakan data BMKG sebagai referensi. Metode koreksi yang digunakan dalam penelitian ini adalah model Random Forest (RF), yang dapat menangkap pola hubungan nonlinear antara data ECWMF dan BMKG (Zarei dkk., 2021). Tahapan koreksi dilakukan dalam empat tahapan, meliputi (i) pengumpulan dan penyelarasan data ECWMF dengan data BMKG pada rentang waktu yang tersedia, (ii) menggunakan data BMKG sebagai target dan data ECWMF sebagai fitur dalam model RF. (iii) Pelatihan model RF dengan validasi silang untuk meningkatkan akurasi koreksi, dan (iv) mengaplikasikan model RF pada data ECWMF untuk menghasilkan data koreksi yang lebih representatif dengan kondisi sebenarnya.

Selanjutnya, data curah hujan harian ECWMF yang telah dikoreksi digunakan sebagai dataset utama dalam pelatihan model Long Short-Term Memory (LSTM). Pembagian dataset

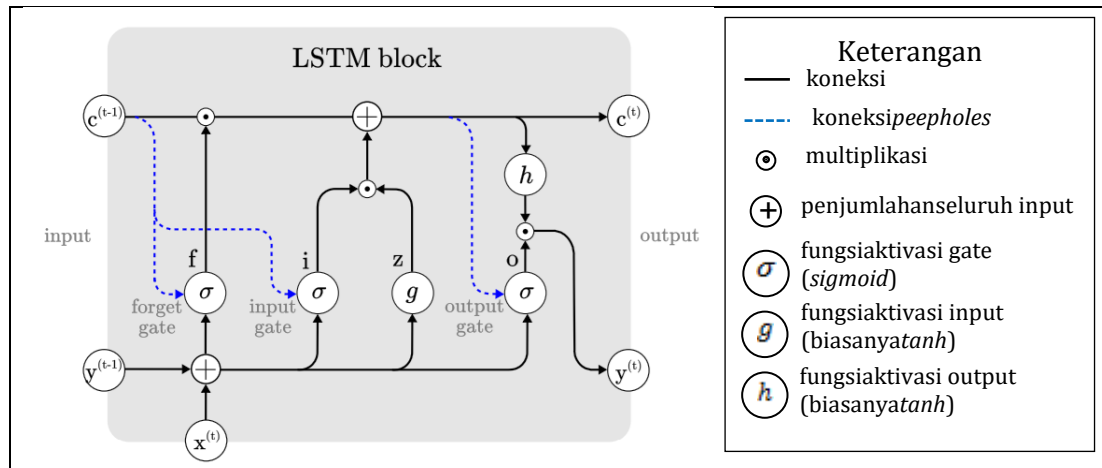
dilakukan dengan skema 80% untuk pelatihan (*training set*), yaitu data curah hujan harian dari 1 Januari 2005 hingga 31 Desember 2020, 10% untuk validasi (*validation set*), yaitu data curah hujan harian dari 1 Januari 2021-31 Desember 2022, dan 10% untuk pengujian (*test set*), yaitu data curah hujan harian sejak 1 Januari 2023 - 31 Desember 2024). Pembagian ini bertujuan untuk memastikan agar model tidak mengalami overfitting serta dapat melakukan generalisasi dengan baik terhadap data baru curah hujan. Gambar 1. Menampilkan grafik pembagian data pelatihan, validasi, dan pengujian.

Arsitektur dan prinsip kerja LSTM

Dalam penelitian ini, model Long Short-Term Memory (LSTM) digunakan sebagai model untuk memprediksi curah hujan harian Kabupaten Manokwari. LSTM merupakan jenis Recurrent Neural Network (RNN) yang dirancang untuk menangani data sekuensial, seperti data runtun waktu dan teks, dengan memori jangka panjang dan jangka pendek.



Gambar 1. Grafik pembagian data curah hujan harian Kabupaten Manokwari untuk pelatihan, validasi, dan pengujian model LSTM



Gambar 2. Arsitektur blok vanilla LSTM (Houdt dkk., 2020)

Model LSTM ini mampu mengatasi masalah ledakan gradien (*vanishing gradient problem*) yang seringkali terjadi pada RNN konvensional, sehingga mampu menangkap pola jangka panjang dalam data.

Komponen utama dari model LSTM terdiri dari *cell state* (C_t), *forget state* (f_t), *input gate* (i_t), dan *output gate* (o_t) (Gambar 2). Prinsip kerja dari blok LSTM dapat dijelaskan sebagai berikut (Houdt dkk., 2020):

- *Cell state* (C_t) bertindak sebagai jalur memori utama yang dapat menyimpan atau membuang informasi berdasarkan kebutuhan. Aliran informasi ini dikendalikan oleh tiga gerbang utama.
- *Forget state* (f_t) berfungsi untuk memutuskan apakah suatu informasi dari waktu sebelumnya perlu dibuang atau disimpan. Penentuan apakah informasi perlu dibuang atau disimpan dihitung menggunakan fungsi sigmoid sebagai berikut.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$
- *Input gate* (i_t) berguna untuk menentukan informasi baru yang akan ditambahkan ke dalam *cell state*. Penentuan informasi baru yang akan ditambahkan dilakukan dengan

dua langkah, yaitu:

Kandidat memori baru (\tilde{C}_t):

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2)$$

Pemilihan informasi (i_t):

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

Pembaruan memori baru:

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

- *Output gate* (o_t) berfungsi untuk menentukan keluaran (output) dari sel LSTM. Keluaran LSTM dihitung dengan fungsi sigmoid berikut.

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

dan keluaran akhir adalah,

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

dengan W adalah bobot (weights) yang terkait dengan $x(t)$, $y^{(t-1)}$ dan $c^{(t-1)}$, σ adalah fungsi logistik untuk fungsi aktivasi gerbang (gate), dan h adalah fungsi tangen hiperbolik yang digunakan sebagai fungsi aktivasi blok *input* dan keluaran *output*.

LSTM sebagai model prediksi Curah Hujan Harian

Alur kerja dari model LSTM dalam prediksi curah hujan diawali dengan menginput data curah hujan historis, dalam hal ini data curah hujan ECWMF. Selanjutnya, memroses urutan data. Pada tahap ini, model menganalisis pola curah hujan dengan

memperbarui memori keadaan melalui *forget gate*, *input gate*, dan *output gate*.

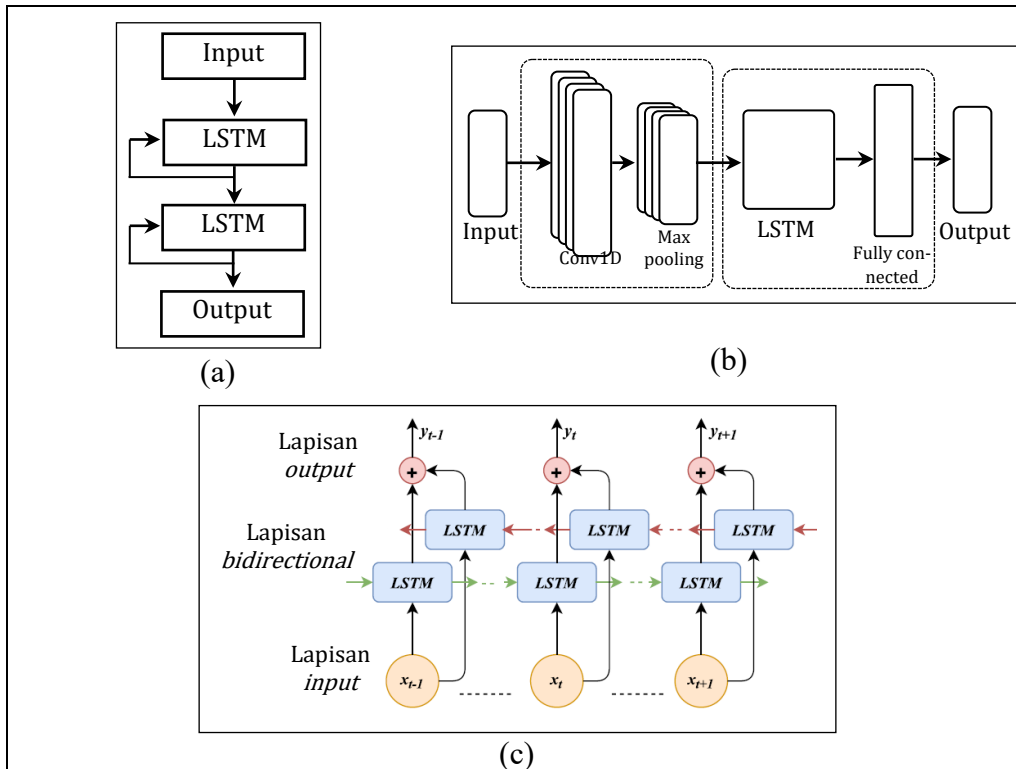
Tahap selanjutnya adalah prediksi keluaran. Pada tahap ini model menghasilkan prediksi curah hujan untuk hari berikutnya berdasarkan pola curah hujan yang telah dipelajari. Tahap terakhir adalah *Backpropagation Through Time* (BPTT). Pada tahap ini bobot jaringan diperbarui melalui propagasi balik menggunakan algoritma optimasi, seperti Adam dan SGD.

Empat varian arsitektur LSTM akan diujicoba untuk sebagai model prediksi curah hujan harian, yaitu: (i) Vanilla LSTM, yaitu model dasar LSTM dengan satu lapisan LSTM; (ii) Stacked LSTM, merupakan model yang terdiri beberapa lapisan LSTM untuk menangkap pola yang lebih kompleks; (iii) Hybrid CNN-LSTM, merupakan model gabungan Convolutional Neural Network (CNN) dan LSTM; dan, (iv) Bidirectional LSTM (BiLSTM), yaitu

model yang menggunakan informasi dari dua arah, yaitu *forward* dan *backward* untuk meningkatkan akurasi prediksi. Pada Gambar 3. ditampilkan diagram model stacked LSTM, hybrid CNN-LSTM dan Bidirectional LSTM.

Perangkat lunak yang digunakan untuk implementasi model LSTM

Model Long Short-Term Memory (LSTM) yang dikembangkan dalam penelitian ini diprogram menggunakan bahasa pemrograman Python. Model diimplementasikan pada platform Google Colab(Google Reseach, n.d.) yang dapat dijalankan secara online pada situs:<https://colab.research.google.com/>.Platform ini menyediakan lingkungan berbasis awan (*cloud*) dengan dukungan komputasi GPU Tesla T4 untuk mempercepat proses pelatihan model.Untuk membangun dan melatih modelLSTM, digunakan pustaka



Gambar 3. Diagram model LSTM: (a). Stacked LSTM(Singh dkk., 2015), (b) Hybrid CNN-LSTM(Livieris dkk., 2020), dan (c) Bidirectional LSTM(Ihianle dkk., 2020)

TensorFlow versi 2.6 sebagai *backend* utama untuk komputasi numerik (Abadi dkk., 2017) dan Keras API versi 2.6 sebagai *high-end level neural-networks* API (Chollet, 2017). Kedua pustaka ini dipilih untuk memudahkan proses perancangan dan pelatihan model. Penggunaan lingkungan Google Colab dipilih untuk mengatasi keterbatasan sumber daya komputasi lokal dengan konfigurasi *runtime* yang konsisten untuk seluruh proses eksperimen. Arsitektur jaringan saraf dirancang secara modular melalui Keras Functional API untuk fleksibilitas dalam menyusun lapisan-lapisan jaringan LSTM yang kompleks serta memudahkan proses *debugging* dan optimalisasi model. Seluruh kode yang diimplementasikan dalam penelitian ini telah diunggah pada *google drive* dan dapat diunduh melalui [situs: https://bit.ly/LSTM_prediksi_hujan](https://bit.ly/LSTM_prediksi_hujan).

Evaluasi Kinerja Model

Untuk menilai kinerja model, pada penelitian ini menggunakan dua metrik evaluasi statistik, yaitu: *Root Mean Square Error* (RMSE). RMSE parameter statistik untuk mengukur akar rata-rata kuadrat dari kesalahan prediksi, yang dapat dinyatakan dengan rumus:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

Mean Absolute Error (MAE). MAE mengukur rata-rata kesalahan absolut antara nilai prediksi dan observasi.

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

dengan *n* adalah jumlah data, *y_i* adalah nilai aktual curah hujan, dan *ŷ_i* adalah nilai prediksi curah hujan.

HASIL DAN PEMBAHASAN

Pengembangan model LSTM untuk prediksi curah hujan harian

Hal yang paling sulit dan memerlukan waktu yang cukup lama dalam pengembangan model LSTM untuk prediksi curah hujan adalah menentukan *hyperparameter* yang optimal agar model dapat menghasilkan hasil prediksi yang akurat dan presisi. Pada penelitian ini, penentuan *hyperparameter* model LSTM dilakukan dengan cara coba-coba (*trial and error*), seperti ditampilkan pada Tabel 1 yang menyajikan konfigurasi *hyperparameter* untuk empat varian model LSTM yang diujicoba pada penelitian ini, yaitu Vanilla LSTM, Stacked LSTM, CNN-LSTM, dan *Bidirectional LSTM* (Bi-LSTM).

Tabel 1. Hyperparameter yang digunakan untuk melatih model LSTM


No	Hyperparameter	Vanilla LSTM	Stacked LSTM	CNN-LSTM	Bidirectional LSTM
1.	Window size	30 dan 60	30 dan 60	30 dan 60	30 dan 60
2.	Batch size	32 dan 64	32 dan 64	32 dan 64	32 dan 64
3.	Jumlah lapisan LSTM	1	2 dan 3	1 dan 2	biLSTM 2
4.	Fungsi aktivasi	ReLU	ReLU	ReLU	ReLU
5.	Optimisasi	adam	adam	adam	adam
6.	Learning rate	0,001	0,001	0,001	0,001
7.	Fungsi loss	mse	mse	mse	Mse
8.	Epoch	50	50	50	50
9.	Early stopping	ya	ya	ya	Ya

Window size 30 hari dan 60 hari diaplikasikan untuk menangkap pola data jangka pendek dan jangka panjang curah hujan harian. Kemudian, Batch size diujicoba 32 dan 64 untuk memastikan keseimbangan antara stabilitas dan kecepatan konvergen model. Selanjutnya jumlah lapisan LSTM dibuat bervariasi dengan LSTM dan CNN-LSTM memiliki lebih banyak lapisan dibandingkan Vanilla LSTM, serta BiLSTM menggunakan dua lapisan untuk menangkap pola maju data dari arah maju dan mundur.

Fungsi aktivasi ReLU digunakan pada semua model dengan pertimbangan fungsi ini efektif dalam mengatasi ledakan (vanishing) gradient dibandingkan fungsi aktivasi lainnya. Optimisasi yang digunakan adalah *adam optimizer* dengan pertimbangan kemampuannya untuk menyesuaikan laju pembelajaran (*learning rate*) sehingga dapat meningkatkan efisiensi konvergensi model. *Mean Square Error* (MSE) dipilih sebagai fungsi loss untuk keseluruhan model dengan pertimbangan konsistensi dalam mengukur perbedaan antara nilai data prediksi dan data aktual curah hujan. Epoch dipilih 50 dan menggunakan *early stopping* untuk keseluruhan model dengan pertimbangan ketika model tidak menunjukkan peningkatan signifikan dalam validasi maka pelatihan akan berhenti, selain itu juga untuk menghindari terjadinya *overfitting* pada saat pelatihan.

Pada gambar 4 ditampilkan kurva fungsi loss selama pelatihan model LSTM, khususnya model Bidirectional LSTM konfigurasi Window Size = 60 hari, Batch Size = 64, lapisan Bidirectional LSTM 64 dan 32 simpul, lapisan dense 32 dan 1 sebagai model terbaik untuk prediksi curah hujan (penjelasan lebih detail tentang model ini disampaikan pada subbab

berikutnya). Berdasarkan gambar tersebut terlihat bahwa grafik menunjukkan penurunan nilai loss secara signifikan pada awal pelatihan. Hal ini mengindikasikan jika model mampu mempelajari pola dari data curah hujan harian yang diberikan. Kemudian pelatihan berhenti pada epoch ke 9 mengindikasikan jika *early stopping* bekerja dengan baik untuk mencegah terjadinya model mengalami *overfitting*.



Gambar 4. Fungsi loss pelatihan Bidirectional LSTM

Hasil pengujian model

Hasil pengujian model LSTM untuk prediksi curah hujan Kabupaten Manokwari ditampilkan pada Tabel 2. Berdasarkan tersebut, terlihat bahwa untuk model Vanilla LSTM kinerja terbaik untuk model dengan Window Size = 60 hari, Batch Size = 64, lapisan LSTM 64 simpul dengan RMSE = 10,63 mm dan MAE = 64,1 mm. Model ini cukup stabil dengan rentang RMSE 10,63 mm – 10,85 mm dan MAE berkisar 6,31 mm – 6,75 mm. Fungsi Aktivasi tanh cenderung menghasilkan kinerja lebih baik dibandingkan fungsi aktivasi relu. Secara umum, Vanilla LSTM cukup andal dalam prediksi curah hujan harian Kabupaten Manokwari. Akan tetapi, memiliki tingkat kesalahan (*error*) yang relative tinggi dibandingkan model lainnya.

Tabel 2. Hasil Pengujian Model LSTM untuk Prediksi Curah Hujan Harian

Model	Window Size	Batch Size	Lapisan LSTM	RMSE (mm)	MAE (mm)
Vanilla LSTM	30	32	64	10,79	6,56
	60	32	64	10,65	6,48
	30	32	128	10,85	6,55
	60	32	128	10,64	6,50
	30	64	64	10,79	6,50
	60	64	64	10,63	6,41
	30	64	128	10,78	6,56
	60	64	128	10,65	6,33
Stacked LSTM	30	64	64-64-32	10,84	6,52
	30	32	128-64-32	10,85	6,75
	30	64	64-64-32	10,86	6,66
	30	64	128-64-32	10,77	6,69
	60	32	64-64-32	10,67	6,40
	60	32	128-64-32	10,72	6,32
	60	64	64-64-32	10,67	6,40
	60	64	128-64-32	10,82	6,51
CNN-LSTM	30	32	Conv1D 64 + LSTM 64	10,88	6,68
	30	64	Conv1D 64 + LSTM 64	10,91	6,60
	60	32	Conv1D 64 + LSTM 64	10,75	6,56
	60	64	Conv1D 64 + LSTM 64	10,88	6,41
	30	32	Conv1D 64 + LSTM 64-32	10,89	6,59
	30	64	Conv1D 64+ LSTM 64-32	11,21	6,95
	60	32	Conv1D 64+ LSTM 64-32	11,05	6,75
	60	64	Conv1D 64+LSTM 64-32	11,05	6,79
	30	32	Conv1D 64-128 + LSTM 64	10,96	6,83
	30	64	Conv1D 64-128 + LSTM 64	10,96	6,53
	60	32	Conv1D 64-128 + LSTM 64	10,72	6,63
	60	64	Conv1D 64-128 + LSTM 64	10,69	6,59
	30	32	Conv1D 64-128 + LSTM 64-32	10,94	6,97
	30	64	Conv1D 64-128 + LSTM 64-32	11,21	6,96
	60	32	Conv1D 64-128 + LSTM 64-32	11,05	6,72
	60	64	Conv1D 64-128 + LSTM 64-32	10,71	6,69
Bidirectional LSTM	30	32	BiLSTM 64-32	10,80	6,73
	30	64	BiLSTM 64-32	10,76	6,58
	30	32	BiLSTM 64-32	10,75	6,57
	30	64	BiLSTM 64-32	10,73	6,53
	30	32	BiLSTM 128-64	10,73	6,53
	30	64	BiLSTM 128-64	10,71	6,58
	60	32	BiLSTM 64-32	10,65	6,64
	60	64	BiLSTM 64-32	10,64	6,46
	60	32	BiLSTM 64-32	10,66	6,23
	60	64	BiLSTM 64-32	10,55	6,49
	60	32	BiLSTM 128-64	10,66	6,63
	60	64	BiLSTM 128-64	10,66	6,47

Selanjutnya untuk model Stacked LSTM, performa terbaiknya diperoleh


dengan Window Size = 60 hari, Batch Size = 32, tiga lapisan LSTM dengan

jumlah tiap-tiap lapisan 128, 64, dan 32 simpul dengan RMSE = 10,67 mm dan MAE = 7,32 mm. Secara umum, kinerja Stacked LSTM tidak menunjukkan peningkatan signifikan dibandingkan Vanilla LSTM. Bahkan pada beberapa konfigurasi nilai MAE Stacked LSTM justru lebih tinggi dibandingkan nilai MAE Vanilla LSTM. Hal ini mengindikasikan bahwa menambah lebih banyak lapisan LSTM tidak memberikan peningkatan yang berarti untuk prediksi curah hujan harian Kabupaten Manokwari.

Kemudian untuk model hybrid CNN-LSTM, kinerja terbaiknya untuk memprediksi curah hujan harian Kabupaten Manokwari diperoleh dengan Window Size = 60 hari, Batch Size = 64, lapisan Conv1D (65 filter), lapisan LSTM 64 simpul, dan lapisan dense layer 32 dan 1 simpul dengan RMSE = 10,69 mm dan MAE = 6,59 mm. Namun demikian, pada beberapa konfigurasi dengan CNN dan LSTM yang lebih banyak menunjukkan peningkatan kesalahan prediksi, seperti nilai RMSE mencapai 11, 21 mm dan MAE 6,96 mm. Dari nilai RMSE dan

MAE dapat dinyatakan bahwa model hybrid CNN-LSTM tidak menunjukkan kinerja yang lebih baik dibanding model lainnya. Hal ini terjadi karena meskipun CNN dapat mengekstrak fitur spasial, kemungkinan besar pola curah hujan yang panjang lebih bergantung pada pola-pola temporal yang lebih baik ditangkap oleh LSTM murni.

Untuk model Bidirectional LSTM, kinerja terbaiknya diperoleh dengan Window Size = 60 hari, Batch Size = 64, lapisan Bidirectional LSTM 64 dan 32 simpul, lapisan dense 32 dan 1 simpul dengan RMSE = 10,55 mm dan MAE = 6,49 mm. Berdasarkan hasil pengujian keseluruhan model, model Bidirectional LSTM memiliki performa terbaik. Hal ini disebabkan karena Model Bidirectional LSTM cenderung menghasilkan nilai RMSE dan MAE yang lebih rendah dibandingkan ketiga model lainnya. Adapun keunggulan dari penggunaan model Bidirectional LSTM untuk prediksi curah hujan adalah memungkinkan model untuk belajar dari informasi masa lalu dan masa depan, sehingga dapat meningkatkan akurasi prediksi.



Gambar 5. Grafik hasil pengujian model terbaik untuk prediksi curah hujan harian kota-manokwari (model Bidirectional LSTM)

Pada Gambar 5 ditampilkan grafik hasil pengujian model terbaik untuk prediksi curah hujan harian Kabupaten Manokwari. Grafik menunjukkan bahwa curah hujan harian hasil prediksi model (garis merah) cukup mengikuti tren data aktual curah hujan (garis biru), terutama dalam hal menangkap fluktuasi musiman (misalnya puncak curah hujan di bulan tertentu). Namun demikian, terdapat penyimpangan (deviasi) pada beberapa titik, seperti pertengahan tahun 2023 dan awal 2024, dimana prediksi kurang akurat. Hal ini kemungkinan disebabkan oleh karena variabilitas tinggi dari data curah hujan atau derau (misal kejadian ekstrim seperti badai). Selain itu, terlihat bahwa data curah hujan hasil prediksi cenderung terlambat dari data curah hujan aktual, seperti puncak prediksi lebih rendah atau tertunda beberapa hari. Hal ini umum terjadi pada model LSTM yang memroses data runtun waktu, yang disebabkan karena window size = 60 hari tidak cukup mampu menangkap pola jangka panjang.

Secara umum, Model LSTM memiliki keunggulan dalam model mampu menangkap pola musiman curah hujan ketika model mampu memprediksi tren umum curah hujan, seperti peningkatan di bulan-bulan tertentu. Kemudian dalam hal stabilitas, model tidak mengalami *overfitting* yang signifikan yang ditandai dari kesesuaian pola prediksi dan actual secara keseluruhan. Disisi lain, kelemahan model LSTM yang dikembangkan pada penelitian ini adalah ketidakakuratan hasil prediksi model saat cuaca hujan ekstrim. Untuk penelitian selanjutnya disarankan agar menambahkan parameter-parameter cuaca dan iklim seperti suhu, kelembaban, kecepatan angin, suhu permukaan laut, dan penyebab variabilitas iklim seperti ENSO, IOD, dan MJO.

KESIMPULAN

Pada penelitian ini telah dilakukan pengembangan model prediksi curah hujan harian Kabupaten Manokwari, Provinsi Papua Barat berbasis Long Short-Term Memory (LSTM). Empat varian arsitektur LSTM digunakan sebagai model untuk memprediksi curah hujan, yaitu Vanilla LSTM, Stacked LSTM, Hybrid CNN-LSTM, dan Bidirectional LSTM. Berdasarkan hasil pengujian, Model Bidirectional LSTM dengan Window Size = 60 hari dan Batch Size = 64, dua lapisan Bidirectional LSTM (jumlah simpul 64 dan 32), dan dua lapisan dense (jumlah simpul 32 dan 1) memberikan nilai RMSE = 10,55 mm dan MAE = 6,49 mm. Model ini merupakan model terbaik untuk memprediksi curah hujan harian Kabupaten Manokwari karena model ini memberikan nilai RMSE dan MAE terendah dibandingkan dengan model lainnya.

DAFTAR PUSTAKA

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D. G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., Zheng, X. (2017). A machine learning approach to radar sea clutter suppression. 2017 IEEE Radar Conference, RadarConf 2017, 1222–1227
- As-syakur, A. R., Tanaka, T., Osawa, T., & Mahendra, M. S. (2013). Indonesian rainfall variability observation using TRMM multi-satellite data. *International Journal of Remote Sensing*, 34(21)
- Asanjan, A. A., Yang, T., Hsu, K., Sorooshian, S., Lin, J., & Peng, Q.

- (2018). Short-Term Precipitation Forecast Based on the PERSIANN System and LSTM Recurrent Neural Networks. *Journal of Geophysical Research: Atmospheres*, 123(22),
- BMKG. (2023). Analisis Dinamika Atmosfer–Laut; Analisis & Prediksi Curah Hujan. Badan Meteorologi Klimatologi dan Geofisika.
- Cahyarini, S. Y., & Henrizan, M. (2018). Coral based-ENSO/IOD related climate variability in Indonesia: A review. *IOP Conference Series: Earth and Environmental Science*, 118(1).
- Chollet, F. (2017). Keras: Deep learning library for python. runs on tensorflow, theano or cntk. <https://github.com/fchollet/keras>
- Google Research. (n.d.). Google Colaboratory. <https://colab.research.google.com/>
- Harjupa, W., Shimomai, T., Hashiguchi, H., Fujiyoshi, Y., & Kawashima, M. (2021). Differences in Mechanisms of Orographic Rainfall over West Sumatra (Case Study: 10 April and 23 April 2004). *Jurnal Ilmu Fisika | Universitas Andalas*, 13(1), 8–17.
- Herjazi, M. I., Cai, X., Yuan, X., Liang, X.-Z., & Kumar, P. K. (2013). Incorporating Reanalysis-Based Short-Term Forecasts from a Regional Climate Model in an Irrigation Scheduling Optimization Problem. *Journal of Water Resources Planning and Management*, 140(5), 699–713.
- Houdt, G. v, Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929–5955.
- Ihianle, I. K., Nwajana, A. O., Ebebuwa, S. H., Otuka, R. I., Owa, K., & Orisatoki, M. O. (2020). A deep learning approach for human activities recognition from multimodal sensing devices. *IEEE Access*, 8, 179028–179038.
- Kim, S., Hong, S., Joh, M., & Song, S.-K. (2017). Deeprain: ConvLSTM Network for Precipitation Prediction using Multichannel Radar Data.
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23), 17351–17360.
- Mondiana, Y. Q., Zairina, A., & Sari, R. K. (2022). Prediksi Peluang Kejadian Curah Hujan Ekstrem Dan Implikasi Pengelolaan Sumberdaya Air. *Journal of Forest Science Avicennia*, 4(2), 96–101.
- Ramli, I., Rusdiana, S., Ayulianur, & Achmad, A. (2019). Comparisons among rainfall prediction of monthly rainfall basis data in Aceh using an autoregressive moving average. *IOP Conference Series: Earth and Environmental Science*.
- Satyamurty, P., De Castro, A. A., Tota, J., Da Silva Gularte, L. E., & Manzi, A. O. (2010). Rainfall trends in the Brazilian Amazon Basin in the past eight decades. *Theoretical and Applied Climatology*, 99(1–2), 139–148.
- Singh, U., Chauhan, S., Krishnamachari, A., & Vig, L. (2015, December 2). Ensemble of deep long short term memory networks for labelling origin of replication sequences. *Proceedings of the 2015 IEEE International Conference on Data Science and Advanced Analytics, DSAA 2015*.
- World Meteorological Organization [WMO]. (2021). *State of the Global Climate 2020 (Issue 1264)*.
- Zarei, M., Najarchi, M., & Mastouri, R.

(2021). Bias correction of global ensemble precipitation forecasts by Random Forest method. *Earth Science Informatics*, 14(2).