

DEEP LEARNING DALAM MEMPREDIKSI CURAH HUJAN BERBASIS SATELIT NOAA DI DAS SAMPEAN BARU JAWA TIMUR

Gusfan Halik^{1*}, Iqbal Rafi'ud Darajad², dan Retno Utami A. Wiyono³

^{1*}Program Studi Magister Teknik Sipil, Universitas Jember, Jl. Kalimantan No. 37, Jember
e-mail: gusfan.teknik@unej.ac.id

²Program Studi Teknik Sipil, Universitas Jember, Jl. Kalimantan No. 37, Jember
e-mail: darajat8@gmail.com

³Program Studi Magister Teknik Sipil, Universitas Jember, Jl. Kalimantan No. 37, Jember
e-mail: retnoutami@unej.ac.id

ABSTRAK

Pencatatan data curah hujan di DAS Sampean Baru Kabupaten Bondowoso sering menghadapi kendala operasional di lapangan, seperti data curah hujan yang tidak lengkap akibat pemeliharaan alat ukur yang kurang baik. Kondisi ini menjadi tantangan utama penyediaan data curah hujan yang lengkap sebagai dasar perencanaan dan pengelolaan alokasi air. Penelitian ini bertujuan untuk mengembangkan metode prediksi curah hujan berbasis data satelit *National Oceanic and Atmospheric Administration* (NOAA). Metode *Deep Learning* dengan *Long Short-Term Memory* (LSTM) digunakan sebagai pendekatan kecerdasan buatan atau *Machine Learning*. Data hujan dari satelit NOAA digunakan sebagai input model LSTM, sedangkan data hujan observasi digunakan sebagai data target dalam membangun model. Hasil penemodelan menunjukkan bahwa curah hujan luaran model memiliki keandalan model yang cukup memadai jika dibandingkan dengan data curah hujan observasi. Penelitian ini menunjukkan bahwa pendekatan *deep learning* LSTM dengan data satelit NOAA dapat dijadikan alternatif dalam memprediksi curah hujan pada suatu DAS dengan data terbatas, sehingga pengelolaan alokasi air dapat dilakukan lebih optimal.

Kata Kunci: Curah Hujan, LSTM, Deep learning, NOAA, Sampean Baru

PENDAHULUAN

Curah hujan merupakan sumber sumberdaya alam utama dalam menjamin ketersediaan air di suatu Daerah Aliran Sungai (DAS) dalam periode waktu tertentu. Curah hujan adalah salah satu indikator dalam bidang meteorologi dan klimatologi yang sangat penting bagi kehidupan, seperti sumber daya air ekosistem, pertanian, dan manajemen bencana alam (Mubarok et al., 2024). Secara umum, curah hujan di Indonesia rata-rata sekitar 2.000 mm per tahun (Febrianti, 2018). Indonesia merupakan negara kepulauan dengan 70% wilayahnya terdiri dari laut dan terletak di daerah garis khatulistiwa, memiliki iklim tropis lembab yang banyak mengandung uap air (Hidayat et al., 2016). Beberapa daerah seperti Sumatera, Jawa, dan Kalimantan adalah daerah yang memiliki rata-rata curah hujan tinggi yang dampak signifikan terhadap keberhasilan usaha pertanian dan perkebunan. Data curah hujan merupakan data dasar sebagai acuan dalam perencanaan infrastruktur sipil dan bangunan air, seperti perencanaan bendungan, drainase, bendung, dan sistem irigasi (Lumbanraja et al., 2023). Data curah hujan yang lengkap sangat diperlukan dalam perencanaan dan pengelolaan alokasi air yang optimal.

Di Indonesiam, sebagian besar stasiun penakar hujan yang ada masih menggunakan metode konvensional. Dalam mengukur tingkat curah hujan secara konvensional, biasanya digunakan perangkat sederhana yang disebut ombrometer (Yudhana et al., 2019). Perkembangan dan kemajuan teknologi yang pesat, curah hujan dapat diperoleh menggunakan teknologi penginderaan jauh atau citra satelit (Kartika et al., 2023). Keunggulan data curah hujan satelit adalah dapat mengukur curah hujan dengan cakupan yang lebih luas, bersifat real-time dan hemat biaya (Marta et al., 2022). Penggunaan data hujan dari citra satelit dapat dimanfaatkan sebagai alternatif solusi jika terjadi kerusakan pada peralatan penakar hujan konvensional.

Salah satu produk curah hujan dengan teknologi penginderaan jauh adalah citra satelit NOAA. Satelit NOAA merupakan satelit ke 3 dari Amerika yang dikembangkan oleh Komunitas ilmiah *National Oceanographic and Atmospheric Administration* (NOAA) untuk mendapatkan informasi dari berbagai objek data menggunakan penginderaan jauh satelit dengan mempelajari proses interaksi di permukaan bumi pada berbagai skala spasial dan temporal (Gutman, 1994). Satelit ini menggunakan sensor *Advanced Very High Definition Radiometer* (AVHRR).

Satelit NOAA AVHRR memiliki keterbatasan resolusi spasial yang diukur dengan *Instantaneous Field of View* (IFOV) pada titik nadir 1.21 km²-sel resolusinya adalah 1 kali 1,1 km (Ehrlich et al., 1994). Adanya keterbatasan resolusi ini, perlu dikembangkan berbagai algoritma kecerdasan buatan berbasis *machine learning* dalam meningkatkan akurasi data curah hujan satelit.

Berbagai metode dikembangkan dalam rangka meningkatkan kualitas data curah hujan satelit, salah satunya adalah metode komputasi *Deep learning*. *Deep learning* merupakan bagian dari cara kerja komputer *Machine learning* dimana *Deep Learning* merupakan algoritma yang menggunakan beberapa Artificial Neural Networks (ANN) dan Hidden layers (Pettit et al., 2021). *Deep learning* merupakan model yang dapat belajar dari pola data yang besar dan kompleks dengan berbagai jenis *Artificial Neural Network* yang dapat dipakai, diantaranya : FNN (*Feedforward Neural Network*) / *Multi Layer Perceptron*, *Convolutional Neural Network*, dan RNN (*Reccurent Neural Network*) dalam pemodelan matematis dan prediksi (Schmidhuber, 2015).

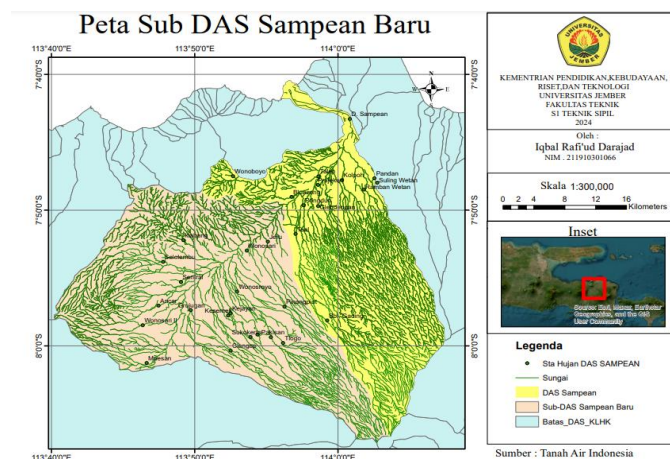
LSTM (*Long Short-Term Memory*) adalah jenis RNN yang memiliki mekanisme khusus yang memungkinkan lebih baik untuk "mengingat" informasi jangka panjang. Ini dapat dicapai melalui penggunaan struktur internal yang kompleks, seperti sel memori, yang memungkinkan penambahan, penghapusan, atau penyimpanan data dari waktu ke waktu. Dengan menyimpan informasi dalam waktu yang lebih lama, sel memori LSTM memungkinkan jaringan mengatasi masalah menghilangnya atau meledaknya gradien (DiPietro et al., 2020). Selain itu, LSTM memiliki gerbang, atau pintu, yang memungkinkan pengaturan aliran informasi ke sel memori. Dengan demikian, gerbang ini dapat mengontrol kapan informasi harus diingat atau dilupakan. Hal ini membuat LSTM sangat berguna untuk memodelkan hubungan jangka panjang dalam data urutan seperti data curah hujan (Wang et al., 2019).

Dalam penelitian ini, LSTM dipilih karena keunggulannya dalam menangani data deret waktu (time series) yang kompleks seperti data curah hujan. LSTM dirancang khusus untuk mengatasi masalah yang sering muncul pada RNN konvensional, seperti hilangnya gradien (*vanishing gradient*) atau meledaknya gradien (*exploding gradient*), yang dapat menghambat proses pembelajaran pada data dengan ketergantungan jangka panjang. Model ini berpotensi efektif untuk memprediksi curah hujan berdasarkan pola temporalnya. Selain itu, LSTM telah terbukti berhasil dalam berbagai aplikasi prediksi dan pemodelan data kompleks, termasuk dalam bidang meteorologi dan klimatologi (Zhang et al., 2020) ; (Parasyris et al., 2022) ; (Vo et al., 2023). Oleh karena itu, aplikasi algoritma LSTM di lokasi Sampean Baru diharapkan dapat menghasilkan prediksi curah hujan yang akurat dan andal, sehingga dapat mendukung perencanaan dan pengelolaan sumber daya air yang lebih optimal dan efektif.

METODE

Lokasi Penelitian

DAS Sampean Baru terletak di Kabupaten Bondowoso, Provinsi Jawa Timur, Indonesia. Daerah aliran sungai ini mencakup 80 % kawasan Kabupaten Bondowoso, termasuk wilayah-wilayah pegunungan dan dataran rendah yang memiliki topografi yang cukup bervariasi. Koordinat geografis DAS Sampean Baru berada di sekitar 7°54' - 7°59' LS dan 113°49' - 114°04' BT. Topografi di wilayah ini sebagian besar merupakan dataran tinggi, dan juga pegunungan seperti Pegunungan Ijen di sebelah timur, yang mempengaruhi pola presipitasi sehingga curah hujan yang turun bervariasi disetiap lokasinya



Gambar 1. Peta Lokasi DAS Sampean Baru

Data Penelitian

Curah Hujan Harian Observasi

Data curah hujan harian observasi di DAS Sampean Baru pada penelitian ini digunakan sebagai data target. Data curah hujan tersebut merupakan dari data curah hujan 16 stasiun, meliputi Sta. Hujan Wonosari II, Sta. Hujan Maesan, Sta. Hujan Ancar, Sta. Hujan Selolembu, Sta. Hujan Sentral, Sta. Hujan Klabang, Sta. Hujan Grujugan, Sta. Hujan Kesemek, Sta. Hujan Kejayaan, Sta. Hujan Clangap, Sta. Hujan Wonosroyo, Sta. Hujan Wonosari, Sta. Hujan Sukokerto, Sta. Hujan Maskuning, Sta. Hujan Jero, Sta. Hujan Pakisan, Sta. Hujan Tlogo, Sta. Hujan Pinang pait.

Data Klimatologi Satelit

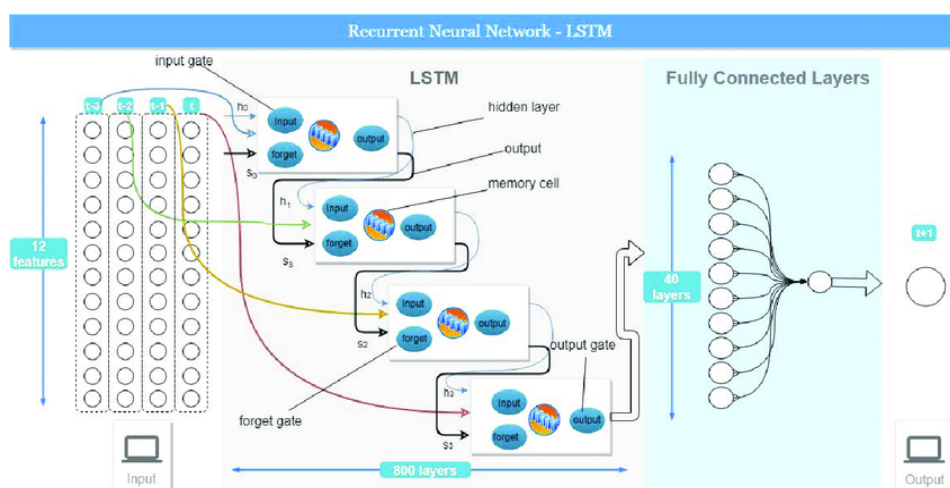
Data curah hujan harian satelit NCEP/NCAR Reanalysis 2 pada penelitian digunakan sebagai data input untuk prediksi curah hujan DAS Mayang. Data NOAA di download di web NOAA psl dalam bentuk file Netcdf. Selanjutnya cropping data sesuai dengan batas koordinat DAS Sampean Baru , namun cropping dilakukan lebih luas dari dari koordinat DAS dikarenakan untuk antisipasi hujan diluar koordinat DAS yang terkena angin sehingga masuk ke wilayah DAS Sampean Baru $7^{\circ}54' - 7^{\circ}59' \text{ LS}$ dan $113^{\circ}49' - 114^{\circ}04' \text{ BT}$. Netcdf dibuka dengan menggunakan aplikasi Ocean Data view sehingga data dalam file tersebut terbaca dan diekspor dalam bentuk data urutan dengan format csv.

Metodologi

Penelitian dimulai dengan tahap persiapan data yang mencakup pengolahan data curah hujan. Data yang digunakan dalam penelitian yang telah diolah menjadi format csv , mencakup dua jenis data yaitu data hujan observasi (sebagai data target) dan data hujan satelit (sebagai input model). Data hujan yang diukur secara konvensional digunakan sebagai target yang akan dibandingkan dengan hasil prediksi model. Sedangkan data hujan dari satelit digunakan sebagai input model LSTM yang akan memprediksi curah hujan. Untuk mengecek kualitas dari data observasi yang dimiliki dilakukan uji konsistensi data dengan menggunakan metode kurva massa ganda. Setelah data diuji konsistensinya dengan grafik dan nilai regresi (R^2) yang sempurna, maka data data dapat digunakan untuk penelitian. Uji ini dilakukan dengan membandingkan kumulatif data hujan selama 10 tahun dengan masing- masing stasiun hujan pembandingnya Rasio data yang digunakan untuk model 70% Training dan 30% Testing untuk diinputkan ke dalam model.

Model Deep Learning LSTM

Model Neural Network yang digunakan adalah LSTM. Fungsi aktivasi yang digunakan pada setiap neuron adalah tanh dan sigmoid. Model yang digunakan memiliki, maka hasil olahan data akan didistribusikan menuju Dense Layer (Fully Connected Layer). Dense Layer akan menghasilkan data Output. **Gambar 2.**



Gambar 2. Skema Model LSTM (Nahapetyan, 2019)

Beberapa elemen yang ada pada LSTM adalah sebagai berikut :

Forget Gate :

$$ft = \sigma(Wf \cdot [h_{t-1}, xt] + bf) \quad (1)$$

ft = vektor keluaran dari forget gate, sigma σ = fungsi sigmoid, Wf = matriks bobot untuk forget gate, h_{t-1} = vektor keluaran dari LSTM pada waktu t-1, xt = Input pada waktu t, dan bf = bias untuk forget gate.

Input Gate :

$$it = \sigma(Wi \cdot [h_{t-1}, xt] + bi) \quad (2)$$

it = vektor keluaran dari Input gate, Wi = matriks bobot untuk Input gate, dan bi = bias untuk Input gate.

Candidate Cell State:

$$\hat{Ct} = \tanh(Wc \cdot [h_{t-1}, xt] + bc) \quad (3)$$

\hat{Ct} = kandidat cell state baru, tanh = fungsi aktivasi tanh, WC = matriks bobot untuk cell state, dan bc = bias untuk cell state

Cell State Update :

$$Ct = ft * Ct_{-1} + it * \hat{Ct} \quad (4)$$

Ct_ = cell state baru, dan Ct-1 = cell state pada waktu sebelumnya. (Gambar 2.3)

Output Gate :

$$ot = \sigma(Wo \cdot [h_{t-1}, xt] + bo) \quad (5)$$

Ot_ = vektor keluaran dari Output gate, Wo = matriks bobot untuk Output gate, dan bo = bias untuk Output gate.

Hidden State Update :

$$ht = ot.tanh(Ct) \quad (6)$$

ht = Hidden state baru.

Persamaan-persamaan diatas menunjukkan bagaimana LSTM memproses informasi atau input dari waktu ke waktu, menggabungkan informasi dari input saat ini dan Hhdden state sebelumnya, serta mengatur dan memperbarui cell state dan hidden state untuk menyimpan informasi jangka panjang. Dalam proses mengolah data input menjadi Output. Pertama dari tahapan input nilai, input node (g), input gate (i), forget gate (f), output gate (o) dihitung secara berurutan. Internal state (s) didapatkan dengan mengakumulasi nilai g, i, f serta s periode sebelumnya. Selanjutnya, nilai akhir dari memori sel (h) akan digunakan untuk mengubah variabel pada proses LSTM selanjutnya.

- Training

Training atau Pelatihan Long Short-Term Memory (LSTM) adalah proses melatih model jaringan saraf untuk mempelajari pola data sekuensial, seperti data deret waktu, yang sangat relevan untuk tugas-tugas seperti prediksi curah hujan.

- Testing

Testing model merupakan suatu proses mengoptimalkan dalam penyesuaian nilai parameter model untuk mendapatkan satu set parameter yang memberikan pendekatan terbaik dari curah hujan maksimum bulanan yang diamati. Adapun untuk mengukur keakuratan model dapat dilakukan perhitungan MSE (*Mean Square Error*), MAE (*Mean Absolute Error*) , Koefisien determinasi (R^2), RMSE (*Root Mean Square Error*) dan NSE (*Nash Stuchliffe*). Perhitungan RMSE dilakukan untuk mengetahui perbedaan hasil antara peramalan dan data observasi. Sedangkan perhitungan NSE dilakukan untuk mengetahui nilai keakuratan prediksi model. Perhitungan tersebut dapat dilihat pada persamaan (7) sampai (11).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Si - Oi| \quad (7)$$

$$MSE = \frac{1}{n} \quad (8)$$

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n (Si - Oi)^2 \right)^{1/2} \quad (9)$$

$$R^2 = \frac{(\sum_{i=1}^n (Oi - \bar{O})(Si - \underline{S}))^2}{\sum_{i=1}^n (Oi - \bar{O})^2 \sum_{i=1}^n (Si - \underline{S})^2} \quad (10)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Si - Oi)^2}{\sum_{i=1}^n (Oi - \bar{O})^2} \quad (11)$$

n = jumla data ; Si = curah hujan luaran model ; Oi = curah hujan pengamatan ; \underline{S} = rerata curah hujan luaran model dan \bar{O} rerata data observasi.

Running LSTM dilakukan pada masing-masing staisun hujan untuk parameter model yang optimal. Parameter optimal model berbeda-beda pada setiap stasiun penakar hujan. Kondisi ini disebabkan pengaruh efek spasial dan pola hujan yang berbeda. Pemilihan dan tuning hyperparameter dilakukan terhadap : jumlah neuron, dropout, optimizer dan Epoch, seperti yang dilakukan penelitian sebelumnya (Fouotsa Manfouo et al., 2023). Penentuan parameter optimal menggunakan metode coba-banding sehingga model luaran model yang memiliki tingkat akurasi tinggi seperti yang ditunjukkan pada Tabel 1.


Tabel 1. Parameter Model LSTM

Stasiun	Neuron	Aktivasi	Rec aktivasi	Drop out	Optimizer	Learn rate	Batch
Wonosari II	10	sig	sig	0.2	adam	0,005	12
Maesan	15	sig	sig	0.1	adam	0,02	12
Ancar	25	sig	sig	0.4	adam	0,01	9
Selolembu	10	sig	sig	0.2	adam	0,03	12
Sentral	15	tanh	sig	0.2	adam	0,01	12
Klabang	15	sig	tanh	0.1	adam	0,01	2
Grujugan	15	sig	tanh	0.5	adam	0,009	12
Kesemek	35	sig	tanh	0.3	adam	0,01	12
Kejayaan	15	hardsig	sig	0.1	adam	0,1	7
Clangap	15	tanh	sig	0.1	adam	0,01	3
Wonosroyo	10	sig	tanh	0.3	adam	0,05	12
Wonosari	10	sig	sig	0.2	adam	0,005	12
Sukokerto	10	sig	tanh	0.4	adam	0,005	8
Maskuning	10	sig	sig	0.2	adam	0,005	12
Jero	10	sig	sig	0.3	adam	0,006	12
Pakistan	10	sig	sig	0.3	adam	0,01	12
Tlogo	10	sig	tanh	0.2	adam	0,01	12
Pinang pait	10	sig	sig	0.3	adam	0,009	12


HASIL

Analisis Data Pemodelan Deep Learning


Setelah melalui Proses Training dan Testing dihasilkan perbandingan prediksi model dengan data hujan observasi tiap stasiun hujan. Sebagai contoh analisis diambil hasil pemodelan pada stasiun daerah hulu yaitu Maesan, stasiun daerah Hilir Jero dan analisis terhadap rata rata wilayah untuk menyederhanakan interpretasi hasil dan memberikan representasi yang lebih jelas. Ketiga elemen ini dipilih karena dianggap mampu mewakili variasi curah hujan yang terjadi di seluruh 18 stasiun tersebut. Stasiun hulu mencerminkan pola curah hujan di bagian atas daerah aliran sungai (DAS), stasiun hilir menggambarkan kondisi di bagian bawah, sedangkan rerata kawasan memberikan gambaran umum yang menggabungkan keseluruhan data dari 18 stasiun tersebut. Berikut hasil dari model yang dibuat.




Gambar 3. Grafik Model vs Aktual (Observasi) Stasiun Maesan




Gambar 4 Scatter plot Model Sta. Maesan




Gambar 5. Grafik Model vs Aktual (Observasi) Stasiun Jero



Gambar 6. Scatter plot Model Sta.Jero



Gambar 7. Grafik Model vs Aktual (Observasi) Rata rata wilayah



Gambar 8.Scatter plot model Rerata Wilayah

Secara keseluruhan LSTM mampu menangkap pola temporal dalam data curah hujan, seperti musim hujan dan kemarau, serta fluktuasi tahunan. Jika garis prediksi (Predicted) mengikuti garis aktual (Actual) dengan baik, ini menunjukkan bahwa LSTM berhasil mempelajari pola-pola ini. Perubahan mendadak dalam pola curah hujan, seperti

kejadian cuaca ekstrem (El Niño atau La Niña), mungkin tidak sepenuhnya tertangkap oleh model karena tidak menggunakan variabel tersebut.

Analisis model terhadap variabel spasial di hulu menghasilkan data prediksi yang baik. Training stage memiliki nilai R^2 yang seimbang dengan nilai $R^2 = 0.74$ untuk training dan $R^2 = 0.70$ Testing. Nilai dari model stasiun hujan Maesan pada (Gambar 3) telah mengikuti pola dari nilai aktual, yang menunjukkan bahwa model sangat baik dalam menangkap fluktuasi curah hujan dari waktu ke waktu. Pada diagram scatter plot (Gambar 4) sebaran data pemodelan terhadap aktual mendekati garis model yang menunjukkan bahwa model mempresentasikan curah hujan setempat dengan baik.

Analisis model terhadap variabel spasial di hilir menghasilkan data prediksi yang baik. Tahap training memiliki nilai R^2 yang cenderung overfitting dengan nilai $R^2 = 0.80$ dan nilai $R^2 = 0.41$ untuk testing. Nilai dari model stasiun hujan Maesan pada (Gambar 5) telah mengikuti pola dari nilai aktual, yang menunjukkan bahwa model sangat baik dalam menangkap fluktuasi curah hujan dari waktu ke waktu. Pada diagram scatter plot (Gambar 6) sebaran data pemodelan terhadap aktual mendekati garis model yang menunjukkan bahwa model mempresentasikan curah hujan setempat dengan baik.


Analisis model terhadap rata-rata wilayah menghasilkan data prediksi yang baik. Training stage memiliki nilai R^2 yang cenderung overfitting dengan nilai $R^2 = 0.87$ yang dapat dilihat pada untuk training dan $R^2 = 0.72$ untuk testing. Nilai dari model stasiun hujan Maesan pada (Gambar 7) telah mengikuti pola dari nilai aktual, yang menunjukkan bahwa model sangat baik dalam menangkap fluktuasi curah hujan dari waktu ke waktu. Pada diagram scatter plot (Gambar 8) sebaran data pemodelan terhadap aktual mendekati garis model yang menunjukkan bahwa model mempresentasikan curah hujan setempat dengan baik.

Validasi Curah Hujan


Validasi digunakan untuk memprediksi seberapa besar ketidakpastian suatu metode. Setelah model berhasil di training dan testing untuk seluruh pos hujan selanjutnya data hasil dari pemodelan akan dievaluasi dengan performa matriks untuk mengetahui apakah model sudah cukup baik atau tidak. Berikut disajikan rekapitulasi evaluasi matriks model tiap pos hujan.

Tabel 5. Rekapitulasi Keandalan Model


Stasiun	R2		RMSE		MSE		MAE		NSE	
	Training	Testing	Testing	Training	Testing	Training	Testing	Testing	Training	Testing
Wonosari II	0,76	0,53	11,81	13,80	139,68	190,63	9,17	10,08	0,73	0,52
Maesan	0,74	0,70	15,79	12,88	249,5	165,9	12,5	11,39	0,73	0,68
Ancar	0,89	0,50	13,50	15,20	183,78	232,32	11,17	12,5	0,76	0,48
Selolembu	0,90	0,59	8,83	13,43	78,09	180,54	7,02	9,72	0,88	0,44
Sentral	0,92	0,47	8,01	19,55	64,10	382,28	6,47	14,96	0,87	0,47
Klabang	0,97	0,63	6,32	13,38	40,	179,06	5,03	11,06	0,95	0,54
Grujugan	0,91	0,44	8,25	15,06	68,17	227,05	5,8	12,18	0,90	0,41
Kesemek	0,56	0,25	17,2	13,7	27,08	203,69	4,19	10,88	0,94	0,33
Kejayaan	0,41	0,24	21,65	17,11	295,99	187,9	14,51	10,56	0,45	0,24
Clangap	0,85	0,56	10,92	15,46	120,43	239,3	8,81	12,87	0,84	0,52
Wonosroyo	0,94	0,58	6,69	12,30	44,81	151,77	5,72	10,07	0,89	0,56
Wonosari	0,72	0,44	11,59	15,22	134,48	231,88	9,13	13,08	0,72	0,44
Sukokerto	0,73	0,57	15,83	18,23	250,81	332,56	13,46	14,75	0,66	0,56
Maskuning	0,72	0,49	10,97	14,33	120,47	205,61	8,78	11,63	0,70	0,48
Jero	0,80	0,41	13,93	11,84	140,21	183,78	9,87	11,06	0,73	0,40
Pakistan	0,93	0,48	7,30	19,10	53,55	364,96	5,98	15,4	0,88	0,42
Tlogo	0,71	0,55	13,02	18,78	169,69	352,79	10,16	14,68	0,71	0,46
Pinang pait	0,94	0,57	6,89	13,8	47,53	190,56	5,45	11,11	0,89	0,56
Rata Rata Wilayah	0,87	0,72	7,87	9,48	61,81	90	6,37	7,81	0,86	0,70



Gambar 9. Grafik R^2 Terhadap Nilai Korelasi Tiap Stasiun



Gambar 10. Grafik R^2 Terhadap Nilai NSE Tiap Stasiun



Gambar 11. Grafik RMSE Terhadap Nilai MAE Tiap Stasiun

Secara keseluruhan, grafik Gambar 9 menunjukkan hubungan yang berbanding lurus antara R^2 dan korelasi, di mana nilai yang lebih tinggi pada satu metrik sering kali diikuti oleh nilai yang tinggi pada metrik lainnya. Korelasi yang baik dalam training dan testing menunjukkan bahwa model Anda memiliki kemampuan yang baik untuk memprediksi curah hujan di sebagian besar stasiun hujan.

Berdasarkan grafik pada Gambar 10 menunjukkan bahwa NSE dan R^2 memiliki hubungan positif, namun NSE memberikan evaluasi tambahan terkait dengan ketepatan model dalam memprediksi nilai curah hujan yang tepat. Jika melihat rerata keseluruhan Gambar 11, nilai RMSE sedikit lebih tinggi daripada MAE, baik untuk training maupun testing. Ini menunjukkan bahwa meskipun ada beberapa kesalahan besar yang mempengaruhi hasil, kesalahan rata-rata di seluruh stasiun cenderung cukup stabil dan tidak terlalu terpengaruh oleh outlier besar. Namun, perbedaan

antara RMSE testing dan MAE testing menunjukkan bahwa ada beberapa titik di mana model menghadapi kesulitan dengan data baru (testing).

Pada data tabel diatas merupakan evaluasi matriks peforma model dari pemodelan curah hujan Satelit NOAA Grid 1x1 dengan beberapa pos hujan sebagai acuan dalam apakah model menghasilkan output yang baik. NSE berkisar antara 0,57 -0,36 yang menyatakan bahwa NSE model baik (Saura et al., 2018).; dengan R dengan rentang 0,76-0,49 menyatakan model mempunyai korelasi yang baik dan R kuadrat yang berkisar antara 0,58-0,24 menyatakan bahwa model mempunyai hubungan positif kuat dan positif sedang.

PEMBAHASAN

Berdasarkan hasil penelitian, pemodelan curah hujan menggunakan algoritma Long Short-Term Memory (LSTM) terbukti sangat direkomendasikan dalam pengembangan pengambilan data curah hujan. Model LSTM, yang dilatih menggunakan data satelit NOAA beresolusi spasial tinggi sebagai input, serta data observasi sebagai target, menunjukkan performa yang cukup baik dengan nilai Nash-Sutcliffe Efficiency (NSE) berkisar antara 0,57 hingga 0,36, koefisien korelasi (R) antara 0,76 hingga 0,49, dan koefisien determinasi (R^2) antara 0,58 hingga 0,24. Meskipun hasil prediksi belum sepenuhnya optimal, nilai-nilai ini mengindikasikan bahwa LSTM memiliki kemampuan yang signifikan dalam menangkap pola kompleks curah hujan dari data deret waktu.

Keunggulan LSTM dalam menyimpan dan memproses informasi jangka panjang menjadikannya unggul dalam menghadapi tantangan kehilangan data atau kesalahan pencatatan yang sering ditemui dalam metode konvensional. Oleh karena itu, pendekatan berbasis LSTM direkomendasikan sebagai alternatif andal untuk memprediksi curah hujan, khususnya dalam pengembangan pengambilan data yang lebih terbarukan dan efisien melalui integrasi data satelit. Potensi Penggunaan LSTM untuk Model Hidrologi sudah banyak diterapkan. Dari referensi berbagai jurnal. LSTM telah terbukti menjadi salah satu metode unggulan dalam pemodelan hidrologi, dengan sejumlah penelitian yang menunjukkan hasil yang sangat baik dalam memprediksi peristiwa hidrologi, seperti banjir dan kekeringan, bahkan dalam kondisi data yang sangat kompleks (Kratzert et al., 2018) ; (Li et al., 2021) ; (Yokoo et al., 2022)

Pada penelitian sebelumnya, prediksi curah hujan di daerah subtropis (China) menggunakan LSTM. LSTM dapat mempelajari dan memprediksi fluktuasi curah hujan dengan lebih akurat. Selain itu, ketika dikombinasikan dengan mekanisme attention, LSTM dapat lebih fokus pada variabel atau periode waktu yang lebih relevan dalam membuat prediksi, sehingga meningkatkan performanya secara signifikan dibandingkan metode prediksi tradisional maupun algoritma pembelajaran mesin lainnya, seperti regresi linear, decision trees, atau support vector machines, ARIMA dan lain lain (Dai et al., 2023)

Hasil penelitian ini juga serupa dengan hasil pada penelitian yang telah dilakukan di Sao Paulo Brazil (Fouotsa Manfouo et al., 2023) bahwa Metode Deep Learning LSTM sangat baik dengan akurasi yang tinggi dalam memodelkan curah hujan di berbagai setiap stasiun penakar hujan. Demikian halnya dengan penerapan LSTM di DAS Sampean Baru Kabupaten Bondowoso Jawa Penelitian ini menunjukkan bahwa Metode Deep Learning direkomendasikan untuk digunakan di tempat lain.

KESIMPULAN

Pemodelan curah hujan berbasis citra satelit NOAA dengan algoritma LSTM memberikan hasil prediksi hujan yang efektif dalam menangkap pola hubungan yang kompleks curah hujan akibat dinamika sirkulasi atmosfer. Model LSTM dalam memprediksi curah hujan memberikan akurasi yang cukup baik. Keunggulan LSTM dalam memproses data deret waktu dan menangani ketidakpastian data menjadikannya alternatif andal untuk pengembangan pengambilan data curah hujan secara lebih efisien dan akurat. Penelitian lanjutan bisa dilakukan dan membandingkan akurasi model LSTM dalam memprediksi curah hujan tipe hujan monsunial dan tipe hujan equatorial.

DAFTAR PUSTAKA

- Dai, Z., Zhang, M., Nedjah, N., Xu, D., & Ye, F. (2023). A Hydrological Data Prediction Model Based on LSTM with Attention Mechanism. *Water (Switzerland)*, 15(4). doi: 10.3390/w15040670
- DiPietro, R., & Hager, G. D. (2020). Deep learning: RNNs and LSTM. In *Handbook of medical image computing and computer assisted intervention* (pp. 503–519). Elsevier.

- Ehrlich, D., Estes, J. E., & Singh, A. (1994). Review article applications of NOAA-AVHRR 1 km data for environmental monitoring. In *International Journal of Remote Sensing* (Vol. 15, Issue 1, pp. 145–161). doi: 10.1080/01431169408954056
- Febrianti, N. (2018). Hubungan pemanasan global dengan kondisi suhu udara dan curah hujan di indonesia. *LAPAN. Bandung*, p. 299.
- Fouotsa Manfouo, N. C., Potgieter, L., Watson, A., & Nel, J. H. (2023). A Comparison of the Statistical Downscaling and Long-Short-Term-Memory Artificial Neural Network Models for Long-Term Temperature and Precipitations Forecasting. *Atmosphere*, 14(4). doi: 10.3390/atmos14040708
- Gutman, G. G. (1994). Global data on land surface parameters from NOAA AVHRR for use in numerical climate models. *Journal of Climate*, 7(5), 669–680.
- Hidayat, A. K., & Empung, E. (2016). Analisis curah hujan efektif dan curah hujan dengan berbagai periode ulang untuk wilayah Kota Tasikmalaya dan Kabupaten Garut. *Jurnal Siliwangi Seri Sains Dan Teknologi*, 2(2).
- Kartika, D., Nomeritae, & Kamiana, I. M. (2023). *Evaluasi Data Curah Hujan Satelit TRMM Dan GPM Terhadap Data Curah Hujan Observasi Di Kalimantan Tengah* (Vol. 11, Issue 1). Palangkaraya.
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall–runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, 22(11), 6005–6022.
- Li, W., Kiaghadi, A., & Dawson, C. (2021). High temporal resolution rainfall–runoff modeling using long-short-term-memory (LSTM) networks. *Neural Computing and Applications*, 33(4), 1261–1278.
- Lumbanraja, R. L. S., & Saragih, I. J. A. (2023). Analisis hidrologi berdasarkan periode ulang parameter curah hujan untuk perhitungan kapasitas bendungan Lau Simeme. *Prosiding Seminar Nasional Fisika*, 2(1), 250–262.
- Marta, S. D., Suhartanto, E., & Fidari, J. S. (2022). Validasi Data Curah Hujan Satelit dengan Data Stasiun Hujan di DAS Ngasinan Hulu, Kabupaten Trenggalek, Jawa Timur. *Jurnal Teknologi Dan Rekayasa Sumber Daya Air*, 3(1), 35–45.
- Mubarok, H. N., Septiani, D., Kurnia, M. B., Fadilah, H., Putri, H. L., Irawati, F. D., Permana, R. D., & Badri, R. M. (2024). Interpolasi Curah Hujan Menggunakan Model Spatial Ordinary Kriging di Kabupaten Tulang Bawang Barat. *Prosiding Seminar Nasional Sains Data*, 4(1), 973–981.
- Nahapetyan, Y. (2019). The benefits of the Velvet Revolution in Armenia: Estimation of the short-term economic gains using deep neural networks. *Central European Economic Journal*, 6(53), 286–303. doi: 10.2478/ceej-2019-0018
- Parasyris, A., Alexandrakis, G., Kozyrakis, G. V., Spanoudaki, K., & Kampanis, N. A. (2022). Predicting meteorological variables on local level with SARIMA, LSTM and hybrid techniques. *Atmosphere*, 13(6), 878.
- Pettit, R. W., Fullen, R., Cheng, C., & Amos, C. I. (2021). Artificial intelligence, machine learning, and deep learning for clinical outcome prediction. In *Emerging Topics in Life Sciences* (Vol. 5, Issue 6, pp. 729–745). Portland Press Ltd. doi: 10.1042/ETLS20210246
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. In *Neural Networks* (Vol. 61, pp. 85–117). Elsevier Ltd. doi: 10.1016/j.neunet.2014.09.003
- Vo, T. Q., Kim, S.-H., Nguyen, D. H., & Bae, D.-H. (2023). LSTM-CM: a hybrid approach for natural drought prediction based on deep learning and climate models. *Stochastic Environmental Research and Risk Assessment*, 37(6), 2035–2051.
- Wang, K., Qi, X., & Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251. doi: 10.1016/j.apenergy.2019.113315
- Yokoo, K., Ishida, K., Ercan, A., Tu, T., Nagasato, T., Kiyama, M., & Amagasaki, M. (2022). Capabilities of deep learning models on learning physical relationships: Case of rainfall-runoff modeling with LSTM. *Science of The Total Environment*, 802, 149876.
- Yudhana, A., Rahmayanti, J., Akbar, S. A., Mukhopadhyay, S., & Karas, I. R. (2019). Modification of manual raindrops type observatory ombrometer with ultrasonic sensor HC-SR04. *International Journal of Advanced Computer Science and Applications*, 10(12), 277–281.
- Zhang, C., Zeng, J., Wang, H., Ma, L., & Chu, H. (2020). Correction model for rainfall forecasts using the LSTM with multiple meteorological factors. *Meteorological Applications*, 27(1), e1852.