

PENERAPAN *DEEP LEARNING* UNTUK PREDIKSI TINGGI MUKA AIR SUNGAI DENGAN MEMPERTIMBANGKAN FAKTOR OPERASI BENDUNGAN

Mamad Tamamadin^{1*}, Oky Subrata², dan Isnan Fauzan Akrom³

¹Kelompok Keahlian Sains Atmosfer, Institut Teknologi Bandung

²Balai Wilayah Sungai Sumatera VI, Direktorat Jenderal Sumber Daya Air, Kementerian Pekerjaan Umum

³Sub Direktorat Sistem Informasi Sumber Daya Air, Dir. Bina Teknik SDA, Kementerian Pekerjaan Umum

*mamad108@itb.ac.id

Pemasukan: 30 Oktober 2025

Perbaikan: 22 Desember 2025

Diterima: 29 Desember 2025

Intisari

Indonesia merupakan wilayah yang rentan banjir, sehingga diperlukan deteksi dini melalui prediksi ketinggian air sungai yang akurat dengan memanfaatkan metode pemodelan yang cepat. Studi ini bertujuan untuk mengembangkan model prediksi tinggi muka air (TMA) akurasi tinggi di beberapa pos pemantauan aliran sungai dengan memanfaatkan sejumlah dataset spasial curah hujan dan informasi debit keluaran bendungan sebagai variabel input dalam model *deep learning* menggunakan kombinasi CNN dan LSTM. Model ini diuji dengan menggunakan dua skenario, yaitu dengan dan tanpa operasi bendungan, dan performa prediksi TMA tersebut dievaluasi di tiga lokasi pos (Katulampa, Kampung Kalapa, dan MT. Haryono). Evaluasi awal hanya dengan menggunakan input spasial curah hujan terhadap salah satu pos di MT. Haryono menunjukkan bahwa nilai korelasi sebesar 0.65, MAE sebesar 0.412, dan NSE sebesar 0.58. Setelah penambahan jumlah citra curah hujan dan integrasi data debit berdasarkan skenario operasi bendungan, terjadi peningkatan akurasi yang signifikan di seluruh pos tersebut, nilai korelasi meningkat menjadi 0.88, nilai MAE menurun menjadi 0.137 m dan NSE meningkat menjadi 0.85. Hasil ini mengonfirmasi bahwa integrasi informasi operasi bendungan sebagai variabel input menghasilkan performa prediksi yang lebih baik dibandingkan pendekatan yang hanya menggunakan data curah hujan, sesuai konsep dasar hubungan antara hujan-aliran dan pengaruh kendali bendungan.

Kata kunci : prediksi tinggi muka air, *deep learning*, debit keluaran bendungan, CNN, LSTM

Latar Belakang

Wilayah Indonesia merupakan wilayah rentan terhadap bencana banjir. Setiap tahun bencana banjir terjadi di berbagai tempat di wilayah Indonesia. Menurut data yang dihimpun dalam Data Informasi Bencana Indonesia (DIBI)-BNPB, terdapat lebih dari 49.128 kejadian bencana hidrometeorologi pada periode tahun 2008 hingga 2025 dan lebih dari 35% (17.208)

kejadian banjir yang menjadi salah satu bencana hidrometeorologi dengan jumlah tertinggi (BNPB, 2025).

Deteksi dini banjir melalui prediksi ketinggian air sungai yang akurat sangat penting untuk mendukung mitigasi yang cepat dan efektif (Alfieri et al., 2018; Perera et al., 2019). Berbagai metode prediksi telah dikembangkan, dan dengan kemajuan teknologi, pemodelan kini banyak memanfaatkan *machine learning*. Dalam prediksi tinggi muka air (TMA) menggunakan deep learning, faktor operasi bendungan berperan besar terhadap akurasi karena pengaturan aliran dapat menyebabkan fluktuasi debit dan TMA yang tidak selalu sejalan dengan kondisi hidrometeorologis. Pelepasan air yang dinamis akibat faktor teknis dan manajerial menciptakan pola aliran kompleks yang sulit diprediksi tanpa mempertimbangkan variabel operasi bendungan, sehingga dapat menimbulkan deviasi signifikan di wilayah hilir.

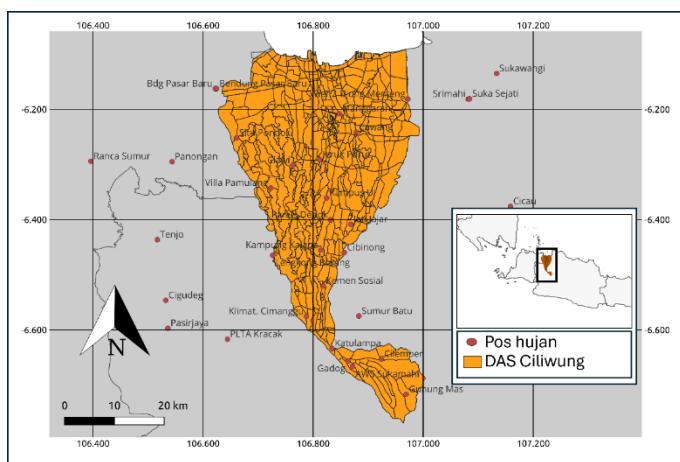
Deep learning telah banyak digunakan dalam masalah teknik dan sains, dan khususnya pemodelan proses hidrologi nonlinier (Chen and Adams, 2006; Pradhan, Tingsanchali and Shrestha, 2020; Shen and Lawson, 2021). Salah satu contoh model *deep learning* yang banyak digunakan adalah *artificial neural network* (ANN) dimana model tersebut meniru sistem kerja jaringan saraf biologis otak manusia dengan memetakan hubungan nonlinier kompleks dan proses yang melekat di antara beberapa variabel yang mempengaruhi melalui struktur modelnya (Jensen, Hardin and Yu, 2009). Kinerja dari berbagai Teknik machine learning dan deep learning dievaluasi, termasuk *Random Forest*, *Support Vector Machine*, dan LSTM, dalam memprediksi TMA dengan menggunakan data historis hidrologi (Ayus, Natarajan and Gupta, 2023). Hasil studi menunjukkan bahwa LSTM memberikan akurasi prediksi tertinggi dibandingkan metode lainnya, terutama dalam menangkap pola temporal yang kompleks pada data muka air. Pendekatan peningkatan model *deep learning* diusulkan untuk prediksi TMA sungai dengan mengintegrasikan metode jaringan kompleks guna merefleksikan hubungan spasial dan temporal antar stasiun pengamatan yang menunjukkan bahwa penggabungan struktur jaringan dalam arsitektur model meningkatkan akurasi prediksi secara signifikan (Kim et al., 2022). Berbagai algoritma *machine learning* dieksplorasi seperti *Random Forest*, XGBoost, dan *Gradient Boosting* untuk meramalkan TMA di Sungai Muda, Malaysia (Adli Zakaria et al., 2023). Pendekatan gabungan CNN-LSTM juga dilakukan untuk memprediksi TMA dan kualitas air secara simultan dengan memanfaatkan fitur spasial dan temporal dari data hidrologi (Baek et al., 2020). Beberapa model *deep learning* diterapkan, termasuk LSTM dan GRU, untuk memprediksi TMA Sungai Kien Giang yang memberikan hasil prediksi yang paling akurat (Hieu et al., 2023).

Meskipun studi sebelumnya menggunakan *deep learning* untuk memprediksi TMA dengan akurasi tinggi, namun umumnya belum mempertimbangkan pengaruh operasi bendungan. Padahal, bendungan berperan penting dalam mengatur aliran melalui mekanisme buka-tutup pintu air dan pelepasan yang dinamis, sehingga model tanpa variabel ini berpotensi bias, terutama di wilayah hilir. Studi ini menerapkan model dengan memasukkan data operasional bendungan, curah hujan yang terukur oleh *ground station* yang diproses menjadi peta isohiet, serta data TMA di beberapa titik. Pendekatan ini memungkinkan prediksi yang lebih akurat dengan mempertimbangkan pengaruh fisik dan operasional bendungan terhadap dinamika sungai.

Metodologi Studi

Data

Studi ini menggunakan Daerah Aliran Sungai (DAS) Ciliwung sebagai studi kasus untuk penerapan dan pengujian algoritma *deep learning* dalam memprediksi tinggi muka air (TMA) sungai. DAS ini dipilih karena memiliki data telemetri curah hujan dan TMA yang relatif lengkap. Peta DAS dan distribusi pos curah hujan telemetri ditampilkan pada Gambar 1. Data yang digunakan terdiri dari dua jenis, yaitu TMA sungai dan curah hujan yang diukur melalui pos duga air serta AWS telemetri dengan resolusi waktu per jam selama periode 1 Juni 2021 hingga 30 Juni 2024. Selain itu, data curah hujan harian dari pos manual juga digunakan untuk memverifikasi kualitas data hujan telemetri.



Gambar 1. Daerah aliran sungai Ciliwung dan beberapa pos hujan telemetri di sekitarnya

Pengujian data telemetri curah hujan dan TMA dilakukan dengan cara:

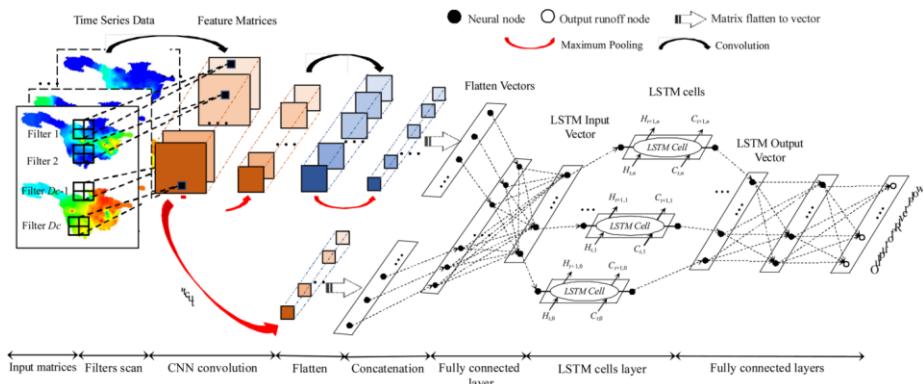
- Error* teridentifikasi dari nilai yang sama dengan jumlah yang sangat banyak
- Error* teridentifikasi dari nilai yang sangat ekstrim. Batas maksimum intensitas curah hujan ditentukan dengan merujuk pada studi Samsudin (2015), yang mencatat intensitas 24,61~48,87 mm/jam untuk periode ulang 2~100 tahun. Karena data penelitian ini kurang dari 5 tahun, digunakan batas maksimum intensitas periode ulang 5 tahun, yaitu 30,57 mm/jam.
- Nilai akumulasi harian dari curah hujan telemetri dibandingkan dengan data dari pos hujan manual terdekat

Dari pengujian terhadap data telemetri curah hujan dan TMA tersebut, maka data yang terindikasi *error* selanjutnya dikeluarkan dari dataset untuk melakukkan training terhadap algoritma *deep learning*.

Metode Deep Learning untuk Prediksi TMA Sungai

Dalam kajian ini, kombinasi *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) digunakan untuk memprediksi ketinggian air. Kedua algoritma ini dapat menangkap fitur spasial dan temporal dari data sekuensial. CNN merupakan algoritma *deep learning* yang paling umum dan telah banyak diterapkan pada bidang seperti pengenalan citra, translasi, dan analisis ucapan (Alzubaidi et al., 2021). CNN dirancang untuk mengenali

pola pada citra, dan pada studi ini digunakan dalam arsitektur CNN-LSTM dengan dua input berbeda: data curah hujan berdimensi 251×141 dan input ketinggian air. Model CNN terdiri dari tiga lapisan konvolusional, dua pooling, dan dua *fully connected*, di mana hasil ekstraksi fitur dari citra dan vektor digabungkan untuk menghasilkan prediksi ketinggian air. CNN mengekstraksi pola gambar melalui lapisan konvolusional yang memproses data dalam bentuk matriks multidimensi, dengan setiap neuron terhubung pada area kecil agar komputasi efisien dan overfitting berkurang. Proses ekstraksi fitur diatur oleh parameter ukuran *filter*, *padding*, dan *stride* yang menentukan area pemindaian, perlindungan tepi, serta jarak pergerakan filter.



Gambar 0. Arsitektur jaringan CNN dan LSTM untuk memprediksi ketinggian air sungai yang diadopsi dari penelitian sebelumnya (Li et al., 2022b)

$$OH = \frac{IH + 2PH - FH}{SH} + 1 \quad (1)$$

$$OW = \frac{IW + 2PW - FW}{SW} + 1 \quad (2)$$

dimana, OH adalah tinggi keluaran, IH adalah tinggi masukan, FH adalah tinggi filter, SH adalah tinggi langkah, OW adalah lebar keluaran, IW adalah lebar masukan, PH adalah tinggi dari *padding*, PW adalah lebar *padding*, FW adalah lebar *filter*, dan SW adalah lebar arah langkah.

Secara umum, lapisan konvolusional memerlukan fungsi aktivasi untuk mengubah sinyal dari linier menjadi non-linier. Fungsi *rectified linear unit* (ReLU) digunakan sebagai fungsi aktivasi untuk meningkatkan kecepatan dan akurasi komputasi dibandingkan dengan fungsi aktivasi lainnya (misalnya fungsi *tangent sigmoid*). Fungsi ReLU mencegah masalah gradien hilang dengan menurunkan gradien *training* secara eksponensial. Fungsi ReLU didefinisikan dalam persamaan berikut:

$$f(x) = \max(0, x) \quad (3)$$

di mana, $f(x)$ adalah keluaran ReLU dan x adalah sinyal masukan.

Lapisan *max-pooling* digunakan untuk mengekstraksi fitur invarian dengan tingkat konvergensi yang efisien. Lapisan ini dapat mengurangi nilai-nilai non-maksimal dengan melakukan *non-linear downsampling* yang dapat mengurangi sampling komputasi selama

proses CNN. *Flatten Layer* digunakan untuk meratakan *output* dari lapisan CNN menjadi vektor satu dimensi. Formula matematik untuk tahap ini adalah sebagai berikut.

$$\text{Flatten}(x) = \text{reshape}(X, [-1]) \quad (4)$$

Setelah itu pengolahan data dilanjutkan pada algoritma LSTM (DiPietro and Hager, 2020). LSTM memiliki beberapa *gate* (gerbang) yang mengendalikan aliran informasi.

a. *Forget Gate*: $f(x) = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$ (5)

b. *Input Gate*: $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$ (6)

c. *Candidate Memory Cell*: $C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$ (7)

d. *Output Gate*: $o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$ (8)

e. *Cell State Update*: $C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$ (9)

f. *Hidden State Update*: $h_t = o_t * \tanh(C_t)$ (10)

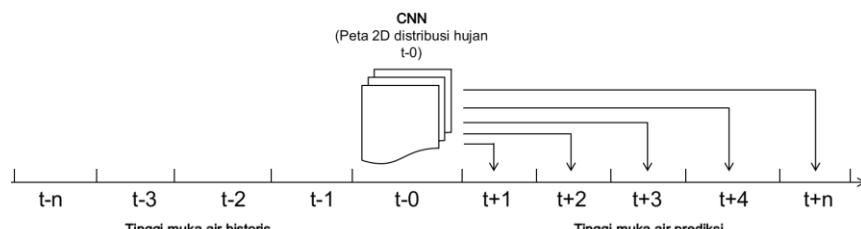
dimana σ adalah fungsi aktivasi sigmoid, W adalah bobot, dan b adalah bias yang dipelajari.

Sebagai tahap akhir dari kombinasi CNN-LSTM ini, terdapat *dense layer* yang berfungsi untuk menghasilkan output prediksi TMA dengan formula sebagai berikut:

$$y = W \cdot h + b \quad (11)$$

Dimana W adalah bobot yang dipelajari, b adalah bias, h adalah input dari LSTM, dan y adalah output (prediksi).

Untuk meningkatkan akurasi, dilakukan berbagai uji parameter pada model CNN-LSTM. Percobaan meliputi variasi ukuran citra (128, 64, 32), jumlah plot curah hujan per sampel, nilai normalisasi (255–150), *batch size* (32–128), dan *epoch* (30–150). Plot curah hujan dibuat dengan latar hitam dan intensitas hujan semakin tinggi ditampilkan semakin putih.



Gambar 3. Konsep prediksi TMA sungai. Input didasarkan pada data TMA historis dan peta 2 dimensi dari distribusi hujan untuk prediksi TMA pada jam ke 1, 2, hingga n.

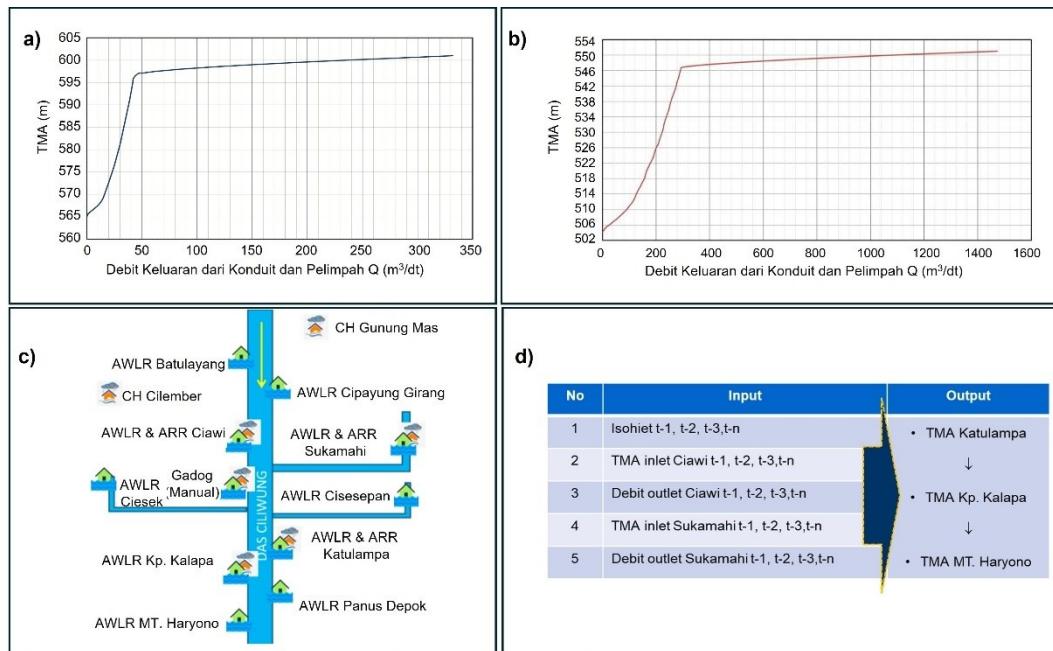
Seperti ditunjukkan pada Gambar 3, studi ini menguji pengaruh curah hujan terhadap kenaikan TMA menggunakan peta 2D distribusi hujan dan data historis. Pengujian dilakukan dengan jeda waktu 0~7 jam untuk menentukan selang waktu prediksi paling akurat. Hasilnya digunakan sebagai dasar penyusunan model prediksi TMA berdasarkan selisih waktu antara hujan dan respons muka air sungai (lihat persamaan 12).

$$\Delta t = t_{wp} - t_{r2d} \quad (12)$$

dimana Δt adalah selisih dari dua langkah waktu, t_{wp} adalah langkah waktu prediksi TMA, dan t_{r2d} adalah langkah waktu peta spasial curah hujan.

Studi ini menggunakan metode interpolasi *Inverse Distance Weighting* (IDW) pada data curah hujan telemetri sebanyak 26.280 waktu sebagai dataset pelatihan deep learning. Metode interpolasi IDW digunakan karena kemudahan dan kecepatan pengolahannya (Boke and Boke, 2017; Jiang et al., 2025).

Metodologi pada Gambar 4 mengintegrasikan data *real-time* untuk memprediksi TMA Sungai Ciliwung dengan mempertimbangkan pengaruh debit keluar Bendungan Ciawi dan Sukamahi. Input berupa data isohiet, TMA inlet, dan debit keluaran digunakan untuk memprediksi TMA di Katulampa, Kampung Kalapa, dan MT. Haryono. Hubungan nonlinier antara TMA dan debit menunjukkan pengaruh operasi bendungan, sehingga model diharapkan merepresentasikan dinamika sungai lebih akurat dalam mendukung peringatan dini banjir.



Gambar 4. *Deep Learning* untuk Prediksi TMA dengan Memasukkan Faktor debit aliran dari 2 Bendungan Kering (*dry dam*)

Gambar 4 menyajikan grafik hubungan TMA dan debit keluar bendungan Sukamahi (a), grafik hubungan TMA dan debit keluar bendungan Ciawi (b), struktur aliran untuk masing-masing bendungan di Ciliwung (c), dan konsep input dan output pada deep learning dengan memasukkan faktor bendungan (d). Vektor yang terhubung penuh dalam algoritma CNN memiliki *loss function* untuk menghitung kesalahan antara nilai yang diamati dan yang disimulasikan dengan membuat vektorisasi sinyal input. MSE digunakan sebagai *fungsi loss* dalam penelitian yang digunakan untuk menghitung *error* antara nilai yang disimulasikan dan yang diamati. Persamaan MSE adalah sebagai berikut:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - O_i)^2 \quad (13)$$

dimana, Y_i adalah hasil simulasinya, O_i adalah data yang diamati, dan N adalah jumlah kumpulan data.

Keakuratan prediksi ketinggian air juga dievaluasi menggunakan koefisien determinasi (R^2), efisiensi *Nash-Sutcliffe* (*NSE*) dan *mean square error* (*MSE*). Persamaan R^2 dan *NSE* didefinisikan sebagai berikut:

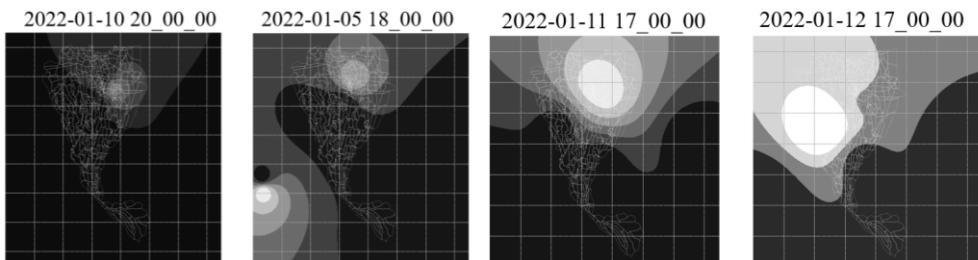
$$R^2 = \left[\frac{\sum_{i=1}^n (O_i - \bar{O}_1)(P_i - \bar{P}_1)}{\sum_{i=1}^n (O_i - \bar{O}_1)^2 (P_i - \bar{P}_1)^2} \right] \quad (14)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_1)^2} \quad (15)$$

dimana n adalah jumlah dataset yang memiliki TMA (m), P_i menunjukkan hasil prediksi, \bar{O}_1 adalah rata-rata dari data yang diamati dan O_i mewakili data yang diamati.

Hasil Studi dan Pembahasan

Gambar 5 menampilkan isohiet curah hujan per jam dari pos telemetri di hulu DAS Ciliwung. Sebanyak 26.280 plot periode 2022-2024 menunjukkan sebaran spasial intensitas hujan. Data ini penting untuk pelatihan model karena merepresentasikan pola hujan secara spasial, membantu model deep learning mengenali hubungan kompleks antara hujan dan TMA di hilir.



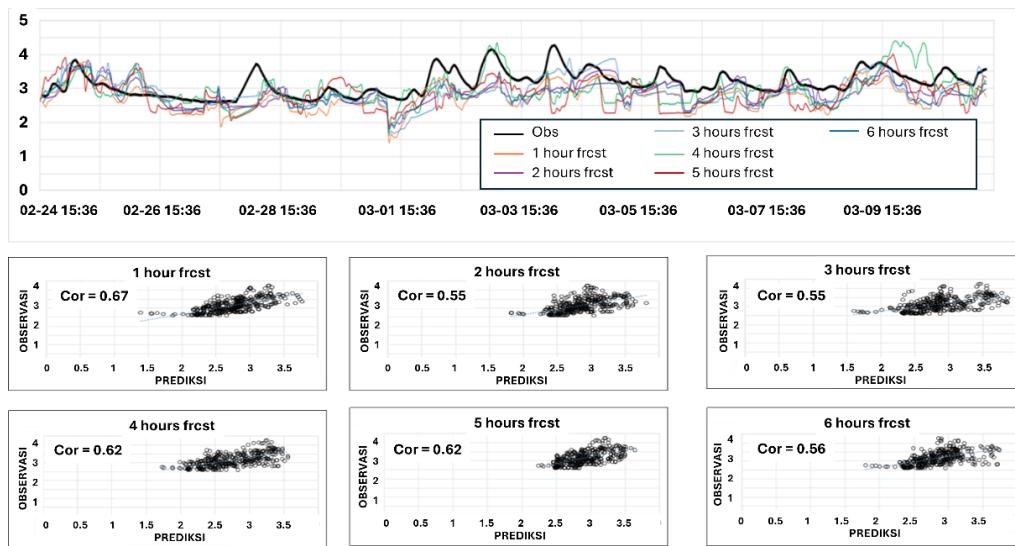
Gambar 5. Isohiet data curah hujan dari pos telemetri

Gambar 6 menunjukkan hasil prediksi TMA menggunakan model *deep learning* dengan berbagai *lead time* atau waktu prakiraan, yaitu 1 hingga 6 jam ke depan. Grafik di bagian atas menggambarkan perbandingan antara data observasi (garis hitam tebal) dan hasil prediksi model pada masing-masing waktu prediksi (1~6 jam), yang ditampilkan dengan garis warna berbeda. Secara umum, model mampu mengikuti tren fluktuasi TMA, meskipun terdapat deviasi kecil pada beberapa puncak nilai.

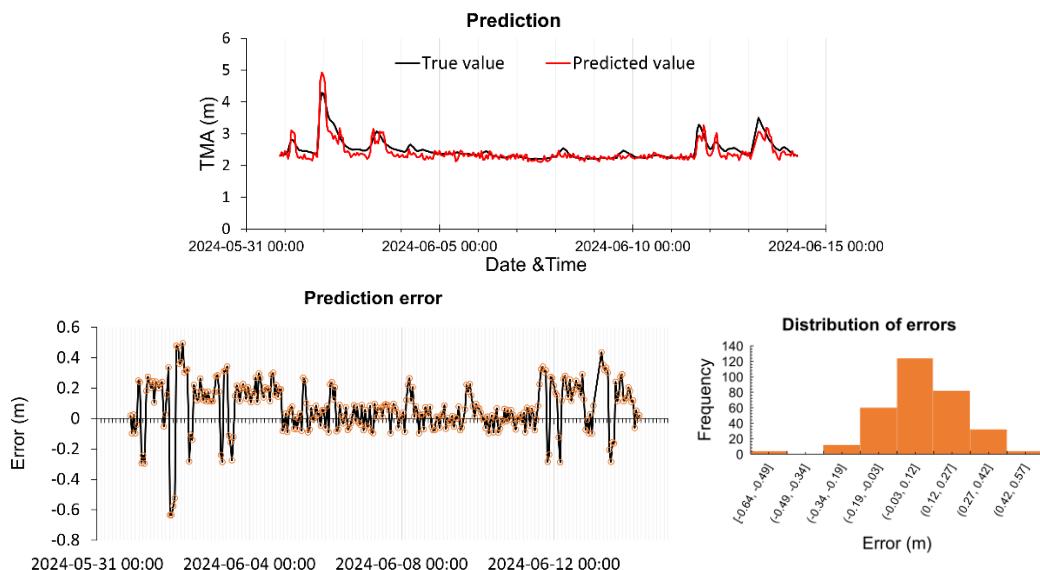
Sementara itu, enam *scatter plot* di bagian bawah memperlihatkan hubungan antara nilai prediksi dan nilai observasi untuk masing-masing *lead time*. Nilai koefisien korelasi Pearson (rr) berkisar antara 0.55 hingga 0.67, dengan akurasi tertinggi pada prediksi 1 jam ke depan ($rr = 0.67$) dan menurun secara bertahap seiring bertambahnya lead time, misalnya menjadi $rr = 0.55$ pada 2 dan 3 jam, dan $rr = 0.56$ pada 6 jam. Hasil ini menunjukkan bahwa model memiliki kemampuan prediksi yang cukup baik dalam jangka pendek, namun akurasinya cenderung menurun seiring waktu, yang merupakan karakteristik umum dalam prediksi hidrologi berbasis data.

Gambar 7 menunjukkan hasil prediksi TMA di MT. Haryono setelah model memasukkan faktor debit keluar dari bendungan sebagai salah satu variabel input. Grafik utama (TMA *prediction*) memperlihatkan bahwa prediksi model (garis merah) secara umum mampu mengikuti pola fluktuasi nilai observasi (garis hitam), termasuk dalam menangkap lonjakan TMA pada saat-saat tertentu. Hal ini menunjukkan bahwa integrasi data debit keluar dari

bendungan memberikan kontribusi positif dalam meningkatkan sensitivitas model terhadap perubahan mendadak akibat pelepasan air.



Gambar 6. Prediksi TMA di pos MT Haryono dengan menggunakan ukuran pixel 64 dan ukuran sampel 20

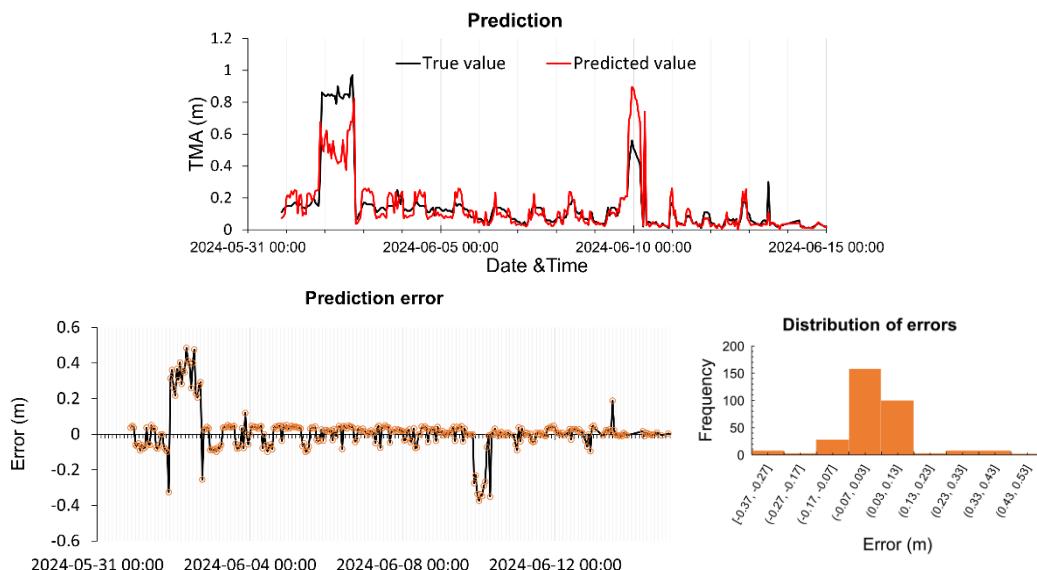


Gambar 7. Prediksi TMA di pos MT Haryono dengan menggunakan ukuran pixel 64 dan ukuran sampel 20 setelah model memasukkan faktor debit keluar dari bendungan

Grafik *prediction errors* di bagian kiri bawah memperlihatkan selisih antara nilai observasi dan prediksi terhadap waktu, dengan sebagian besar error berada dalam rentang ± 0.3 meter, menandakan bahwa model cukup stabil dalam menjaga akurasi selama periode pengujian. Sementara itu, histogram *distribution of errors* menunjukkan distribusi galat yang bersifat simetris dan cenderung terpusat di sekitar nol, yang menandakan tidak adanya bias sistematis dalam hasil prediksi. Secara keseluruhan, hasil ini mendukung hipotesis bahwa

mempertimbangkan faktor operasi bendungan dapat meningkatkan performa model prediksi TMA.

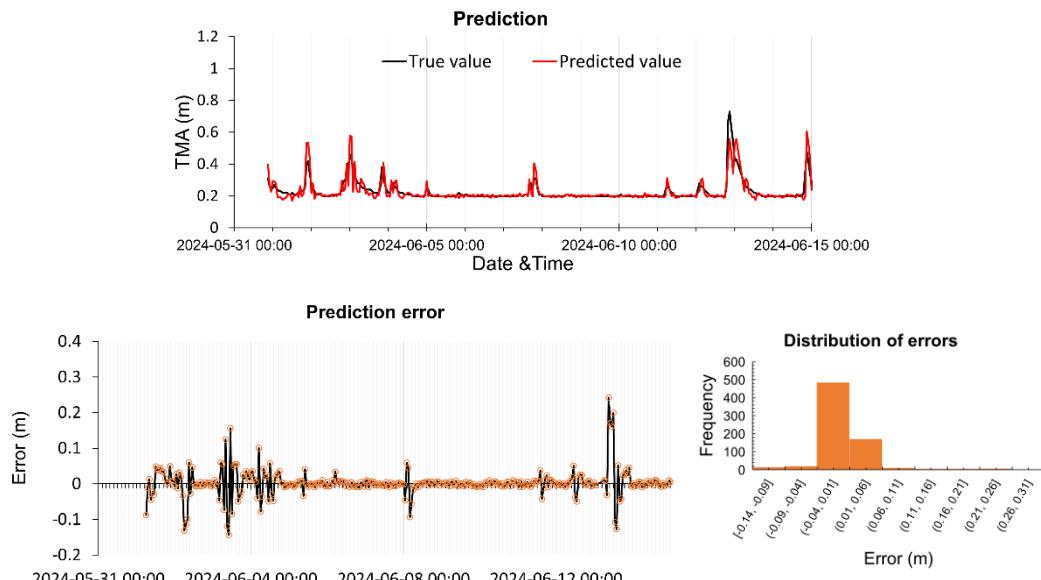
Gambar 8 dan 9 menampilkan hasil prediksi TMA di Pos Katulampa dan Kampung Kalapa setelah memasukkan variabel debit keluar bendungan ke dalam model. Di Katulampa, model mampu menangkap tren umum observasi meski kurang akurat pada puncak TMA; sebagian besar galat berada di bawah ± 0.2 m dengan distribusi simetris di sekitar 0~0.1 m, menunjukkan stabilitas dan minim bias. Sementara itu, di Kampung Kalapa, garis prediksi (merah) berhasil mengikuti fluktuasi nilai aktual (hitam), terutama saat terjadi lonjakan TMA tajam, menandakan bahwa penambahan variabel debit bendungan meningkatkan kemampuan model mengenali dinamika aliran mendadak akibat pelepasan air.



Gambar 8. Prediksi TMA di pos Katulampa setelah model memasukkan faktor debit keluar dari bendungan

Grafik *prediction errors* menunjukkan sebagian besar kesalahan berada pada rentang kecil (-0.1 hingga 0.1 m), dengan beberapa outlier saat puncak aliran. Ini menandakan model masih sulit menangkap lonjakan ekstrem, meski akurasinya membaik. Histogram kesalahan yang terpusat di sekitar nol menunjukkan tidak adanya bias signifikan. Secara keseluruhan, penambahan data debit bendungan meningkatkan akurasi prediksi TMA di hilir seperti di Kampung Kalapa.

Tabel 1 dan 2 menunjukkan perbandingan hasil uji akurasi model prediksi TMA di tiga pos pengamatan (Katulampa, Kampung Kalapa, dan MT. Haryono) sebelum dan sesudah penambahan jumlah *image* curah hujan serta variabel debit keluaran dari bendungan. Pada Tabel 1 (sebelum penambahan variabel), nilai korelasi (CC), *Mean Absolute Error* (MAE), dan *Nash-Sutcliffe Efficiency* (NSE) menunjukkan bahwa akurasi model bervariasi antar lokasi. Pos Kampung Kalapa memiliki performa paling baik (CC=0.82 dan NSE=0.71) dengan kesalahan prediksi rata-rata (MAE) paling kecil, yaitu 0.069 m. Sebaliknya, Pos MT. Haryono menunjukkan akurasi terendah, terutama dari sisi MAE yang sangat tinggi (0.412 m), yang mengindikasikan adanya deviasi besar antara prediksi dan data aktual.



Gambar 9. Prediksi TMA di pos Kp. Kalapa setelah model memasukkan faktor debit keluar dari bendungan

Tabel 1. Prediksi TMA sebelum penambahan jumlah image curah hujan dan faktor debit keluaran bendungan

Pos TMA	Uji Akurasi		
	CC	MAE	NSE
Katulampa	0.58	0.11	0.68
Kp. Kalapa	0.82	0.069	0.71
MT. Haryono	0.65	0.412	0.58

Tabel 2. Prediksi TMA setelah penambahan jumlah image curah hujan dan faktor debit keluaran bendungan

Pos TMA	Uji Akurasi		
	CC	MAE	NSE
Katulampa	0.83	0.062	0.75
Kp. Kalapa	0.82	0.020	0.81
MT. Haryono	0.88	0.137	0.85

Terlihat pada Tabel 1 dan 2, akurasi prediksi TMA yang ditunjukkan MAE di Kp. Kalapa selalu lebih tinggi dibandingkan Katulampa dan MT. Haryono dapat dijelaskan dari posisi geografis serta relevansi input model terhadap kondisi hidrologis. Kp. Kalapa berada di tengah aliran, sehingga pola TMA di titik ini merupakan hasil integrasi dari hulu (Katulampa) dan pengaruh bendungan Ciawi serta Sukamahi. Input berupa curah hujan spasial, TMA inlet, dan debit outlet bendungan lebih sesuai dengan kondisi di Kp. Kalapa, sehingga model CNN-LSTM mampu menangkap pola spasial-temporal dengan lebih baik. Sebaliknya, Katulampa lebih dipengaruhi oleh curah hujan lokal di hulu yang variabilitasnya tinggi, sementara MT. Haryono di hilir menghadapi kompleksitas tambahan seperti kontribusi anak sungai dan limpasan perkotaan.

Selain itu, kualitas data dan tingkat noise juga berperan. Data di Kp. Kalapa cenderung lebih konsisten karena aliran sudah tersaring oleh bendungan, sehingga pola TMA lebih stabil dan

mudah diprediksi. Di Katulampa, curah hujan ekstrem atau variabilitas kecil dapat menurunkan akurasi, sedangkan di MT. Haryono faktor antropogenik seperti urbanisasi dan sistem drainase kota menambah ketidakpastian.

Untuk skenario jumlah data 17,520 image (sebelum penambahan), kombinasi *hyperparameter* yang optimal cenderung menggunakan ukuran citra 64, normalisasi ke 255, *batch size* 64, dan *epoch* sekitar 100. Ukuran citra 64 menjaga keseimbangan antara detail spasial dan efisiensi komputasi, sementara normalisasi penuh (0-255) membantu stabilitas training. *Batch size* 64 cukup untuk menjaga generalisasi tanpa terlalu membebani memori, dan *epoch* 100 memberi waktu cukup bagi model CNN-LSTM untuk belajar pola spasial-temporal tanpa *overfitting*.

Sedangkan setelah penambahan *image* curah hujan menjadi 26,280, hasil lebih baik karena jumlah data yang lebih besar meningkatkan kemampuan model dalam mengenali variasi pola hujan dan respon hidrologis. Pada skenario ini, kombinasi optimal adalah ukuran citra 128, normalisasi ke 200, *batch size* 128, dan *epoch* 150. Ukuran citra lebih besar memungkinkan model memanfaatkan detail spasial tambahan, *batch size* 128 lebih stabil dengan data besar, dan *epoch* 150 memberi kesempatan model untuk konvergen dengan baik. Semakin banyak data, model CNN-LSTM dapat menangkap kompleksitas sistem hidrologi dengan lebih akurat, sehingga prediksi TMA menjadi lebih presisi. Di Katulampa, CC naik dari 0.58 ke 0.83, MAE turun ke 0.062 m, dan NSE ke 0.75; di MT. Haryono, NSE naik ke 0.85. Kinerja terbaik diperoleh di Kampung Kalapa (NSE 0.81; MAE 0.020 m), menunjukkan efektivitas kombinasi data hujan spasial dan debit bendungan. Selisih prediksi-observasi masih wajar, dipengaruhi faktor lapangan seperti pengaturan pintu air atau perubahan morfologi sungai, sehingga integrasi hasil model dengan pengetahuan lapangan tetap penting. Jumlah data spasial yang lebih besar berkontribusi pada peningkatan performa model, karena memperkaya representasi pola curah hujan dan aliran sungai yang dipelajari.

Hasil simulasi penerapan CNN-LSTM pada prediksi tinggi muka air (TMA) di DAS Ciliwung menunjukkan konsistensi dengan hasil penelitian sebelumnya, di mana peningkatan jumlah data dan resolusi spasial berkontribusi terhadap akurasi model yang lebih tinggi. Dua studi sebelumnya (Deng, Chen and Huang, 2022; Li et al., 2022a) menegaskan bahwa performa CNN-LSTM meningkat seiring bertambahnya data curah hujan dan debit serta sangat bergantung pada pemilihan *hyperparameter* seperti *batch size* dan *epoch*, sejalan dengan hasil *tuning* yang dilakukan dalam penelitian ini. Penelitian lain (Oddo et al., 2024) juga melaporkan bahwa resolusi citra yang lebih detail mampu memperbaiki kualitas prediksi, mendukung keputusan penggunaan citra berukuran 128 pada skenario dengan jumlah data yang lebih besar.

Keterbatasan penelitian ini terletak pada variabel yang digunakan, yaitu curah hujan, debit, dan operasi bendungan. Faktor lain seperti tata guna lahan, sedimentasi, dan kondisi infrastruktur belum dimasukkan. Selain itu, penelitian ini belum mencakup integrasi model dengan sistem peringatan dini atau pengambilan keputusan operasional di lapangan. Penelitian selanjutnya perlu difokuskan pada pengayaan data dan pengembangan model. Pengumpulan data yang lebih panjang dan beragam dari pengukuran, satelit, atau *Internet of Thing* (IoT) akan meningkatkan akurasi. Penambahan variabel seperti kelembapan tanah, karakteristik DAS, dan morfologi sungai membantu menangkap dinamika hidrologi yang lebih kompleks. Dari sisi metode, penerapan model deep learning lanjutan seperti LSTM

dengan *attention* atau *physics-informed machine learning* berpotensi meningkatkan kinerja. Validasi di lokasi lain penting untuk menguji generalisasi, sementara integrasi ke sistem peringatan dini berbasis *dashboard* dapat menjadikan model lebih aplikatif bagi pengelolaan bendungan.

Kesimpulan dan Saran

Kesimpulan

Penelitian ini menunjukkan bahwa performa awal model prediksi TMA berbeda-beda di setiap pos pengamatan. Sebelum penambahan data pendukung, Pos Kampung Kalapa sudah menunjukkan performa yang relatif baik dengan nilai korelasi (CC) sebesar 0.82 dan nilai NSE sebesar 0.71. Sebaliknya, Pos MT. Haryono memiliki akurasi yang kurang memadai, ditunjukkan oleh nilai MAE yang cukup tinggi (0.412 m). Hal ini mengindikasikan bahwa prediksi di beberapa lokasi masih rentan terhadap *error* dan belum cukup andal untuk kebutuhan operasional. Setelah dilakukan penambahan jumlah citra curah hujan dan dimasukkannya faktor debit keluaran bendungan sebagai variabel tambahan, model menunjukkan peningkatan performa yang signifikan di seluruh pos. Peningkatan paling mencolok terjadi di Pos Katulampa dan MT. Haryono, di mana nilai korelasi dan NSE meningkat tajam serta nilai MAE menurun drastis. Di Kampung Kalapa, peningkatan akurasi juga terlihat, dengan MAE turun hingga hanya 0.020 m dan nilai NSE naik ke 0.81, menjadikan pos ini sebagai titik dengan prediksi paling akurat.

Akurasi model pada ruas tengah (Kp. Kalapa) tetap tinggi baik sebelum maupun setelah penambahan jumlah citra hujan dan debit pelepasan bendungan karena lokasi ini secara hidrologis sudah merepresentasikan integrasi aliran dari hulu dan pengaruh bendungan. Pola TMA di Kp. Kalapa relatif stabil dan konsisten, sehingga bahkan dengan jumlah data yang lebih sedikit, model CNN-LSTM sudah mampu menangkap karakteristik utama yang memengaruhi fluktuasi muka air di titik tersebut. Penambahan jumlah citra hujan dan debit pelepasan bendungan memperkaya informasi spasial-temporal, tetapi dampaknya lebih signifikan pada titik hulu (Katulampa) dan hilir (MT. Haryono) yang memiliki variabilitas lebih kompleks. Di Kp. Kalapa, pola aliran yang sudah terfilter membuat tambahan data tidak banyak mengubah performa, sehingga akurasi tetap sama baiknya. Dengan kata lain, ruas tengah memiliki kondisi hidrologis yang lebih representatif dan mudah diprediksi, sehingga model mencapai akurasi optimal bahkan sebelum data tambahan dimasukkan.

Penerapan *deep learning* dengan arsitektur CNN-LSTM dalam prediksi tinggi muka air (TMA) menunjukkan sejumlah keunggulan yang signifikan. Model ini mampu menangkap pola spasial-temporal secara bersamaan, sehingga dapat memanfaatkan data citra curah hujan sekaligus dinamika aliran sungai. Keunggulan lain adalah fleksibilitas dalam mengolah data besar, sehingga semakin banyak citra hujan dan variabel hidrologis yang dimasukkan, semakin baik kemampuan model dalam mengenali kompleksitas sistem.

Namun, terdapat pula kelemahan yang perlu diperhatikan untuk riset lanjutan. Model ini sangat bergantung pada kualitas dan kelengkapan data; *noise* atau ketidakakuratan data hidrologis dapat menurunkan performa. Selain itu, interpretabilitas model juga terbatas, sehingga sulit menjelaskan secara detail hubungan sebab-akibat antara curah hujan, debit bendungan, dan TMA. Oleh karena itu, riset lanjutan dapat diarahkan pada pengembangan

metode *explainable AI*, optimasi hyperparameter yang lebih adaptif, serta integrasi dengan model hidrologi fisik untuk meningkatkan akurasi sekaligus transparansi hasil prediksi.

Saran

Pengembangan model prediksi TMA disarankan menggunakan data lebih lengkap, terutama debit keluaran bendungan dan citra hujan resolusi tinggi, yang terbukti meningkatkan akurasi di wilayah rawan banjir seperti Kampung Kalapa. Evaluasi perlu dilakukan pada pos berakurasi rendah seperti MT. Haryono untuk menelusuri sumber kesalahan. Peningkatan resolusi data, pengayaan jangka panjang, serta penambahan variabel DAS dan morfologi sungai akan memperbaiki kinerja model. Uji di lokasi lain dan integrasi ke *dashboard* operasional akan memperluas penerapan dan manfaatnya.

Ucapan Terima Kasih

Kami sampaikan ucapan terima kasih yang sebesar-besarnya kepada Direktorat Bina Teknik Sumber Daya Air, Kementerian Pekerjaan Umum atas dukungan dan fasilitas yang diberikan dalam pelaksanaan penelitian ini. Dukungan data, akses informasi teknis, serta arahan yang konstruktif dari Bina Teknik SDA telah menjadi bagian penting dalam keberhasilan studi ini.

Daftar Referensi

- Adli Zakaria, M.N., Ahmed, A.N., Abdul Malek, M., Birima, A.H., Hayet Khan, M.M., Sherif, M. and Elshafie, A., 2023. Exploring machine learning algorithms for accurate water level forecasting in Muda river, Malaysia. *Helijon*, [online] 9(7), p.e17689. <https://doi.org/10.1016/j.helijon.2023.e17689>.
- Alfieri, L., Cohen, S., Galantowicz, J., Schumann, G.J.P., Trigg, M.A., Zsoter, E., Prudhomme, C., Kruczakiewicz, A., Coughlan de Perez, E., Flamig, Z., Rudari, R., Wu, H., Adler, R.F., Brakenridge, R.G., Kettner, A., Weerts, A., Matgen, P., Islam, S.A.K.M., de Groot, T. and Salamon, P., 2018. A global network for operational flood risk reduction. *Environmental Science & Policy*, [online] 84, pp.149–158. <https://doi.org/10.1016/j.envsci.2018.03.014>.
- Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M.A., Al-Amidie, M. and Farhan, L., 2021. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data* 2021 8:1, [online] 8(1), pp.53-. <https://doi.org/10.1186/S40537-021-00444-8>.
- Ayus, I., Natarajan, N. and Gupta, D., 2023. Prediction of Water Level Using Machine Learning and Deep Learning Techniques. *Iranian Journal of Science and Technology, Transactions of Civil Engineering* 2023 47:4, [online] 47(4), pp.2437–2447. <https://doi.org/10.1007/S40996-023-01053-6>.
- Baek, S.-S., Pyo, J., Chun, J.A., Baek, S.-S., Pyo, J. and Chun, J.A., 2020. Prediction of Water Level and Water Quality Using a CNN-LSTM Combined Deep Learning Approach. *Water* 2020, Vol. 12, [online] 12(12). <https://doi.org/10.3390/W12123399>.

- BNPB, 2025. *Data Informasi Bencana Indonesia (DIBI)*. [online] Badan Nasional Penanggulangan Bencana (BNPB). Available at: <<https://dibi.bnrb.go.id/>> [Accessed 23 November 2025].
- Boke, A.S. and Boke, A.S., 2017. Comparative Evaluation of Spatial Interpolation Methods for Estimation of Missing Meteorological Variables over Ethiopia. *Journal of Water Resource and Protection*, [online] 9(8), pp.945–959. <https://doi.org/10.4236/JWRP.2017.98063>.
- Chen, J. and Adams, B.J., 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, [online] 318(1–4), pp.232–249. <https://doi.org/10.1016/J.JHYDROL.2005.06.017>.
- Deng, H., Chen, W. and Huang, G., 2022. Deep insight into daily runoff forecasting based on a CNN-LSTM model. *Natural Hazards* 2022 113:3, [online] 113(3), pp.1675–1696. <https://doi.org/10.1007/S11069-022-05363-2>.
- DiPietro, R. and Hager, G.D., 2020. Deep learning: RNNs and LSTM. *Handbook of Medical Image Computing and Computer Assisted Intervention*, [online] pp.503–519. <https://doi.org/10.1016/B978-0-12-816176-0.00026-0>.
- Hieu, T.T., Chieu, T.Q., Quang, D.N. and Hieu, N.D., 2023. Water level prediction using deep learning models: A case study of the Kien Giang River, Quang Binh Province. *River*, [online] 2(4), pp.468–479. <https://doi.org/10.1002/RVR2.63>.
- Jensen, R.R., Hardin, P.J. and Yu, G., 2009. Artificial neural networks and remote sensing. *Geography Compass*, [online] 3(2), pp.630–646. <https://doi.org/10.1111/J.1749-8198.2008.00215.x>.
- Jiang, Y., Wang, W., Fullhart, A.T., Yu, B. and Chen, B., 2025. Regionalization of IDF Curves for Mainland China: A Comparative Evaluation of Machine Learning versus Spatial Interpolation Techniques. *EGUsphere*, [online] pp.1–34. <https://doi.org/10.5194/EGUSPHERE-2025-3228>.
- Kim, D., Han, H., Wang, W., Kim, H.S., Kim, D., Han, H., Wang, W. and Kim, H.S., 2022. Improvement of Deep Learning Models for River Water Level Prediction Using Complex Network Method. *Water* 2022, Vol. 14, [online] 14(3). <https://doi.org/10.3390/W14030466>.
- Li, P., Zhang, J., Krebs, P., Li, P., Zhang, J. and Krebs, P., 2022a. Prediction of Flow Based on a CNN-LSTM Combined Deep Learning Approach. *Water* 2022, Vol. 14, [online] 14(6). <https://doi.org/10.3390/W14060993>.
- Li, X., Xu, W., Ren, M., Jiang, Y. and Fu, G., 2022b. Hybrid CNN-LSTM models for river flow prediction. *Water Supply*, [online] 22(5), pp.4902–4919. <https://doi.org/10.2166/WS.2022.170>.
- Oddo, P.C., Bolten, J.D., Kumar, S. V. and Cleary, B., 2024. Deep Convolutional LSTM for improved flash flood prediction. *Frontiers in Water*, 6, p.1346104. <https://doi.org/10.3389/FRWA.2024.1346104>.
- Perera, D., Seidou, O., Agnihotri, J., Ramsy, M., Smakhtin, V., Coulibaly, P. and Mehmood, H., 2019. Flood Early Warning Systems: A Review of Benefits, Challenges and Prospects. [online] Available at:

- <<http://inweh.unu.edu/publications/>> [Accessed 25 December 2025]. <https://doi.org/10.53328/MJFQ3791>.
- Pradhan, P., Tingsanchali, T. and Shrestha, S., 2020. Evaluation of Soil and Water Assessment Tool and Artificial Neural Network models for hydrologic simulation in different climatic regions of Asia. *Science of The Total Environment*, [online] 701, p.134308. <https://doi.org/10.1016/J.SCITOTENV.2019.134308>.
- Shen, C. and Lawson, K., 2021. Applications of deep learning in hydrology. *Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science and Geosciences*, [online] pp.285–297. <https://doi.org/10.1002/9781119646181>.

[Halaman ini sengaja dibiarkan kosong/*This page is intentionally left blank*]