

MODEL PREDIKSI TINGGI MUKA AIR SUNGAI MENGGUNAKAN JARINGAN SYARAF
TIRUAN

RIVER WATER LEVEL PREDICTION MODEL USING ARTIFICIAL NEURAL NETWORKS

Agusman^{*1}, S. Imam Wahyudi², A.Wati Pranoto³

¹Mahasiswa/Teknik Sipil/ Universitas Tarumanagara

²Dosen /Teknik Sipil/ Universitas Islam Sultan Agung

³Dosen /Program Studi Teknik Sipil/ Universitas Tarumanagara

Korespondensi: agusman8233@gmail.com

ABSTRAK

Penelitian ini mengembangkan model prediksi tinggi muka air menggunakan integrasi *Artificial Neural Network* (ANN) dan *Long Short-Term Memory* (LSTM). ANN memetakan hubungan nonlinier antar-parameter hidrologi, sedangkan LSTM menangkap pola ketergantungan temporal pada data deret waktu. Hasil perbandingan empat model—Regresi Linear, ANN, LSTM, dan hybrid ANN–LSTM—menunjukkan bahwa model berbasis jaringan saraf memberikan performa prediksi yang jauh lebih baik daripada model linier. Model Regresi Linear menghasilkan error terbesar (MSE 0.0175; RMSE 0.128; MAE 0.103; R^2 0.785), disusul ANN dengan peningkatan akurasi signifikan (MSE 0.0114; RMSE 0.101; MAE 0.0549; R^2 0.874). LSTM memberikan hasil lebih baik (MSE 0.0048; RMSE 0.067; MAE 0.0472; R^2 0.902), namun model terbaik adalah hybrid ANN–LSTM dengan nilai error terendah (MSE 0.00417; RMSE 0.063; MAE 0.0388) dan R^2 tertinggi (0.937). Kombinasi ini mampu menangkap pola nonlinier dan dinamika temporal secara lebih optimal sehingga menghasilkan prediksi yang stabil dan akurat. Selain itu, penelitian ini menunjukkan bahwa model hidrodinamika DufLOW berpotensi dikembangkan sebagai alat simulasi mitigasi untuk pengelolaan tinggi muka air, seperti pengujian skenario hujan ekstrem, perubahan tata ruang, operasi infrastruktur pengendali banjir, optimasi saluran, hingga simulasi dampak perubahan iklim.

ABSTRACT Kata Kunci: Prediksi, Hybrid, ANN, LTSM, Tinggi Muka Air

ABSTRACT

This study developed a water level prediction model using the integration of Artificial Neural Network (ANN) and Long Short-Term Memory (LSTM). ANN maps nonlinear relationships between hydrological parameters, while LSTM captures temporal dependence patterns in time series data. The comparison results of four models—Linear Regression, ANN, LSTM, and ANN–LSTM hybrid—showed that the neural network-based model provided significantly better prediction performance than the linear model. The Linear Regression model produced the largest error (MSE 0.0175; RMSE 0.128; MAE 0.103; R^2 0.785), followed by ANN with a significant increase in accuracy (MSE 0.0114; RMSE 0.101; MAE 0.0549; R^2 0.874). LSTM provided better results (MSE 0.0048; RMSE 0.067; MAE 0.0472; R^2 0.902), but the best model was the hybrid ANN–LSTM with the lowest error value (MSE 0.00417; RMSE 0.063; MAE 0.0388) and the highest R^2 (0.937). This combination is able to capture nonlinear patterns and temporal dynamics more optimally, resulting in stable and accurate predictions. In addition, this study shows that the DufLOW hydrodynamic model has the potential to be developed as a mitigation simulation tool for water level management, such as testing extreme rainfall scenarios, spatial changes, flood control infrastructure operations, channel optimization, and simulating the impacts of climate change.

Keywords: Prediction, Hybrid, ANN, LTSM, Water Level

PENDAHULUAN

Kenaikan tinggi muka air sungai yang drastis akibat curah hujan tinggi menyebabkan banjir, merusak infrastruktur, dan mengancam kehidupan manusia (Wu et al., 2022). Sebaliknya, penurunan tinggi muka air sungai akibat musim kemarau panjang atau eksploitasi air yang berlebihan dapat menyebabkan kekeringan, menghambat aktivitas pertanian dan mengurangi ketersediaan air bersih dan menghambat perekonomian (Baudoin et al., 2017). Fluktuasi tinggi muka air sungai yang tidak terkendali dapat mempercepat erosi tebing sungai serta meningkatkan sedimentasi, yang dapat mengurangi kapasitas aliran sungai dan memperparah risiko banjir (Q. Li et al., 2011), untuk itu sangat penting memperhatikan pengelolaan sumber daya air.

Mendukung pengelolaan sumber daya air tidak hanya memperkecil resiko tetapi dapat menjadikan masa depan sungai lebih produktif, seperti pengembangan infrastruktur sumber daya air, ketangguhan terhadap bencana hidrometeorologi (Bayu Rizky Prayoga & Budi Harsoyo, 2023). melakukan pengembangan pusat data sungai dengan penginderaan jarak jauh (Crétau et al., 2011), pengelolaan data hidrologi terkait tinggi muka air serta sistem prediksi dan peringatan dini terhadap bencana meteorologi yang dapat disebarkan secara cepat melalui jaringan komunikasi utamanya pada sungai-sungai kecil yang belum diperhatikan (Thieken et al., 2023).

Ahli hidrologi sering dihadapkan pada masalah prediksi dan estimasi kuantitas seperti limpasan, curah hujan, konsentrasi kontaminan, dan tahap air. Informasi semacam ini diperlukan dalam desain teknik hidrologi dan hidrolis serta pengelolaan sumber daya air. Sebagian besar proses hidrologi sangat nonlinier dan menunjukkan tingkat variabilitas spasial dan temporal yang tinggi yang membuat semakin rumit oleh ketidakpastian dalam perkiraan parameter (ASCE, 2000).

Prediksi tinggi muka air sungai memiliki peran penting dalam pengelolaan sumber daya air dan mitigasi bencana banjir, terutama di tengah tantangan global seperti perubahan iklim yang semakin tak terduga. Akurasi dalam memprediksi tinggi muka air sangat penting untuk melindungi kehidupan, properti, dan memastikan pemanfaatan air yang berkelanjutan. Dalam beberapa dekade terakhir, berbagai pendekatan telah diterapkan untuk menangani kompleksitas data hidrologi, seperti model statistik konvensional menggunakan beberapa pendekatan untuk memodelkan dan memprediksi

tinggi muka air sungai, seperti analisis regresi (Damanik et al., 2020) dan model hidrologi matematis yang menggunakan parameter-parameter hidrologi seperti curah hujan, luas daerah aliran sungai, dan koefisien limpasan (Jayadianti et al., 2020).

Namun, untuk kondisi-kondisi tertentu, model-model ini belum mampu memberikan hasil prediksi yang akurat. Teknik yang lebih canggih seperti Jaringan Syaraf Tiruan (Artificial Neural Network/ANN) menjadi pilihan model prediksi saat ini dan sesuai perkembangan zaman. Beberapa penelitian terdahulu telah menunjukkan keberhasilan penggunaan ANN. ANN menjadi alat pemodelan yang kuat dalam berbagai aplikasi, termasuk untuk memprediksi banjir berdasarkan data historis (Bomers et al., 2019), serta lebih spesifik terkait tinggi muka air sungai (Zhu et al., 2020).

ANN menjadi salah satu pendekatan yang menjanjikan dengan kemampuannya mempelajari dan mengenali pola-pola dalam data historis, yang kemudian digunakan untuk prediksi kehilangan data curah hujan dalam perekaman sehingga dapat memprediksi peramalan tinggi muka air dengan memiliki nilai akurasi 94,6 % (Bustami et al., 2007).

Penelitian terbaru terkait kesempurnaan dan akurasi dalam pengembangan model dengan menganalisis hubungan dua jenis ANN, yaitu Feed Forward Neural Network (FFNN) dan Long Short Term Memory Network (LSTM) menunjukkan LSTM mengungguli FFNN dan menegaskan bahwa hubungan temporal jauh lebih kuat dalam memprediksi ketinggian air (Herath et al., 2023), dan LSTM juga memberikan hasil yang baik dalam semua situasi hidrologi dan dapat dilatih secara efektif pada volume data yang sangat besar (Vizi et al., 2023). Diperkuat dipenelitian lain menggabungkan kemampuan ANN dengan (LSTM) dalam suatu percobaan ANN, LSTM menunjukkan bahwa penggabungan ANN-LSTM berkinerja lebih baik (Zhou et al., 2024).

Kota Baubau memiliki sebuah sungai yang melewati Kecamatan Wolio, Kecamatan Murhum dan Kecamatan Batupoaro dan terlihat membelah Kota Baubau dengan melintasi tiga jalur jembatan yaitu jembatan beli, jembatan tengah dan jembatan gantung. Sungai tersebut pada umumnya memiliki potensi yang dapat dijadikan sebagai sumber tenaga listrik, pertanian, perikanan, kebutuhan industri, kebutuhan rumah tangga dan pariwisata (BPS 2023), namun belum tersentuh karena kurangnya data hasil analisis terkait potensi sungai.

Selain kurangnya hasil analisis, data-data yang berkaitan dengan sungai kota Baubau juga sangat sulit diketahui dari Lembaga pemerintah karena belum adanya pengukuran dan pengambilan data secara resmi oleh Lembaga yang berwenang, sehingga kurangnya kualitas data sungai berupa debit, topografi sungai, DAS, tinggi muka air dan data yang berkaitan dengan kualitas air.


Sungai kota Baubau saat ini hanya memiliki fungsi alamiah sebagai pengendalian banjir dengan menampung air hujan yang berlebihan dan melepaskannya secara perlahan menuju laut sehingga mengurangi risiko banjir di daerah sekitar. Namun luapan air sungai di kota Baubau sering terjadi di musim hujan dan jumlah air yang tertampung didalam sungai tidak dapat diprediksi ditambah lagi tidak tersedianya data terkait tinggi muka air sungai ditahun tahun sebelumnya.

Untuk melengkapi data analisis penelitian dalam prediksi tinggi muka air menggunakan jaringan syaraf tiruan dibutuhkan parameter tinggi muka air ditahun tahun sebelumnya yang dihasilkan dari analisis menggunakan *software* duflow yang dikembangkan di Belanda. Sehingga penelitian ini dapat dinyatakan model hybrid memadukan *software* Duflow untuk melengkapi data prediksi tahun sebelumnya sednagkan ANN dan LTSM memprediksi Tinggi Muka Air di waktu yang akan datang.

TINJAUAN PUSTAKA

Jaringan Syaraf Tiruan (JST)

Artificial Neural Network (ANN), atau dalam bahasa Indonesia dikenal sebagai Jaringan Syaraf Tiruan (JST), merupakan sistem komputasi yang meniru cara kerja jaringan saraf manusia. Konsep dasar dari jaringan ini dikembangkan dengan mengadaptasi struktur dan fungsi otak manusia sebagai sumber inspirasinya. Jaringan syaraf tiruan mampu menyelesaikan berbagai tugas yang kompleks, seperti mengklasifikasikan data dan mengenali pola. Selain itu, ANN juga dapat digunakan untuk melakukan prediksi terhadap berbagai model statistik, serta mampu merepresentasikan data yang bersifat linier maupun non-linier secara fleksibel (Mahendra et al., 2023)



Gambar 1. Arsitektur Jaringan Syaraf Tiruan

Sumber: J. Han, and M. Kember. (2006)

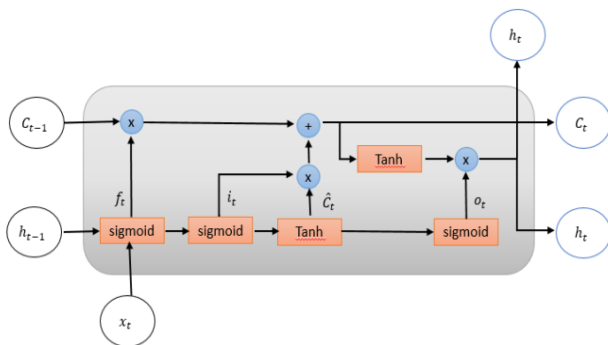
Dalam pengembangan Jaringan Syaraf Tiruan (JST), terdapat tiga arsitektur dasar yang umum digunakan untuk memproses data dan menghasilkan prediksi atau klasifikasi. Setiap arsitektur ini memiliki struktur dan kompleksitas yang berbeda, bergantung pada kebutuhan dan tujuan penggunaannya (Fadilah et al., 2024).

- Single Layer Neural Network adalah bentuk paling sederhana dari jaringan syaraf tiruan. Pada arsitektur ini, hanya terdapat satu lapisan pemrosesan yang secara langsung menghubungkan lapisan input (input layer) dengan lapisan output (output layer) melalui bobot-bobot tertentu. Model ini menerima data dari input, memprosesnya secara langsung, lalu menghasilkan keluaran. Karena strukturnya yang sederhana, jenis jaringan ini umumnya digunakan untuk menyelesaikan masalah yang linier dan tidak terlalu kompleks, seperti klasifikasi biner sederhana. Diagram dari arsitektur single layer ini biasanya menunjukkan hubungan langsung antar node input ke node output tanpa lapisan tersembunyi.
- Multilayer Neural Network atau jaringan syaraf multi-lapisan, memiliki arsitektur yang lebih kompleks dibandingkan single layer. Pada jaringan ini, terdapat satu atau lebih hidden layer (lapisan tersembunyi) yang terletak di antara input layer dan output layer. Hidden layer bertugas untuk memproses dan mengekstraksi fitur dari data input sebelum diteruskan ke output layer. Setiap neuron di hidden layer akan menerima input, melakukan perhitungan berbasis bobot dan fungsi aktivasi tertentu, lalu meneruskan hasilnya ke lapisan berikutnya. Semakin banyak hidden layer yang digunakan, jaringan ini menjadi deep neural network (DNN), yang memungkinkan pemrosesan data yang lebih rumit seperti pengenalan gambar, suara, dan prediksi pola non-linier
- Recurrent Neural Network (RNN) Selain arsitektur single layer dan multilayer, terdapat juga Recurrent Neural Network (RNN) yang dirancang khusus untuk memproses data yang bersifat berurutan atau time series. Berbeda dari jaringan feedforward standar, RNN memiliki mekanisme feedback di mana output dari satu tahap dapat digunakan kembali sebagai input untuk tahap berikutnya. Ini memungkinkan jaringan untuk "mengingat" informasi sebelumnya dan mempertahankan konteks waktu

dalam prediksi atau klasifikasi, sangat bermanfaat dalam pemrosesan bahasa alami (Natural Language Processing), prediksi time series, serta pengenalan pola data sekuensial lainnya

LSTM

Long Short-Term Memory (LSTM) adalah suatu pengembangan dari model Recurrent Neural Network (RNN) yang diperkenalkan oleh Sepp Hochreiter dan Jürgen Schmidhuber pada tahun 1997. LSTM dikembangkan untuk mengatasi 14 permasalahan vanishing gradient yang kerap muncul pada RNN, terutama saat memproses data berurutan dalam rentang waktu yang panjang. Melalui adanya *memory cell*, LSTM mampu mempertahankan informasi lebih lama dan menjaga kestabilan gradien selama proses pelatihan, yang pada akhirnya meningkatkan akurasi dalam analisis data berbasis waktu. Selain itu, arsitektur ini dilengkapi dengan mekanisme gate yang berfungsi untuk mengatur seleksi informasi secara adaptif, sehingga membuat LSTM lebih efektif dalam mengenali pola data yang kompleks dan bersifat dinamis (Puteri, 2023)



Gambar 2. Arsitektur Long Short-Term Memory
Sumber: J. Han, and M. Kember. (2006)

- Forget Gate (f_t)** berfungsi untuk menentukan informasi mana yang perlu dihapus dari cell state. Nilai ini diperoleh melalui fungsi sigmoid yang menerima input dari hidden state sebelumnya dan persamaannya sebagai berikut

$$f_t = \sigma(W_{fh} [h_{t-1}], W_{fx} [x_t], b_f) \quad (1)$$

Jika nilai forget gate mendekati 0, maka informasi akan dilupakan, sedangkan jika mendekati 1, informasi tetap dipertahankan.

- Input Gate (i_t)** berfungsi mengatur informasi baru yang akan ditambahkan ke cell state. Proses ini terdiri dari dua tahap, yaitu menentukan nilai penting melalui fungsi sigmoid dan

menghasilkan kandidat nilai baru melalui fungsi tanh:

$$i_t = \sigma(W_{ih} [h_{t-1}], W_{ix} [x_t], b_i) \quad (2)$$

$$C_t = \tanh(W_{ch} [h_{t-1}], W_{cx} [x_t], b_c) \quad (3)$$

Hasilnya kemudian dikombinasikan dengan nilai forget gate untuk memperbarui cell state:

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

- Output Gate (o_t)** menentukan bagian dari cell state yang akan dijadikan keluaran. Proses ini melibatkan fungsi sigmoid untuk menentukan bobot keluaran dan fungsi tanh untuk menormalisasi nilai:

$$O_t = \sigma(W_{oh} [h_{t-1}], W_{ox} [x_t], b_o) \quad (5)$$

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

Hasil *hidden state* digunakan sebagai *output* dari unit LSTM saat ini dan diteruskan ke langkah berikutnya.

Model DUFLOW

Duflow merupakan Model hidraulika satu dimensi (1D) pada sistem tata air merupakan model numerik yang digunakan untuk mensimulasikan perilaku aliran air sepanjang saluran, sungai, atau jaringan drainase dengan asumsi variasi aliran hanya terjadi pada satu arah memanjang alur. Model ini dilengkapi dengan antarmuka menu yang memungkinkan pengguna untuk memasukkan, mengedit, dan mengelola data secara interaktif, meliputi data geometri saluran, kondisi batas, parameter hidraulik, serta data hidrologi pendukung.

Simulasi aliran pada model ini dapat dilakukan dalam kondisi *steady flow* (aliran tetap) maupun *unsteady flow* (aliran tidak tetap), di mana karakteristik aliran dapat berubah terhadap waktu dan ruang. Pendekatan *unsteady* memungkinkan analisis dinamika muka air akibat hujan, pasang surut, maupun perubahan debit secara temporal.

Hasil pemodelan disajikan dalam bentuk output grafik dan tabel, seperti profil tinggi muka air, kecepatan aliran, debit, serta perubahan muka air terhadap waktu. Output ini memudahkan interpretasi hasil simulasi dan mendukung analisis teknis dalam perencanaan, evaluasi, dan pengelolaan sistem tata air serta pengendalian banjir.

HASIL DAN PEMBAHASAN

Data Tinggi Muka Air Berbasis DufLOW

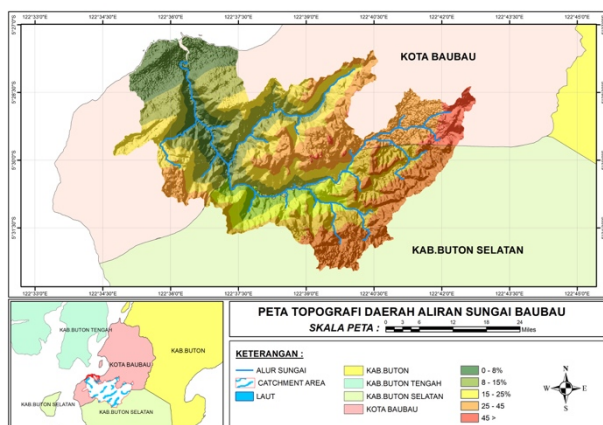
Salah satu parameter penelitian ini adalah data tinggi muka air yang datanya tidak tersedia, baik dari hasil penelitian maupun instansi terkait. Oleh karena itu, data tersebut diperoleh melalui analisis menggunakan software DufLOW, Data masukan seperti curah hujan, debit sungai, pasang surut laut, tutupan lahan, luas DAS, serta data penampang sungai diolah untuk menghasilkan tinggi muka air, yang hasilnya kemudian divalidasi, dievaluasi berdasarkan data real time, dikalibrasi dengan data tahun sebelumnya dan divisualisasikan dalam bentuk grafik dan tabel. Dari data yang didapatkan kemudian dijadikan data parameter untuk data input Jaringan Syaraf Tiruan. Data Tinggi muka Air yang digunakan selama 1 tahun dalam bentuk tabel.

Berikut ini hasil analisis dalam waktu satu hari menggunakan dufLOW dalam bentuk grafik untuk data harian dalam jam yang dianalisis pada 3 titik lokasi jembatan yaitu pada sec 00002 adalah jembatan Beli, Sec 00021 adalah Jembatan Tengah dan Sec 00030 adalah Jembatan Gantung yang berada pada hilir.

Gambar 3. Skematisasi model DUFLOW
Sumber: Referensi Manual Duflo (2002)

METODE


Penelitian ini dilaksanakan di area DAS Baubau yang terletak di antara garis lintang 50 270 8" dan 50 320 33" Ls serta bujur 1220 330 5" dan 1220 420 34" BT. Pada gambar 3.1 menampilkan peta lokasi penelitian yang akan dilaksanakan. Kota Baubau memiliki luas wilayah 29,313.96 ha.



Gambar 4. Peta Lokasi Penelitian
Sumber: Analisis Data 2025

Analisis data dalam penelitian ini dilakukan untuk memastikan pengolahan data yang tepat sehingga menghasilkan model prediksi tinggi muka air yang akurat menggunakan jaringan syaraf tiruan (JST). Tahapan analisis data meliputi:

1. Pengumpulan data hidrologi untuk membuat model learning dalam prediksi tinggi muka air;
2. Pemodelan Hidrodinamika menggunakan DufLOW untuk menentukan tinggi muka air sungai real time dan prediksi data historis.
3. Prediksi menggunakan ANN, LTSM dan ANN-LTSM.




Gambar 5. Grafik Tinggi Muka Air pada Jembatan Beli tgl 1 Februari 2025
Sumber: Analisis Data Pemodelan DufLOW 2025

Terlihat bahwa tinggi muka air pada titik awal (garis merah) relatif stabil di sekitar 1,5 m, sedangkan pada titik akhir (garis biru) mengalami dua kali kenaikan signifikan masing-masing hingga sekitar 2,0 m pada pagi dan sore hari. Pola ini mencerminkan adanya pengaruh pasang surut harian ganda (semi-diurnal) yang menyebabkan perubahan tinggi muka air secara periodik, sekaligus menggambarkan dinamika aliran yang dipengaruhi oleh kondisi debit dan pasang laut di wilayah Sungai Kota Baubau.

Tabel 1. Perbandingan MSE Tiap Model dan Lokasi

| Model | Jembatan GT (MSE) | Jembatan TGH (MSE) | Jembatan BELI (MSE) |
|--------------------------|-------------------|--------------------|---------------------|
| Regresi Linear | 0.0172 | 0.0168 | 0.0185 |
| ANN | 0.0117 | 0.0109 | 0.0115 |
| LSTM | 0.0051 | 0.0048 | 0.0045 |
| ANN-LSTM (Hybrid) | 0.0043 | 0.0042 | 0.004 |


Sumber: Hasil Analisis (2025)



Gambar 6. Grafik Tinggi Muka Air pada Jembatan Tengah tgl 1 Februari 2025

Sumber: Analisis Data Pemodelan DufLOW2025

Terlihat bahwa tinggi muka air pada titik awal (garis merah) sempat meningkat tajam hingga sekitar 2,0 m pada awal waktu, kemudian menurun hingga mendekati 0 m sebelum kembali naik secara bertahap. Pada titik akhir (garis biru), pola fluktuasi menunjukkan dua kali puncak utama masing-masing sekitar 06:00 dan 18:00, dengan ketinggian maksimum mendekati 2,0 m. Pola ini mengindikasikan adanya pengaruh pasang surut harian ganda (semi-diurnal tide) yang kuat, di mana tinggi muka air meningkat dan menurun secara teratur. Hasil ini menunjukkan bahwa segmen aliran tersebut sangat dipengaruhi oleh dinamika pasang laut, yang berdampak langsung terhadap perubahan debit dan aliran air di wilayah Sungai Kota Baubau.



Gambar 7. Grafik Tinggi Muka Air pada Jembatan Gantung tgl 1 Februari 2025

Sumber: Analisis Data Pemodelan DufLOW2025

Grafik hasil simulasi hidrodinamika pada segmen SEC00030 atau di sekitar jembatan Gantung area hilir sungai menunjukkan pola fluktuasi tinggi

muka air yang periodik selama satu hari pengamatan. Tinggi muka air awal (garis merah) dan akhir (garis biru) menunjukkan tren yang hampir sama, dengan dua puncak utama sekitar pukul 06:00 dan 18:00, masing-masing mencapai ketinggian sekitar 2,0 m. Pola ini menggambarkan pengaruh pasang surut harian ganda (semi-diurnal), di mana air mengalami dua kali pasang dan dua kali surut dalam satu siklus harian. Kondisi tersebut mengindikasikan bahwa aliran di segmen ini masih dipengaruhi oleh dinamika pasang laut di wilayah Sungai Kota Baubau.

Data Hasil Prediksi Menggunakan JST

Tabel 2. Rangkuman Rata-rata Metrik Evaluasi

| Model | MSE (avg) | RMSE (avg) | MAE (avg) | R ² (avg) |
|--------------------------|----------------|--------------|---------------|----------------------|
| Regresi Linear | 0.0175 | 0.128 | 0.103 | 0.785 |
| ANN | 0.0114 | 0.101 | 0.0549 | 0.874 |
| LSTM | 0.0048 | 0.067 | 0.0472 | 0.902 |
| ANN-LSTM (Hybrid) | 0.00417 | 0.063 | 0.0388 | 0.937 |

Sumber: Hasil Analisis (2025)

Berdasarkan hasil di atas, terlihat bahwa setiap peningkatan kompleksitas arsitektur model memberikan perbaikan performa yang signifikan terhadap nilai kesalahan prediksi (MSE). Performa terbaik dicapai oleh model hybrid ANN-LSTM, dengan MSE rata-rata 0.00417, yang menunjukkan tingkat kesalahan prediksi paling kecil dibandingkan tiga model lainnya. Analisis lebih rinci tiap model dapat dijelaskan sebagai berikut:

1. Model Regresi Linear

Model regresi linear memberikan hasil paling sederhana, dengan MSE rata-rata sebesar 0.0175. Hasil ini menggambarkan bahwa hubungan antara waktu dan tinggi muka air tidak dapat direpresentasikan secara linear murni. Fenomena tinggi muka air yang bersifat fluktuatif dan non-stasioner menyebabkan model linier kesulitan menangkap pola musiman maupun siklus ekstrem, seperti pasang-surut yang cepat berubah.

2. Model Artificial Neural Network (ANN)

Model ANN memperlihatkan peningkatan kinerja dibandingkan regresi linear, dengan MSE rata-rata turun menjadi 0.0114. ANN mampu mempelajari hubungan non-linear antar data, berkat lapisan neuron yang menyesuaikan bobot untuk meminimalkan kesalahan. Namun, karena

ANN tidak memiliki mekanisme memori jangka panjang, model ini masih terbatas dalam menangkap ketergantungan temporal antar waktu (time dependency) yang sangat kuat pada data hidrologi seperti tinggi muka air.

3. Model Long Short-Term Memory (LSTM)

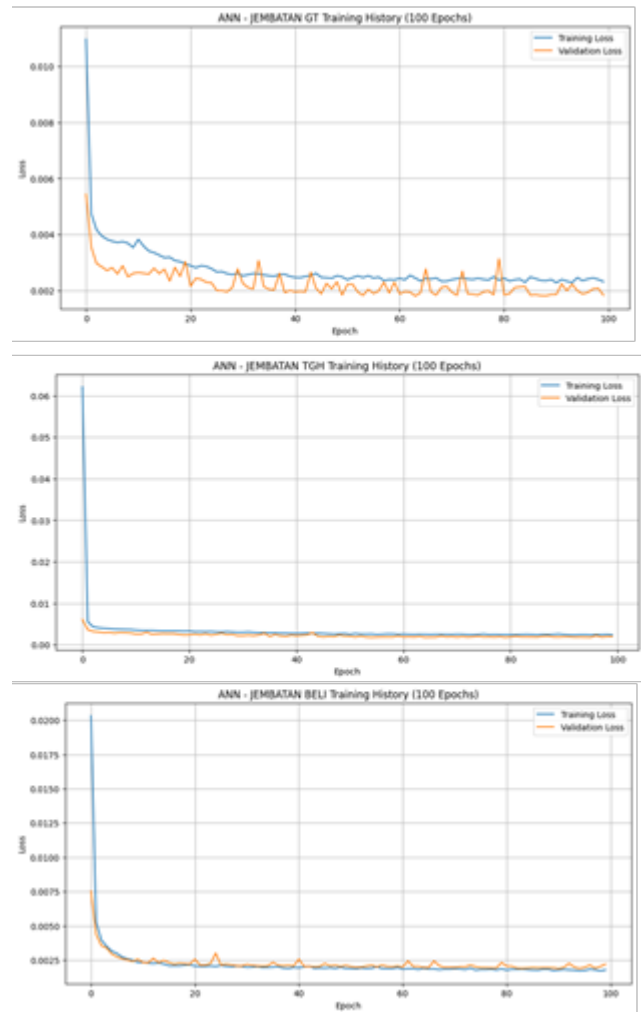
Model LSTM menunjukkan peningkatan signifikan dengan rata-rata MSE **0.0048**, hampir **60%** lebih rendah dibanding ANN. Keunggulan LSTM terletak pada kemampuannya mengenali pola temporal jangka panjang melalui *gating mechanism* (input gate, forget gate, dan output gate) yang menjaga aliran informasi dari satu waktu ke waktu berikutnya. Dengan demikian, model ini dapat mempelajari pola pasang-surut air dan tren harian dengan akurasi yang jauh lebih tinggi.

4. Model Hybrid ANN–LSTM

Model ANN–LSTM merupakan kombinasi dua pendekatan cerdas: ANN sebagai *feature extractor* dan LSTM sebagai *sequence learner*. Model ini memberikan hasil terbaik di ketiga lokasi pengamatan dengan MSE rata-rata 0.00417, menunjukkan peningkatan akurasi sebesar $\pm 12.5\%$ dibandingkan LSTM murni. Keunggulan utama model ini adalah kemampuannya untuk:

- Menggabungkan representasi non-linear kompleks (ANN) dengan pemahaman urutan waktu (LSTM).
- Mengurangi noise pada data sensor air, terutama pada transisi cepat antara kondisi pasang dan surut.
- Menangkap hubungan multivariabel antar lokasi jembatan, karena model mampu mengenali keterkaitan spasial jika data diintegrasikan lintas titik pengamatan.


Dalam konteks prediksi tinggi muka air, ANN–LSTM terbukti lebih adaptif dan stabil ketika dihadapkan pada dinamika data yang fluktuatif akibat pengaruh pasang laut, curah hujan, serta perubahan tekanan atmosfer. Model ini juga menunjukkan konsistensi kinerja antar lokasi, yang terlihat dari selisih MSE antar titik pengamatan yang sangat kecil (0.0043 – 0.0040). Evaluasi pelatihan model dapat dilihat pada gambar berikut:



Gambar 8. Evaluasi Proses Pelatihan Model ANN
Sumber: Analisis Data JST 2025

Jembatan Beli. Pada awal pelatihan (epoch 1), nilai loss relatif tinggi, dengan training loss mendekati 0,030 dan validation loss sekitar 0,009. Namun, penurunan loss terjadi sangat cepat pada 5–10 epoch pertama, menunjukkan bahwa model dengan cepat mempelajari pola dasar dalam data. Setelah melewati sekitar epoch ke-10, kedua kurva loss menjadi stabil dan berada pada kisaran 0,0015–0,0025, dengan fluktuasi yang sangat kecil. Baik training loss maupun validation loss menunjukkan pola yang hampir berimpit, menandakan bahwa model memiliki generalisasi yang baik tanpa indikasi overfitting. Konsistensi kedua kurva ini menunjukkan bahwa data pelatihan dan validasi dipelajari secara seimbang dan model tidak mengalami degradasi performa pada data yang tidak dilatih. Secara keseluruhan, grafik ini menunjukkan bahwa model ANN–LSTM mampu berkonvergensi dengan cepat dan stabil, dengan tingkat error yang rendah serta performa prediksi yang konsisten hingga akhir pelatihan (epoch ke-100). Ini mengindikasikan bahwa arsitektur model dan parameter pelatihan sudah sesuai untuk memodelkan pola tinggi muka air di lokasi tersebut.

Gambar 9. Evaluasi Proses Pelatihan Model LTSM
Sumber: Analisis Data JST 2025



Gambar 10. Evaluasi Proses Pelatihan Model
ANN-LTSM

Sumber: Analisis Data JST 2025

Grafik menampilkan perubahan nilai training loss dan validation loss selama proses pelatihan model ANN–LSTM untuk prediksi tinggi muka air di

KESIMPULAN

Dari perbandingan performa empat model prediksi—Regresi Linear, ANN, LSTM, dan ANN–LSTM—berdasarkan metrik MSE, RMSE, MAE, dan R^2 . Secara umum, terlihat bahwa model berbasis jaringan saraf memberikan hasil yang lebih akurat dibandingkan model linier. Model Regresi Linear memiliki nilai error terbesar, dengan MSE sebesar 0.0175, RMSE 0.128, dan MAE 0.103, serta R^2 0.785. Hal ini menunjukkan bahwa kemampuan model linier dalam menjelaskan variasi data masih terbatas, karena karakteristik data tinggi muka air bersifat nonlinier dan dipengaruhi oleh dinamika hidrologi yang kompleks. Model ANN menunjukkan peningkatan akurasi yang signifikan dibanding Regresi Linear, dengan penurunan MSE menjadi 0.0114, RMSE 0.101, dan MAE 0.0549, serta kenaikan R^2 menjadi 0.874. Ini mengindikasikan bahwa ANN mampu menangkap pola nonlinier dalam data dengan lebih baik. Model LSTM, yang dirancang untuk memproses data deret waktu, memberikan hasil yang lebih baik lagi. Nilai MSE 0.0048, RMSE 0.067, dan MAE 0.0472, serta R^2 0.902, menunjukkan bahwa LSTM efektif mempelajari ketergantungan temporal pada data tinggi muka air. Model terbaik adalah Hybrid ANN–LSTM, dengan nilai error terendah: MSE 0.00417, RMSE 0.063, dan MAE 0.0388, serta nilai R^2 tertinggi 0.937. Kombinasi ANN dan LSTM

memungkinkan model menangkap pola nonlinear sekaligus dinamika temporal secara lebih optimal. Performa ini menunjukkan bahwa pendekatan hybrid mampu menghasilkan prediksi yang lebih stabil, akurat, dan adaptif dibanding model tunggal.

DAFTAR PUSTAKA

- Bustami, R., Bessaih, N., Bong, C., & Suhaili, S. (2007). *rosIJCS_34_2_10*. IAENG International Journal of Computer Science, November.
- Crétaux, J. F., Arsen, A., Calmant, S., Kouraev, A., Vuglinski, V., Bergé-Nguyen, M., Gennero, M. C., Nino, F., Abarca Del Rio, R., Cazenave, A., & Maisongrande, P. (2011). SOLS: A lake database to monitor in the Near Real Time water level and storage variations from remote sensing data. *Advances in Space Research*, 47(9), 1497–1507. <https://doi.org/10.1016/j.asr.2011.01.004>
- De Fraiture, C., Susanto, R. H., Suryadi, F. X., Mutiara, H., & Wahyu, H. (2017). URBAN DRAINAGE MANAGEMENT AND FLOOD CONTROL IMPROVEMENT USING DUFLOW CASE STUDY: AUR SUB CATCHMENT, PALEMBANG, SOUTH SUMATRA, INDONESIA. In *Makara Journal of Technology*. <http://journal.ui.ac.id/technology>
- Ehteram, M., Ferdowsi, A., Faramarzpour, M., Al-Janabi, A. M. S., Al-Ansari, N., Bokde, N. D., & Yaseen, Z. M. (2021). Hybridization of artificial intelligence models with nature inspired optimization algorithms for lake water level prediction and uncertainty analysis. *Alexandria Engineering Journal*, 60(2), 2193–2208. <https://doi.org/10.1016/j.aej.2020.12.034>
- Herath, M., Jayathilaka, T., & Hoshino, Y. (2023). applied sciences Deep Machine Learning-Based Water Level Prediction Model for Colombo Flood Detention Area.
- Jayadianti, H., Cahyadi, T. A., Amri, N. A., & Pitayandanu, M. F. (2020). Metode Komparasi Artificial Neural Network pada Prediksi Curah Hujan-Literature Review. *Jurnal Tekno Insentif*, 14(2), 47–53.
- Li, H., Zhang, L., Zhang, Y., Yao, Y., Wang, R., & Dai, Y. (2024). Water-Level Prediction Analysis for the Three Gorges Reservoir Area Based on a Hybrid Model of LSTM and Its Variants. *Water (Switzerland)*, 16(9). <https://doi.org/10.3390/w16091227>
- Li, Q., Liu, H. D., & Zhao, Y. (2011). Analysis and prediction for Xiaolangdi reservoir sand blocking operation period and water level of the lower Yellow River. *Applied Mechanics and Materials*, 71–78, 1318–1323. <https://doi.org/10.4028/www.scientific.net/AMM.71-78.1318>
- Marcela, J., Castillo, M., Manuel, J., Cspedes, S., Eduardo, H., & Cuchango, E. (2020). Water Level Prediction Using Artificial Neural Network Model. July.
- Mohammed, S. J., Zubaidi, S. L., Al-Ansari, N., Ridha, H. M., & Al-Bdairi, N. S. S. (2022). Hybrid Technique to Improve the River Water Level Forecasting Using Artificial Neural Network-Based Marine Predators Algorithm. *Advances in Civil Engineering*, 2022. <https://doi.org/10.1155/2022/6955271>
- Sastrodihardjo, S. (2010). Upaya mengatasi masalah banjir secara menyeluruh. Yayasan Badan Penerbit Pekerjaan Umum, Mediatama Saptakarya. <https://books.google.co.id/books?id=t1blZwEACAAJ>
- SIDAL, F., & ALTUN, Y. (2023). Prediction of Lake Van Water Level using Artificial Neural Network Model with Meteorological Parameters and Multiple Linear Regression Analysis: A Comparative Study. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(4), 1028–1040. <https://doi.org/10.17798/bitlisfen.1316881>
- Tamiru, H., & Dinka, M. O. (2021). Application of ANN and HEC-RAS model for flood inundation mapping in lower Baro Akobo River Basin, Ethiopia. *Journal of Hydrology: Regional Studies*, 36. <https://doi.org/10.1016/j.ejrh.2021.100855>
- Thieken, A., Zenker, M.-L., & Bubeck, P. (2023). Flood-related fatalities during the flood of July 2021 in North Rhine-Westphalia, Germany: what can be learnt for future flood risk management? *Journal of Coastal and Riverine Flood Risk*, 2. <https://doi.org/10.59490/jcrfr.2023.0005>