

Model Prediksi Ketinggian Air Disemua Pintu Muka Air Sungai Ciliwung Dengan Menggunakan Metode Long Short-Term Memory

Moh Hasyimi¹, Lifatin Nada², Feri Zain³

^{1,2,3}Program Studi Bisnis Digital, Universitas Annuqayah, Indonesia

Published: August , 2025

ABSTRAK

Ketinggian air sangat besar efeknya untuk pertimbangan seperti pembangunan, kehidupan sosial, ekonomi, kesehatan, bahkan terhadap infrastruktur dan lainnya. Ketinggian air juga menjadi pertimbangan membuat keputusan berbagai hal yang akan diambil dan dilakukan. Memprediksi ketinggian permukaan air sungai Ciliwung menggunakan data time series dengan memanfaatkan mesin learning adalah solusi yang bisa diambil dengan tujuan membuat model prediksi menggunakan algoritma Long Short-Term Memory (LSTM) dengan optimasi Adam memberikan informasi 10 menit sekali selama 24 jam. Hasil menunjukkan keberhasilan dalam membuat model prediksi ketinggian permukaan air sungai Ciliwung, namun hasil juga menunjukkan bahwa satu jenis data belum bisa dijadikan acuan secara akurat. Evaluasi nilai MSE sebesar 3620.69 dengan 6.829 data latih 1467.35 untuk 2.845 data uji dengan total data 9.963. Metode ini terbukti bekerja dengan baik walaupun menggunakan data yang kurang variatif. Hasil loss dan akurasi prediksi terbukti berhasil namun tidak dianjurkan digunakan sebagai acuan utama membuat keputusan tereakit ketinggian air sungai Ciliwung.

Keywords: Ciliwung, Ketinggian air, LSTM, Prediksi, Time Series

© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0>

PENDAHULUAN

Perkembangan kota yang begitu pesat serta perubahan iklim, banjir menjadi salah satu bencana alam yang paling sering terjadi serta membawa kerugian serius bagi kehidupan dan harta benda penduduk (Liu dkk, 2021). Sungai Ciliwung di Pulau Jawa adalah salah satu sungai yang rutin mengalami banjir tahunan karena luapan air di wilayah hilirnya. Sungai Ciliwung memiliki beberapa pintu air yang tersebar sepanjang sungai Ciliwung seperti pintu Mangarai, Flusing Ancol, Istiqlah, Jembatan Merah dan yang lainnya. Kegiatan pengembangan teknik seperti navigasi, konstruksi pantai, dan perlindungan banjir sangat bergantung pada prediksi akurasi ketinggian air di muara yang dapat menjadi vital untuk keselamatan dan keberlanjutan pembangunan ekonomi di masyarakat (Chen dkk, 2020). Fluktuasi muka air terutama diperairan laut dan pantai, dihasilkan oleh pasang surut astronomis dan dapat di prediksi dari model Classical Harmonic Analysis (CHA) seperti model T_TIDE dengan akurasi yang relatif tinggi.

Ketinggian air sangat besar efeknya untuk pertimbangan banyak hal seperti pembangunan, kehidupan sosial, ekonomi bahkan terhadap kesehatan infrastruktur dan yang lainnya (Prasad dkk, 2022). Tinggi atau rendahnya ketinggian permukaan air juga menjadi pertimbangan dalam membuat keputusan terkait berbagai hal yang akan diambil dan dilakukan oleh penanggung jawab kebijakan. Memprediksi ketinggian air merupakan cara yang sangat efektif dalam menjawab masalah tersebut dengan memanfaatkan kemajuan teknologi dan informasi yang ada. Seiring dengan perkembangan teknologi komputasi, banyak peneliti mencoba membuat prediksi dengan menggunakan kecerdasan komputasional seperti Fuzzy, Neural Network, Self-organizing Maps (SOM) dan metode lainnya (Mislan dkk, 2018).

Berbagai metode prediksi telah dikembangkan hingga saat ini dengan berbagai pendekatan yang dikembangkan meliputi pendekatan stokastik dan deterministik (Soebroto dkk, 2015). Model prediksi sebagian besar menggunakan pendekatan deterministik, yaitu kondisi saat t atau $t-1$ dan $t+1$,

dengan periode harian. Metode yang banyak digunakan untuk meramalkan data non-linear diantaranya yaitu Threshold Autoregressive (TAR), Autoregressive Conditional Heteroscedastic (ARCH), Artificial Neural Networks (ANN) dan Support Vector Regression (SVR) dan berbagai macam metode yang lainnya. Estimasi ketinggian air biasanya dilakukan dengan menggunakan model berbasis proses. Model-model ini harus dipilih dengan cermat untuk memprediksi perubahan ketinggian air yang sebenarnya (Choi dkk, 2020). Sejumlah besar parameter, seperti faktor-faktor yang mempengaruhi tinggi muka air, memerlukan waktu yang lama untuk kalibrasi sehingga dapat menjamin keakuratan prediksi model (Liu dkk, 2021).

Sejalan dengan model berbasis fisika, teknik Machine Learning (ML) telah berkembang dari waktu ke waktu, berfokus pada pembelajaran dari data dan pengalaman saat ini untuk meningkatkan pemahaman pada masalah berikutnya (Hosseiny dkk. 2020). Pendekatan seperti itu secara khusus berguna ketika (a) model saat ini tidak sepenuhnya mampu menerjemahkan bahasa-bahasa fisika dalam bentuk istilah matematika, (b) biaya komputasi tidak praktis atau tidak sedikit, atau (c) pengetahuan yang tersedia tentang masalah terbatas (Chen dkk. 2019). Ini telah membuat pendekatan Machine Learning (ML) sebagai alat yang ampuh untuk menilai berbagai aspek rekayasa sumber daya air, namun tidak terbatas pada jaringan distribusi air, analisis kualitas air, hubungan tahap-debit, transportasi sedimen, estimasi curah hujan dan pemetaan kerentanan makanan (Hosseiny dkk, 2020). Karena metodologi berbasis proses membutuhkan waktu terlalu lama untuk dimodelkan (Wang dan Song, 2020), studi terbaru telah memprediksi ketinggian air menggunakan model ML berbasis data, seperti artificial neural network (ANN).

Recurrent Neural Network (RNN) adalah salah satu model jenis ANN yang mencakup lapisan berulang. Perbedaan antara lapisan rekuren dan lapisan tersembunyi yang terhubung penuh biasa adalah bahwa neuron di dalam lapisan rekuren dapat terhubung satu sama lain (Kusudo dkk, 2022). Namun, keterbatasan aplikasi RNN adalah ketidakmampuannya untuk mempelajari dan memproses tugas yang bersifat ketergantungan jangka panjang secara otomatis, yang mengakibatkan penurunan akurasi prediksi. Long short-term memory (LSTM) memecahkan masalah tersebut dengan memiliki masa pakai memori jangka pendek yang lebih lama melalui input, sehingga membuka jalan untuk pelatihan yang lebih efisien dan intensif dengan kumpulan data deret waktu atau rentan waktu yang besar. Tingkat kesalahan yang lebih rendah ditemukan dengan jaringan LSTM dibandingkan dengan RNN dan gated recurrent units (GRUs) yang menggunakan ketergantungan long-short yang lebih sederhana daripada jaringan LSTM (Pan dkk, 2020).

Model LSTM telah berhasil digunakan dalam penelitian yang berhubungan dengan mengukur ketinggian air. Contohnya seperti analisis evaluasi dan perubahan permukaan air (Kusudo dkk, 2022) mempertimbangkan curah hujan (Chorong dan Chung-Soo, 2021) bahkan dengan mempertimbangkan sedimen untuk mengukur ketinggian air dari suatu wilayah atau daerah (Zhao dkk, 2020). LSTM telah menunjukkan kinerja yang lebih baik bila dibandingkan dengan Recurrent Neural Networks (RNN) yang terjaga keamanannya dan wavelet neural networks (WNN) untuk prediksi deret waktu multi-step aliran limbah keluar (Zhang dkk, 2020). LSTM dapat menangkap ketergantungan jangka panjang antara input dan output untuk memprediksi limpasan curah hujan (Gude dkk, 2020). LSTM juga membuktikan bahwa dapat memprediksi ketinggian air lebih akurat daripada model hidrologi berbasis fisika yang saat ini digunakan seperti Autoregressive Integrated Moving Average (ARIMA) atau USGS (Gude dkk, 2020).

Penelitian model hidrologi menggunakan algoritma pembelajaran mendalam untuk pengelolaan air yang lebih baik. Model Single-Output Long Short-Term Memory (LSTM-SO) dan Encoder-Decoder Long Short-Term Memory (LSTM-ED) dikembangkan dan kinerjanya dibandingkan dengan menggunakan variabel input yang berbeda (Kusudo dkk, 2022). Kesalahan Root-Mean-Squared dan Efisiensi Nash-Sutcliffe diperkirakan untuk membandingkan kinerja model. Struktur dasar yang digunakan menghasilkan output yang diperoleh digunakan sebagai input selanjutnya. Proses ini diulangi terus menerus dan melakukan prediksi hingga 24 jam. Hasil penelitian menunjukkan bahwa model LSTM-ED memiliki akurasi yang lebih baik.

Penelitian analisis teknik berbasis AI untuk memperkirakan ketinggian air menurut curah hujan mengusulkan SVM dan teknik peningkatan gradien (Chorong dan Chung-Soo, 2021). Untuk AI deep learning, prakiraan ketinggian air dilakukan menggunakan jaringan LSTM di antara RNN yang


digunakan untuk analisis deret waktu atau rentan waktu. Sebagai hasil dari penelitian ini adalah dianalisis bahwa LSTM memiliki kesalahan terkecil dan kinerja analisis terbaik 6 dibandingkan dengan DNN dan SVM dalam memprediksi muka air tertinggi dan waktu terjadinya. Mengeksplorasi kesesuaian di dalam mengadopsi AutoDL untuk Penilaian Kualitas Air dengan menggambarkan perbandingan antara AutoDL dan model konvensional dan analisis untuk meramalkan kualitas air (Prasad dkk, 2022). Mengusulkan mekanisme yang bersahabat dengan biaya yang harus dikeluarkan untuk memfasilitasi model dalam mempelajari representasi fitur contoh dan fluktuasi. (CSLSTM) untuk memprediksi PWL (tingkat air pressurizer) dari PWR (reaktor air bertekanan) reaktor nuklir (Zhang dkk, 2020). Untuk mengatasi masalah yang disebabkan oleh penyebaran fitur hidrodinamik melalui aliran air MLP memanfaatkan fitur hidrodinamik dengan melatih spasial dan temporal serta mencari korelasi saluran yang berdekata langkah-langkah time-steps dan RNN untuk memprediksi ketinggian air berdasarkan data historis (Ren dkk, 2020).

Penelitian ini akan fokus dalam melakukan prediksi ketinggian permukaan air sungai dengan data time-series menggunakan algoritma LSTM. Implementasi model LSTM untuk melakukan prediksi atau peramalan. Penelitian juga bertujuan membuat model prediksi dengan menggunakan algoritma Long Short-Term Memory (LSTM) untuk melakukan prediksi ketinggian permukaan pintu air dengan menggunakan data time-series di Sungai Ciliwung. Pemamfaatannya berupa kontribusi ilmu pengetahuan dalam pemanfaatan algoritma LSTM untuk menghasilkan model prediksi dengan studi kasus sungai Ciliwung Jakarta. Manfaat hasil prediksi bisa digunakan untuk membantu dalam pengambilan keputusan pemerintah dalam hal mengantisipasi atau menanggulangi efek-efek dari meluapnya permukaan air sungai Ciliwung yang berpotensi terjadinya banjir terhadap pemukiman disekitar sungai. Dalam penelitian ini kami mempertimbangkan referensi (Pan dkk, 2020) dan (Bhar dan Bakshi, 2020) menggunakan data histori ketinggian air dirasa cukup untuk menjadi data utama dalam melakukan prediksi ketinggian permukaan air di Sungai Ciliwung DKI Jakarta pada penelitian kali ini. Data yang akan dikelola bersumber dari sebuah situs yang menyediakan dataset DKI Jakarta dengan rentan waktu dari tahun 2018 sampai dengan tahun 2020 yaitu 36 bulan dengan bentuk tipe data rentan waktu.

METODE

Long Short-Term Memory (LSTM)

Cell pada LSTM dapat dilihat pada Gambar 2.1 yang terdiri dari layer neuron dilambangkan dengan persegi panjang, operasi element-wise dilambangkan dengan lingkaran. Panah hitam melambangkan aliran informasi didalam cell dan antar cell maupun keluaran dari cell (output h). Cell LSTM mempunyai 2 hasil keluaran, yang pertama adalah informasi yang sebenarnya hidden state (h_t) yang diteruskan ke cell selanjutnya menjadi input dari cell selanjutnya, yang kedua yaitu cell state (C_t). C_t merupakan kunci utama dari LSTM. Cell merupakan garis horizontal yang menghubungkan semua output layer pada LSTM seperti pada. LSTM memiliki kemampuan untuk menambah atau menghapus informasi dari cell state yang disebut gates. Gate berfungsi mengatur informasi masuk secara opsional dengan menggunakan sigmoid layer yang. Keluaran dari sigmoid layer menunjukkan informasi diteruskan dengan simbol angka 1 atau dihentikan dengan simbol angka 0. Langkah persamaan LSTM dapat dilihat pada persamaan dibawah.



$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (2.1)$$

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (2.2)$$

$$\tilde{C}_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (2.3)$$

$$C_t = i_t * \tilde{C}_t + f_t * C_{t-1} \quad (2.4)$$

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (2.5)$$

$$h_t = o_t * \tanh(C_t) \quad (2.6)$$

Proses yang ada di sel LSTM terdapat data input pada deret waktu (x_t) dan data masukan dari langkah waktu sebelumnya (h_{t-1}). Tahap terakhir dalam sel LSTM akan menghitung hidden state untuk sel berikutnya yang merupakan hasil keluaran sel saat ini dan menjadi input untuk sel berikutnya serta sel pertama, nilai h_{t-1} diinisialisasikan menjadi 0 karena menjadi nilai paling awal. Fase berikut merupakan fase propagasi maju yang ada pada lapisan LSTM pada timestep 1 hingga 10.

- Menghitung nilai cell state (C)1 pada gerbang input menggunakan fungsi aktivasi tanh dan input gate dengan fungsi aktivasi sigmoid. Memory cell berfungsi untuk menyimpan informasi dari hidden unit diseluruh proses seperti pada formula 2.3.
- Nilai yang sudah didapatkan pada C 1 langkah selanjutnya adalah menghitung nilai yang ada pada input gate dengan menggunakan formula 2.2.
- Nilai yang diperoleh pada input gate, kemudian dilakukan penghitungan nilai pada forget gate untuk menyaring informasi yang tidak relevan menggunakan formula 2.1.
- Langkah selanjutnya adalah memperbarui status sel sebelumnya atau C_{t-1} menjadi status sel yang baru C_t menggunakan formula 2.4.
- Langkah berikutnya, output gate bertugas untuk menampilkan informasi dan mengirimkan informasi selanjutnya dari hidden state baru menggunakan formula 2.5.
- Hasil yang diperoleh dari gerbang output tersebut dimasukkan ke dalam fungsi tanh (nilai yang didapatkan pada fungsi tanh antara -1 dan 1), kemudian dikalikan dengan hasil keluaran dari gerbang sigmoid sehingga menghasilkan nilai keluaran yang telah ditentukan sebelumnya menggunakan formula 2.6.

Contoh perhitungan dengan menggunakan formula LSTM dapat dilihat pada Tabel 2.1 dibawah. Hasil tersebut didapatkan menggunakan nilai bobot yang diinisialisasikan serta data yang kami miliki sehingga menghasilkan nilai satu sampai dengan timestep 10.

Tabel 2.1 Hasil perhitungan LSTM dengan data latih.

Ts	Notasi					
	C_t	i_t	f_t	o_t	C_t	h_t
1	0.125994	0.5383	0.5449	0.5515	0.067817	0.037343
2	0.229036	0.5815	0.5553	0.5509	0.17085	0.093217
3	0.364603	0.6349	0.5576	0.5703	0.326764	0.179992
4	0.51724	0.6920	0.6388	0.5872	0.543001	0.290806
5	0.70998	0.7841	0.5513	0.5704	0.856057	0.395985
6	0.803081	0.8369	0.6389	0.5847	1.150788	1.150788
7	0.855299	0.8734	0.5561	0.5752	1.386957	0.507653
8	0.878137	0.8881	0.5605	0.6128	1.557267	0.560668
9	0.89803	0.9032	0.5746	0.6258	1.705919	0.585886
10	0.912375	0.9148	0.5899	0.5836	1.840934	0.554953

Mean Square Error (MSE)

Media untuk mengevaluasi kinerja model pada penelitian menggunakan Mean Square Error (MSE). MSE adalah metode alternatif untuk mengevaluasi teknik peramalan yang digunakan untuk mengukur tingkat akurasi hasil perkiraan suatu model metode ini secara umum digunakan untuk mengecek estimasi berapa nilai kesalahan pada peramalan (Kim dkk 2022) (Bhar dkk, 2020). Nilai yang dihasilkan MSE merupakan nilai rata-rata kuadrat dari jumlah kesalahan pada model prediksi. MSE adalah teknik yang mudah diimplementasikan dan telah banyak digunakan dalam berbagai studi yang berkaitan dengan (Karunasingha 2022). MSE merupakan fungsi yang bisa mendefinisikan kesalahan error pada sebuah garis regresi yang ada. Caranya adalah dengan menghitung selisih dari nilai sebenarnya atau aktual y_i dengan nilai prediksi $\hat{y}_i$ yang didapat kemudian hasilnya dikuadratkan, hasil keseluruhan dari kuadrat semua data observasi yang dipakai kemudian dibagi

dengan jumlah total data abservasi (Nilesh dkk, 2022). Persamaan evaluasi akurasi MSE dapat dilihat dibawah.

$$\begin{aligned} \text{MSE} &= \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \\ &= \frac{(y_1 - \hat{y}_1)^2 + (y_2 - \hat{y}_2)^2 + (y_3 - \hat{y}_3)^2 + \dots + (y_n - \hat{y}_n)^2}{n} \end{aligned} \quad (2.7)$$

Dimana;

y_i = Nilai sebenarnya atau aktual

$\hat{y}_i$ = Nilai prediksi

n = Jumlah data obeservasi

TEMUAN PEMBAHASAN


Hasil akurasi dari pembuatan model terkadang sangat kurang dari yang diharapkan, bukan hanya masalah dataset dan preprocessing yang kurang baik, tapi pemilihan parameter untuk prediksi dapat menjadi salah satu penyebabnya. Hasil penelitian ini juga didapat dari menentukan berapa nilai sliding window. Metode ini akan menghasilkan variabel input (x) dan variabel target berupa (y), karena tidak ada standart baku dalam menentukan nilai window biasanya akan dilakukan beberapa percobaan untuk mencari nilai yang paling sesuai, namun terdapat resiko dalam mencari nilai window yaitu semakin besar nilai window yang dipakai akan semakin memerlukan waktu yang cukup lama dalam proses trining dataset. Penelitian kali ini kami menggunakan window size dengan nilai 144, nilai ini kami gunakan dengan asumsi kami mencoba melakukan prediksi dengan rentan waktu setiap 10 menit selama 24 jam dengan kata lain kami bisa menghasilkan data ketinggian air sebanyak 144 data. Scikit-Learn kita akan menggunakan GridSearchCV, ini untuk mencari parameter terbaik untuk pengklasifikasi yang ingin kita gunakan. Prosesnya akan dilakukan secara brute force dan melaporkan parameter yang memiliki akurasi paling baik, setelah melalui proses GridSearchCV kemudian dapat memilih parameter yang terbaik juga dengan demikian akurasi pun dapat meningkat lebih signifikan ketimbang tidak menggunakan GridSearchCV. Loss merupakan nilai dari penghitungan loss function dari training dataset dan prediksi dari model, ditahap ini kami juga menggunakan early stopping dengan maksud untuk menghentikan training model guna mencegah overfitting model. Validation loss nilai penghitungan loss function dari validation dataset dan prediksi dari modelnya dengan input data dari validation dataset tersebut. Hasil dari training model terbaik yang menggunakan fitur GridSearchCV seperti pada Tabel 3.1 dibawah.

Tabel 3.1 Hasil nilai parameter terbaik

Loss Function	LSTM Unit	Dropout
-0.004488 (0.003463)	16	0.1
-0.004462 (0.003224)	16	0.2
-0.004173 (0.003269)	32	0.1
-0.004107 (0.003162)	32	0.2
-0.004150 (0.003173)	64	0.1
-0.004571 (0.003210)	64	0.2
-0.004118 (0.003204)	128	0.1
-0.004279 (0.003142)	128	0.2

Hasil dari penelitian akan berupa prediksi dari pintu air yang ada di sungai Ciliwung DKI Jakarta dari 9 pintu air yang tersebar disepanjang sungai itu mengalir namun menggunakan Bendung Cibelok Gadog sebagai sampel penelitian. Hasil berupa diagram yang menunjukkan ketinggian (Sentimeter/cm) dengan rentan waktu 24 jam dari salah satu pintu air sebagai sampel, penelitian pada sub bab ini akan dijelaskan hasil implementasi peramalan ketinggian air dari permukaan pintu air sungai Ciliwun. Hasil dari optimasi Adam akan menghasilkan nilai bobot baru, bobot baru tersebut yang nantinya akan digunakan untuk lebih mengoptimalkan kinerja algoritma LSTM dalam

melakukan prediksi ketinggian permukaan air. Hasil prediksi model menggunakan data latih dan uji sebagai percobaan seperti pada Gambar 3.1 dan 3.2 dibawah.




Gambar 3.1 Hasil prediksi data latih



Gambar 3.2 Hasil prediksi data uji

Prediksi yang dilakukan menggunakan data uji untuk tujuan pengujian model menghasilkan Gambar 4.11 yang divisualisasikan dalam bentuk plot. Hasil yang menunjukkan data test prediksi sepanjang tujuh hari terakhir sebelum peramalan dimasa depan bisa dilihat pada pada Gambar 3.3 dibawah.



Gambar 3.3 Hasil prediksi 7 hari terakhir dengan data latih

Pembuatan model menggunakan komputasi python, dalam pembuatan model juga da perintah yang menunjukkan sebuah syntac yang berupa `n_future = 144` yang menjelaskan bahwa peramalan yang akan dilakukan sepanjang waktu 24 jam, 144 menunjukkan bahwa data ketinggian air akan menghasilkan data 10 menit sekali yang berarti peramalan ini akan menghasilkan data sebanyak 144 data ketinggian air sepanjang waktu 24 jam dimasa depan. Data menunjukkan waktu dan ketinggian air yang akan terjadi di pintu air tersebut dalam bentuk plot gambar agar lebih mudah dipahami pergerakan garisnya. Gambar 3.4 dibawah menunjukkan salah satu sampel pintu air yang menjadi penelitian kali ini.



Gambar 3.4 Hasil prediksi data latih

Tabel 3.2 dibawah adalah bentuk data peramalan yang berhasil dilakukan disalah satu pintu air yang bernama Bendung Cibalok Gadog Sungai Ciliwung. Data menunjukkan waktu dan ketinggian air yang akan terjadi di pintu air tersebut, satuan waktunya adalah setiap 10 menit dengan perubahan ketinggian air bisa dipantau dengan seksama pada tabel. Tabel tersebut dapat kita lihat waktu terawal menunjukkan pada tanggal dan waktu 12/31/2020 23:20 dengan ketinggian 130.2 cm sedangkan waktu terakhir menunjukkan pada 1/7/2021 23:20 dengan ketinggian pada angka 118.9 cm. Tabel yang kami buat adalah sebagai contoh untuk pintu air dan pintu sungai yang lain bahwa prosesnya akan sama, jadi kami rasa cukup dengan menampilkan sampel berupa satu pintu air sebagai contoh pengerjaan penelitian ini.

Tabel 3.2 Tabel ramalan 24 jam dimasa depan

No	Nama PA	1/Jan/2021	Ketinggian (cm)
1	Bendung Cibalok Gadog	00:10	130.00
2	Bendung Cibalok Gadog	00:20	123.847
3	Bendung Cibalok Gadog	00:30	123.909
4	Bendung Cibalok Gadog	00:40	123.685
5	Bendung Cibalok Gadog	00:50	123.37
....			
143	Bendung Cibalok Gadog	23:50	115.163
144	Bendung Cibalok Gadog	23:60	115.159

Penelitian ini menggunakan Mean Squared Error (MSE) untuk melakukan evaluasi akurasi model, evaluasi model menggunakan data latih sebanyak 6.829 sedangkan data uji sebanyak 2.845. Nilai yang didapat tergolong kecil untuk ukuran data latih dan uji dengan menunjukkan nilai kesalahan atau perbedaan nilai aktual dengan nilai prediksi, hasil yang diperoleh telah dilakukan perataan atau mencari nilai rata-rata dari masing-masing jenis data. Preses dalam melakukan evaluasi akurasi dimulai dengan mempersiapkan dua jenis data aktual dikurangi dengan data hasil prediksi yang kemudian akan dilakukan perkalian kuadrat. Proses tersebut dilakukan memperimbangan sebanyak apa data yang digunakan dalam penelitian, setelah semua data sudah dilakukan penjumlahan maka total hasilnya akan dibagikan berdasarkan jumlah data observasi yang digunakan. Nilai rata-rata pada hasil prediksi setelah dilakukan evaluasi dari prediksi data tersebut menunjukkan nilai 3620.69 untuk data latih dan 1467.35 untuk nilai data uji, nilai ini terbilang cukup besar untuk model prediksi, namuh dengan nilai tersebut tergolong nilai yang wajar melihat paramater yang digunakan untuk model prediksi. Nilai evaluasi akurasi MSE dapat dilihat pada Tabel 3.3 dibawah.

Tabel 3.3 Nilai evaluasi akurasi MSE data latih dan uji

Nilai Evaluasi MSE	
Data Latih	Data Uji
3620.69	1467.35

Peramalan dilakukan dengan berdasarkan parameter yang tersedia serta pengerjaan dan pengamatan yang telah dilakukan diatas, terdapat beberapa faktor yang mungkin mempengaruhi hasil akhir dari penelitian. Faktor yang mempengaruhi yaitu dataset yang digunakan sebagaimana disebutkan sebelumnya, didalam penelitian ini data yang digunakan dirasa tidak ada masalah kalau terakait dengan masalah jumlah, namun yang jadi masalah adalah datanya tidak variatif sehingga menyebabkan variabelnya terlalu sedikit sebagai bahan pertimbangan lebih validnya hasil yang bisa didapat nantinya.

Data observasi yang digunakan menunjukkan bahwa data yang bisa dipakai untuk membuat peremalan murni hanya time-series dari ketinggian air yang dihasilkan serta hasil dari normalisasi secara komputasi. Dari awal memang itulah tujuan dari penelitian kami, yaitu untuk mencari tau seberapa akuratkah jika melakukan peramalan hanya dengan data yang tidak cukup variatif dan cuma mengandalkan jumlah semata. Model melakukan pelatihan dengan hasil prediksi yang baik namun saat dilakukan proses validasi kemampuan model menurun sehingga mengurangi nilai akurasi. Penelitian ini berdasarkan hasil pelatihan model menunjukkan bahwa implementasi model

LSTM dengan metode optimasi Adam untuk mencari nilai bobot baru menghasilkan nilai loss dan akurasi yang tidak terlalu baik dan belum dapat digunakan untuk sepenuhnya menjadi acuan dari keakuratan peramalan ketinggian permukaan pintu air sungai Ciliwung jika hanya dengan bermodalkan data time series semata.

Hasil dari penelitian ini yaitu penggunaan model long short-term memory untuk melakukan peramalan dengan objek studi kasus ketinggian permukaan pintu air sungai Ciliwung telah berhasil dilakukan menggunakan data time series setiap 10 menit sekali selama rentan waktu 24 jam dimasa depan seperti pada Tabel 3.2 diatas. Uji coba dengan menggunakan dataset satu pintu air yaitu Bendung Cibalok Gadog dengan jumlah 9.963 data yang telah dilakukan normalisasi menunjukkan hasil evaluasi model akurasi nilai MSE sebesar 3620.69 dengan menggunakan 6.829 data latih dan nilai MSE 1467.35 untuk 2.845 data uji seperti pada Tabel 3.3. Pintu air dan pintu sungai yang menjadi bahan penelitian anatara lain yaitu Bendung Cibalok Gadog, Bendung, Katulampa (Hulu), PS Depok, PA Manggarai, PA Istiqlal, PA Jembatan Merah, PA Flusing Ancol, PA Cibalok Gadog dan PS Katulampa (Hulu) juga menghasilkan nilai yang serupa.

Hasil penelitian menunjukkan data belum bisa dijadikan sebagai acuan utama dalam memastikan ketinggian permukaan air secara akurat, hal itu terbukti dari semua bentuk garis yang dihasilkan dari semua plot seperti pada Gambar 3.4 bernilai kurang meyakinkan. Penelitian ini masih terdapat beberapa kekurangan, adapun kekurangan tersebut disebabkan oleh dataset yang kurang variatif dalam variabel peramalan penelitian ini termasuk dari validitas data itu sendiri. Penelitian ini akan menghasilkan yang lebih akurat jika pada kasus ini data yang digunakan lebih banyak atau variatif seperti curah hujan, kepadatan penduduk, angin serta cuaca dari ekstraksi satelit dan lain sebagainya. Penelitian lebih lanjut perlu dilakukan untuk mempelajari cara paling optimal didalam melakukan implementasi data yang sangat banyak serta beragam. Penelitian kali ini berdasarkan jenis dan jumlah data tersebut menjadi batasan masalah karena menggunakan dataset yang tergolong sudah siap digunakan untuk melakukan peramalan. Penelitian ini lebih fokus kepada menguji keakuratan pembuatan model LSTM dengan metode optimasi Adam terhadap peramalan ketinggian permukaan air berdasarkan data history atau time-series yang sangat besar, berdasarkan penjelasan tersebut penggunaan data yang cenderung lebih banyak dan variatif menjadi batasan masalah dalam penelitian ini.

KESIMPULAN

Model prediksi dengan tujuan mengukur ketinggian permukaan air sungai Ciliwung DKI Jakarta berhasil dibuat berdasarkan data time-series dari history sungai dengan menggunakan salah satu model deep neural network learning yaitu algoritma LSTM. Hasil penelitian menunjukkan data belum bisa dijadikan sebagai acuan utama dalam memprediksi ketinggian permukaan air secara akurat, hal itu terbukti dari hasil dengan jumlah data 9.963, nilai MSE sebesar 3620.69 dengan menggunakan 6.829 data training dan nilai MSE 1467.35 untuk 2.845 data uji sebagai sampel. Metode ini bekerja dengan baik walaupun dengan data yang tidak variatif dan menghasilkan nilai yang memuaskan untuk melakukan prediksi.

Penelitian selanjutnya dapat menghasilkan tingkat akurasi yang tinggi sangat disarankan menggunakan lebih banyak variabel. Metode yang terbaru atau sudah diperbaharui akan membantu mengurangi banyak penyesuaian yang dibutuhkan dalam implementasinya. Penelitian selanjutnya juga sangat disarankan mempertimbangkan penggunaan perangkat komputasi yang lebih mempunyai, semakin banyak data serta semakin variatif variabel yang digunakan maka beban pemrosesan komputasi akan semakin berat dan semakin banyak memakan waktu.

REFERENSI

Bhar, Kalyan Kumar, and Susmita Bakshi. 2020. "Application of Artificial Neural Network for Predicting Water Levels in Hooghly Estuary, India." *H2Open Journal* 3 (1): 401–15.

<https://doi.org/10.2166/h2oj.2020.041>.

Chang, Z., Yang Zhang, and W. Chen. 2019. "Electricity Price Prediction Based on Hybrid Model of Adam Optimized LSTM Neural Network and Wavelet Transform." *Energy* 187: 115804.

<https://doi.org/10.1016/j.energy.2019.07.134>.

- Chen, Wei, Haoyuan Hong, Shaojun Li, Himan Shahabi, Yi Wang, Xiaojing Wang, and Baharin Bin Ahmad. 2019. "Flood Susceptibility Modelling Using Novel Hybrid Approach of Reduced-Error Pruning Trees with Bagging and Random Subspace Ensembles." *Journal of Hydrology* 575: 864–73.
<https://doi.org/10.1016/j.jhydrol.2019.05.089>.
- Chen, Yongping, Min Gan, Shunqi Pan, Haidong Pan, Xian Zhu, and Zhengjin Tao. 2020. "Application of Auto-Regressive (AR) Analysis to Improve Short-Term Prediction of Water Levels in the Yangtze Estuary." *Journal of Hydrology* 590: 1–11.
<https://doi.org/10.1016/j.jhydrol.2020.125386>.
- Choi, Changhyun, Jungwook Kim, Heechan Han, Daegun Han, and Hung Soo Kim. 2020. "Development of Water Level Prediction Models Using Machine Learning in Wetlands: A Case Study of Upo Wetland in South Korea." *Water (Switzerland)* 12 (1): 1–18.
<https://doi.org/10.3390/w12010093>.
- Chorong, Kim, and Kim Chung-Soo. 2021. "Analysis of AI-Based Techniques for Forecasting Water Level According to Rainfall." *Tropical Cyclone Research and Review* 10 (4): 223–28.
<https://doi.org/10.1016/j.tcr.2021.12.002>.
- Gude, Vinayaka, Steven Corns, and Suzanna Long. 2020. "Flood Prediction and Uncertainty Estimation Using Deep Learning." *Water (Switzerland)* 12 (3): 1–16.
<https://doi.org/10.3390/w12030884>.
- Hosseiny, Hossein, Foad Nazari, Virginia Smith, and C. Nataraj. 2020. "A Framework for Modeling Flood Depth Using a Hybrid of Hydraulics and Machine Learning." *Scientific Reports* 10 (1): 1–14.
<https://doi.org/10.1038/s41598-020-65232-5>.
- Karunasingha, Dulakshi Santhusitha Kumari. 2022. "Root Mean Square Error or Mean Absolute Error? Use Their Ratio as Well." *Information Sciences* 585: 609–29.
<https://doi.org/10.1016/j.ins.2021.11.036>.
- Kim, Boeun, Kyung Hwan Ryu, and Seongmin Heo. 2022. "Mean Squared Error Criterion for Model-Based Design of Experiments with Subset Selection." *Computers and Chemical Engineering* 159: 107667.
<https://doi.org/10.1016/j.compchemeng.2022.107667>.
- Kusudo, Tsumugu, Atsushi Yamamoto, Masaomi Kimura, and Yutaka Matsuno. 2022. "Development and Assessment of Water-Level Prediction Models for Small Reservoirs Using a Deep Learning Algorithm." *Water (Switzerland)* 14 (1): 1–16.
<https://doi.org/10.3390/w14010055>.
- Liu, Yu, Hao Wang, Xiaohui Lei, and Hao Wang. 2021. "Real-Time Forecasting of River Water Level in Urban Based on Radar Rainfall: A Case Study in Fuzhou City." *Journal of Hydrology* 603: 1–14.
<https://doi.org/10.1016/j.jhydrol.2021.126820>.
- Mislan, A. F.O. Gaffar, Havaluddin, and N. Puspitasari. 2018. "Water Level Prediction of Lake Cascade Mahakam Using Adaptive Neural Network Backpropagation (ANNBP)." *IOP Conference Series: Earth and Environmental Science* 144 (1): 1–8.
<https://doi.org/10.1088/1755-1315/144/1/012009>.
- Nhu, Viet Ha, Himan Shahabi, Ebrahim Nohani, Ataollah Shirzadi, Nadhir Al-Ansari, Sepideh Bahrami, Shaghayegh Miraki, Marten Geertsema, and Hoang Nguyen. 2020. "Daily Water Level Prediction of Zrebar Lake (Iran): A Comparison between M5p, Random Forest, Random Tree and Reduced Error Pruning Trees Algorithms." *ISPRS International Journal of Geo-Information* 9 (8): 1–19.
<https://doi.org/10.3390/ijgi9080479>.
- Nilesh Kumar Rai, and Pradum Shukla, Rabindra Nath Shaw D. Saravanan Labh Kumar. 2022. "Chapter Ten - Rmse And Mape Analysis For Short-Term Solar Irradiance, Solar Energy, And Load

Forecasting Using A Recurrent Artificial Neural Network.” *Applications of AI and IOT in Renewable Energy*, 181–92.

<https://doi.org/10.1016/B978-0-323-91699-8.00010-3>.

Pan, Mingyang, Hainan Zhou, Jiayi Cao, Yisai Liu, Jiangling Hao, Shaoxi Li, and Chi Hua Chen. 2020. “Water Level Prediction Model Based on GRU and CNN.” *IEEE Access* 8: 60090–100.

<https://doi.org/10.1109/ACCESS.2020.2982433>.

Prasad, D. Venkata Vara, Lokeswari Y. Venkataramana, P. Senthil Kumar, G. Prasannamedha, S. Harshana, S. Jahnvi Srividya, K. Harrinei, and Sravya Indraganti. 2022. “Analysis and Prediction of Water Quality Using Deep Learning and Auto Deep Learning Techniques.” *Science of The Total Environment* 821 (153311): 1–20.

<https://doi.org/10.1016/j.scitotenv.2022.153311>.

Ren, Tao, Xuefeng Liu, Jianwei Niu, Xiaohui Lei, and Zhao Zhang. 2020. “Real-Time Water Level Prediction of Cascaded Channels Based on Multilayer Perception and Recurrent Neural Network.” *Journal of Hydrology* 585: 1–14.

<https://doi.org/10.1016/j.jhydrol.2020.124783>.

Smagulova, Kamilya, and Alex Pappachen James. 2019. “A Survey on LSTM Memristive Neural Network Architectures and Applications.” *European Physical Journal: Special Topics* 228 (10): 2313–24.

<https://doi.org/10.1140/epjst/e2019-900046-x>.

Soebroto, Arief Andy, Imam Cholissodin, Randy Cahya Wihandika, Maria Tenika Frestantiya, and Ziya El Arief. 2015. “Prediksi Tinggi Muka Air (TMA) Untuk Deteksi Dini Bencana Banjir Menggunakan SVR-TVIWPSO.” *Jurnal Teknologi Informasi Dan Ilmu Komputer* 2 (2): 79–86.

<https://doi.org/10.25126/jtiik.201522126>.

Syarifa, Syifa. 2019. “Pencemaran Sungai Ciliwung Dan Dampak Buruknya Bagi Masyarakat Dki Jakarta.” *Jurnal Ilmiah Pendidikan Lingkungan Dan Pembangunan* 16 (02): 2–6.

Tsujikura, Hiroki, Kohji Tanaka, and Yasuto Tachikawa. 2016. “Development of a Water Surface Level Prediction Method Affected by River Mouth Sandbar Collapse.” *Procedia Engineering* 154: 1349–58.

<https://doi.org/10.1016/j.proeng.2016.07.491>.

Wang, Qi, and Wang Song. 2020. “Machine Learning-Based Water Level Prediction in Lake Erie.” *Water (Switzerland)* 12 (10): 1–14.

<https://doi.org/10.3390/w12102654>.

Wibowo, A., P. W. Wiryawan, and N. I. Nuqoyati. 2019. “Optimization of Neural Network for Cancer Micro RNA Biomarkers Classification.” *Journal of Physics: Conference Series* 1217 (1): 0–8.

<https://doi.org/10.1088/1742-6596/1217/1/012124>.

Zhang, Jin, Xiaolong Wang, Cheng Zhao, Wei Bai, Jun Shen, Yang Li, Zhisong Pan, and Yexin Duan. 2020. “Application of Cost-Sensitive LSTM in Water Level Prediction for Nuclear Reactor Pressurizer.” *Nuclear Engineering and Technology* 52 (7): 1429–35.

<https://doi.org/10.1016/j.net.2019.12.025>.

Zhao, Gang, Bo Pang, Zongxue Xu, and Liyang Xu. 2020. “A Hybrid Machine Learning Framework for Real-Time Water Level Prediction in High Sediment Load Reaches.” *Journal of Hydrology* 581: 1–10.

<https://doi.org/10.1016/j.jhydrol.2019.124422>.