



**ANALISIS KINERJA ALGORITMA CNN DAN LSTM UNTUK
MEMPREDIKSI TINGGI MUKA AIR DI DKI JAKARTA, INDONESIA**

TUGAS AKHIR

Ayu Wulandari
41518010117

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS MERCU BUANA
JAKARTA
2022**

MERCU BUANA



**ANALISIS KINERJA ALGORITMA CNN DAN LSTM UNTUK
MEMPREDIKSI TINGGI MUKA AIR DI DKI JAKARTA, INDONESIA**

Tugas Akhir

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer

Oleh:
Ayu Wulandari
41518010117

PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS ILMU KOMPUTER

UNIVERSITAS MERCU BUANA

JAKARTA

MERCU BUANA
2022

LEMBAR PERNYATAAN ORISINALITAS

LEMBAR PERNYATAAN ORISINALITAS

Yang bertanda tangan dibawah ini:

NIM : 41518010117

Nama : Ayu Wulandari

Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk
Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia

Menyatakan bahwa Laporan Tugas Akhir saya adalah hasil karya sendiri dan bukan plagiat. Apabila ternyata ditemukan didalam laporan Tugas Akhir saya terdapat unsur plagiat, maka saya siap untuk mendapatkan sanksi akademik yang terkait dengan hal tersebut.

Jakarta, 14 Maret 2022



Ayu Wulandari



UNIVERSITAS
MERCU BUANA

SURAT PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR

SURAT PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR

Sebagai mahasiswa Universitas Mercu Buana, saya yang bertanda tangan di bawah ini :

Nama Mahasiswa : Ayu Wulandari
NIM : 41518010117
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia

Dengan ini memberikan izin dan menyetujui untuk memberikan kepada Universitas Mercu Buana **Hak Bebas Royalti Noneksklusif** (*None-exclusive Royalty Free Right*) atas karya ilmiah saya yang berjudul diatas beserta perangkat yang ada (jika diperlukan).

Dengan Hak Bebas Royalti/Noneksklusif ini Universitas Mercu Buana berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat dan mempublikasikan tugas akhir saya.

Selain itu, demi pengembangan ilmu pengetahuan di lingkungan Universitas Mercu Buana, saya memberikan izin kepada Peneliti di Lab Riset Fakultas Ilmu Komputer, Universitas Mercu Buana untuk menggunakan dan mengembangkan hasil riset yang ada dalam tugas akhir untuk kepentingan riset dan publikasi selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 14 Maret 2022


METERAI TEMPEL
059FDAJX703747288
Ayu Wulandari

UNIVERSITAS
MERCU BUANA

SURAT PERNYATAAN LUARAN TUGAS AKHIR

SURAT PERNYATAAN LUARAN TUGAS AKHIR

Sebagai mahasiswa Universitas Mercu Buana, saya yang bertanda tangan di bawah ini :

Nama Mahasiswa : Ayu Wulandari
NIM : 41518010117
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia

Menyatakan bahwa :

1. Luaran Tugas Akhir saya adalah sebagai berikut :

No	Luaran	Jenis	Status
1	Publikasi Ilmiah	Jurnal Nasional Tidak Terakreditasi	Diajukan ✓
		Jurnal Nasional Terakreditasi	
		Jurnal International Tidak Bereputasi	Diterima
		Jurnal International Bereputasi	
	Disubmit/dipublikasikan di :	Nama Jurnal : Rekayasa Sistem dan Teknologi Informasi (RESTI) ISSN : 2580-0760 Link Jurnal : http://jurnal.iaii.or.id/index.php/RESTI Link File Jurnal Jika Sudah di Publish :	

2. Bersedia untuk menyelesaikan seluruh proses publikasi artikel mulai dari submit, revisi artikel sampai dengan dinyatakan dapat diterbitkan pada jurnal yang dituju.
3. Diminta untuk melampirkan scan KTP dan Surat Pernyataan (Lihat Lampiran Dokumen HKT), untuk kepentingan pendaftaran HKI apabila diperlukan

Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 14 Maret 2022

UNIVERSITA
MERCU BUANA



BBAA91AJX783747254
Ayu Wulandari

LEMBAR PERSETUJUAN PENGUJI

LEMBAR PERSETUJUAN PENGUJI

NIM : 41518010117
Nama : Ayu Wulandari
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk
Memprediksi Tinggi Muka Air di DKI Jakarta,
Indonesia

Tugas Akhir ini telah diperiksa dan disidangkan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana.

Jakarta, 18 Maret 2022



(Wawan Gunawan, S.Kom. MT)
Anggota Penguji 2

UNIVERSITAS
MERCU BUANA

LEMBAR PERSETUJUAN PENGUJI

LEMBAR PERSETUJUAN PENGUJI

NIM : 41518010117
Nama : Ayu Wulandari
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk
Memprediksi Tinggi Muka Air di DKI Jakarta,
Indonesia

Tugas Akhir ini telah diperiksa dan disidangkan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana.

Jakarta, 30 Maret 2022



(Umniy Salamah, ST., MMSI)
Anggota Penguji 1

UNIVERSITAS
MERCU BUANA

LEMBAR PERSETUJUAN PENGUJI

LEMBAR PERSETUJUAN PENGUJI

NIM : 41518010117
Nama : Ayu Wulandari
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk
Memprediksi Tinggi Muka Air di DKI Jakarta,
Indonesia

Tugas Akhir ini telah diperiksa dan disidangkan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana.

Jakarta, 18 Maret 2022



(Wawan Ginayun, S.Kom, MT)
Anggota Penguji 2

UNIVERSITAS
MERCU BUANA

LEMBAR PENGESAHAN

LEMBAR PENGESAHAN

LEMBAR PENGESAHAN

NIM : 41518010117
Nama : Ayu Wulandari
Judul Tugas Akhir : Analisis Kinerja Algoritma CNN dan LSTM untuk
Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia

Tugas Akhir ini telah diperiksa dan disidangkan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana.

Jakarta, 22 Maret 2022

Menyetujui,



(Vina Ayumi, S.Kom, M.Kom)
Dosen Pembimbing

Mengetahui,



(Wawan Ghawan, S.Kom, MT)
Koord. Tugas Akhir Teknik Informatika



(Emil R. Kaburuan, Ph.D.)
Ka. Prodi Teknik Informatika

UNIVERSITAS
MERCU BUANA

KATA PENGANTAR

Puji syukur saya panjatkan kehadiran Allah SWT yang telah memberikan segala rahmat dan karunia-Nya, sehingga saya dapat menyelesaikan Tugas Akhir yang berjudul “Analisis Kinerja Algoritma CNN dan LSTM untuk Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia” dalam jangka waktu yang sudah ditentukan. Tanpa pertolongan-NYA, mungkin saya tidak akan sanggup menyelesaikan dengan baik. Laporan Tugas Akhir ini dibuat sebagai syarat untuk LULUS sebagai sarjana Ilmu Komputer dari Universitas Mercu Buana.

Penulis menyadari dalam pembuatan Tugas Akhir ini tidak terlepas dari bantuan dan bimbingan dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Keluarga saya, khususnya nenek dan kakek serta kedua orang tua saya yang telah menyemangati, mendukung dan selalu mendoakan yang terbaik untuk proses meraih gelar sarjana. Serta selalu percaya bahwa saya bisa menyelesaikan kuliah dengan baik.
2. Ibu Harni Kusniyati, M.Kom selaku Dosen Pembimbing Akademik yang telah memantau dan membantu studi saya hingga akhir.
3. Ibu Vina Ayumi S.Kom., M.Kom. selaku dosen Pembimbing Tugas Akhir yang telah memberikan masukan saat bimbingan dan meluangkan waktu sebagian besarnya untuk melakukan bimbingan dalam penyusunan tugas akhir ini hingga selesai.
4. Seluruh Dosen Program Studi Teknik Informatika yang sudah memberikan ilmu yang bermanfaat selama kuliah berlangsung. Memberi kesempatan untuk belajar, berkarya dan juga berkembang.
5. Seluruh Staff Administrasi dan Tata Usaha yang telah banyak membantu dan memberikan kemudahan, terima kasih atas semua pelayanan dan arahannya.
6. Sahabat dan kerabat, yang telah memberikan semangat, dukungan dan doa sehingga saya bisa melewati dan menyelesaikan Tugas Akhir ini dan mendapatkan gelar sarjana.

7. Pihak-pihak dan personal yang tidak dapat disebut satu per satu yang terlibat dalam pembuatan Tugas Akhir ini sehingga dapat selesai dengan baik.

Akhir kata, penulis berharap Tugas Akhir ini dapat menjadi referensi untuk dikembangkan lebih baik lagi kedepannya, karena penulis menyadari hasil Tugas Akhir ini masih jauh dari sempurna. Masih terdapat kekurangan dalam eksperimen, cara penjelasan maupun kekeliruan penulisan. Untuk itu, kritik dan saran pembaca sangat dihargai dan diharapkan. Semoga Tugas Akhir ini dapat memberikan manfaat bagi para pembaca.

Jakarta, 18 Januari 2022

Penulis



DAFTAR ISI

HALAMAN SAMPUL.....	i
HALAMAN JUDUL	i
LEMBAR PERNYATAAN ORISINALITAS	ii
SURAT PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR... iii	
SURAT PERNYATAAN LUARAN TUGAS AKHIR.....	iv
LEMBAR PERSETUJUAN PENGUJI	v
LEMBAR PENGESAHAN	viii
ABSTRAK	ix
ABSTRACT.....	x
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
NASKAH JURNAL	1
KERTAS KERJA.....	10
BAB 1. LITERATUR REVIEW	11
BAB 2. ANALISIS DAN PERANCANGAN.....	30
BAB 3. SOURCE CODE	34
BAB 4. DATASET.....	44
BAB 5. TAHAPAN EKSPERIMEN.....	46
BAB 6. HASIL SEMUA EKSPERIMEN.....	50
DAFTAR PUSTAKA	58
LAMPIRAN DOKUMEN HAKI.....	61
LAMPIRAN KORESPONDENSI	64
CURRICULUM VITAE.....	65

NASKAH JURNAL

Terakreditasi SINTA Peringkat 2

Surat Keputusan Direktur Jenderal Pendidikan Tinggi, Riset, dan Teknologi, Nomor: 158/E/KPT/2021
masa berlaku mulai Volume 5 Nomor 2 Tahun 2021 sampai Volume 10 Nomor 1 Tahun 2026

Terbit online pada laman web jurnal: <http://jurnal.iaii.or.id>



JURNAL RESTI

(Rekayasa Sistem dan Teknologi Informasi)

Vol. 6 No. x (2022) x - x

ISSN Media Elektronik:
2580-0760

Analisis Kinerja Algoritma CNN dan LSTM untuk Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia

*CNN and LSTM Algorithm Performance Analysis to Predict Water Level in DKI
Jakarta, Indonesia*

Ayu Wulandari¹, Vina Ayumi²

Teknik Informatika, Ilmu Komputer, Universitas Mercu Buana

¹41518010117@student.mercubuana.ac.id, ²vina.ayumi@mercubuana.ac.id

Abstract

Floods are the most frequent and extreme disasters that cause considerable losses to human life, such as loss of life, damage to infrastructure, socio-economic culture, hydrological and climatic properties strongly influenced by floods. Indonesia is a country that often experiences climate change. So it is not uncommon for floods to occur in various regions in Indonesia. High rainfall intensity and lack of water catchment areas cause flooding and increased river, stream or sea discharge. Therefore, we need a model to predict the water level for flood early warning. This study aims to predict water level using Convolutional Neural Network (CNN) and Long Short Term Memory (LSTM) algorithms on univariate time series data. Using CNN and LSTM algorithms to predict water levels will reduce casualties and other losses due to flooding. This study shows that LSTM gives better results than CNN for predicting water level data from all tests. The test results show that the LSTM model produces a MAPE value of 4.3015, while CNN obtains a MAPE value of 4.5897.

Keywords: Water Level, Time-Series Prediction, Convolutional Neural Network, Long Short-Term Memory, Deep Learning.

Abstrak

Banjir merupakan bencana yang paling sering terjadi dan ekstrim yang menyebabkan kerugian besar bagi kehidupan manusia, seperti kehilangan nyawa, kerusakan infrastruktur, sosial ekonomi budaya, fitur hidrologi dan iklim sangat dipengaruhi oleh banjir. Indonesia termasuk negara yang sering mengalami perubahan iklim. Sehingga tidak jarang terjadi pula bencana banjir di berbagai daerah di Indonesia. Intensitas curah hujan yang tinggi dan minimnya area resapan air merupakan salah satu masalah penyebab banjir yang dapat mengakibatkan debit aliran sungai, kali atau laut menjadi meningkat. Oleh karena itu dibutuhkan suatu metode yang bisa prediksi tinggi muka air, agar bisa memberikan peringatan dini bahaya banjir. Penelitian ini bertujuan untuk memprediksi tinggi muka air menggunakan algoritma Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM) dengan data deret waktu univariat. Dengan adanya penerapan algoritma CNN dan LSTM untuk memprediksi tinggi muka air, diharapkan dapat mengurangi korban jiwa dan kerugian lain yang disebabkan oleh banjir. Hasil penelitian ini menunjukkan bahwa dari seluruh pengujian diketahui bahwa, LSTM memberikan hasil yang lebih baik dibandingkan dengan CNN untuk memprediksi data tinggi muka air. Dibuktikan dari hasil pengujian akhir, didapat bahwa model LSTM menghasilkan nilai MAPE 4.3015, sedangkan CNN memperoleh nilai MAPE 4.5897.

Kata kunci: Tinggi Muka Air, Prediksi Deret Waktu, Convolutional Neural Network, Long Short-Term Memory, Deep Learning.

Universitas Mercu Buana

<http://digilib.mercubuana.ac.id/>

1. Pendahuluan

Bencana adalah salah satu ancaman utama bagi permukiman dalam beberapa dekade terakhir (Majelis Umum PBB, 39 2015). Frekuensi banjir meningkat selama abad ke-20. Menurut statistik yang disediakan oleh Perserikatan Bangsa-Bangsa, antara bencana alam, banjir dan badai telah menyebabkan paling banyak korban jiwa dan kerusakan pada masyarakat [1]. Banjir sendiri dianggap sebagai kondisi cuaca yang paling sering terjadi dan ekstrim yang menyebabkan kerugian besar bagi kehidupan manusia, seperti kehilangan nyawa, kerusakan infrastruktur, sosial ekonomi budaya, fitur hidrologi dan iklim sangat dipengaruhi oleh banjir [2]. Banjir hadir bahkan di negara maju seperti Australia, Jepang, dan Amerika Serikat, dan di negara berkembang seperti Indonesia, Pakistan, Kolombia, dan Bangladesh [3]. Wilayah dengan iklim yang berubah ke arah yang lebih ekstrim dan curah hujan yang lebih sering terjadi, kemungkinan besar mengalami kondisi banjir [1]. Indonesia berada di antara Samudera Hindia dan Samudera Pasifik dan dua benua, khususnya Asia dan Australia, sehingga iklim sering berubah dan dipengaruhi oleh banyak faktor. Fenomena lainnya, seperti El-Nino Southern Oscillation (ENSO), menambah kompleksitas lingkungan [4]. Berdasarkan hal tersebut perubahan iklim dapat memengaruhi banyak sistem bumi. Sehingga dapat menyebabkan bencana alam seperti banjir dan kekeringan. Indonesia termasuk negara yang sering mengalami perubahan iklim. Sehingga tidak jarang terjadi pula bencana banjir di berbagai daerah di Indonesia. Sesuai dengan Annual Global Climate dan Laporan Bencana yang juga menunjukkan bahwa dari tahun 2015, 2016 dan 2017 efek paling negatif terlihat pada tahun 2015 ketika banjir menyebabkan kerugian 27 triliun dolar di seluruh dunia [3].

Intensitas curah hujan yang tinggi dan kurangnya daerah resapan air merupakan salah satu faktor penyebab banjir yang dapat mengakibatkan debit aliran sungai, kali atau laut menjadi meningkat [2]. Besarnya debit aliran sungai menjadi penyebab tinggi muka air meningkat. Berbagai model digunakan dalam mengembangkan sistem prediksi banjir tingkat lanjut sebagai langkah untuk mengurangi risiko ini. Misalnya, pembuatan kebijakan, analisis ekonomi, pengelolaan sumber daya air, dan penanggulangan bencana nasional diperkuat dengan prediksi yang tepat dan akurat [2]. Berdasarkan hal tersebut, pengukuran tinggi muka air dibutuhkan untuk mengantisipasi banjir. Oleh karena itu, dibutuhkan sebuah metode yang

dapat prediksi tinggi muka air, agar bisa memberikan peringatan dini bahaya banjir.

Beberapa penelitian sebelumnya mengenai prediksi diantaranya yaitu Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM)[5], melakukan perbandingan dua model yaitu MLP dan LSTM untuk mendapatkan hasil prediksi terhadap data time series harga beras dengan akurasi terbaik, tingkat keakuratan tiap model diukur menggunakan RMSE. Penelitian tersebut menghasilkan bahwa model LSTM lebih unggul dan lebih akurat daripada MLP. Penelitian lainnya yaitu Context-based Hydrology Time Series Data for A Flood Prediction Model Using LSTM [6], melakukan perbandingan dua algoritma yaitu Long Short Term Memory dan Multiple Linear Regression terhadap data hidrologi time series untuk mengetahui presentasi error berdasarkan nilai MAPE dalam memprediksi banjir serta keakuratan model. Berdasarkan penelitian tersebut diketahui bahwa LSTM lebih akurat dalam memprediksi banjir dibandingkan dengan Multiple Linear Regression, dilihat dari hasil persentase error LSTM yang lebih rendah dibandingkan Multiple Linear Regression, dimana LSTM menghasilkan nilai MAPE sebesar 3,6% sedangkan Multiple Linear Regression sebesar 10,55%. Selanjutnya yaitu Prediksi Harga Emas Menggunakan Univariate Convolutional Neural Network [7], memprediksi data time series harga emas menggunakan pendekatan univariate CNN, penelitian ini menggunakan RSME untuk mempermudah dalam validasi. Tujuan dari prediksi ini untuk memperkecil kesalahan sehingga dapat meminimalkan selisih antara perkiraan dengan kejadian sebenarnya. Penelitian tersebut mendapatkan kinerja terbaik pada model 1 dimana eksperimen dense layer pada kondisi 5, dengan penyetelan hyperparameter model filter konvolusi sebesar 64, pooling layer 2, ukuran kernel 2, dense layer 50, dan jumlah epoch sebanyak 2000 serta dengan nilai RMSE sebesar 690,40.

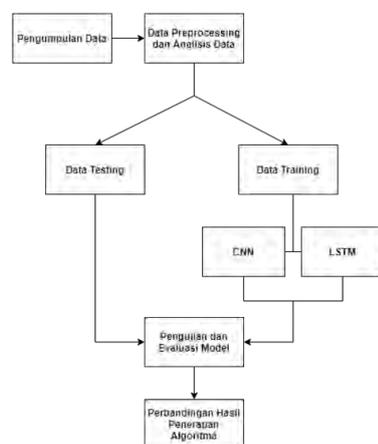
Penelitian ini bertujuan untuk memprediksi tinggi muka air menggunakan algoritma Convolutional Neural Network (CNN) dan Long Short Term Memory (LSTM) pada data deret waktu univariat. Univariate Convolutional Neural Network (CNN) dapat digunakan untuk memprediksi data time series, dalam kasus ini yaitu tinggi muka air [7]. Long Short Term Memory (LSTM) bersifat umum dan efektif dalam menangani dependensi temporal jangka panjang yang kompleks dan metode deep learning yang digunakan dalam melakukan

prediksi banjir berdasarkan data *time series* ketinggian air dan curah hujan[6]. Jenis data pada penelitian ini adalah data deret waktu univariat, dimana data tersebut berbentuk urutan berdasarkan waktu yang telah terjadi dan hanya memiliki satu variabel[7]. Sebuah prediksi sepenuhnya tidak dapat dipastikan, tetapi memiliki peluang dapat memberikan hasil prediksi yang mendekati hasil sebenarnya[7]. Dalam penelitian ini, selain penggunaan parameter dasar, diterapkan pula metode untuk meningkatkan kinerja model prediksi dengan hyperparameter tuning. Hyperparameter tuning atau penyetelan parameter merupakan variabel untuk menentukan bagaimana struktur model neural network dilatih, contohnya learning rate, batch size, epochs, jumlah hidden unit, activation function, dropout, filter konvolusi[6].

Dengan adanya penelitian ini, diharapkan implementasi algoritma CNN dan LSTM dalam memprediksi tinggi muka air, dapat digunakan sebagai pedoman untuk prediksi dini banjir dan memudahkan pemerintah provinsi DKI Jakarta dalam pengambilan keputusan untuk prediksi dini terjadinya bencana banjir di wilayah DKI Jakarta dalam rangka mengurangi korban jiwa dan kerugian lain yang disebabkan oleh banjir.

2. Metode Penelitian

Penelitian ini diawali dengan proses pengumpulan data, kemudian dilanjutkan pada tahap preprocessing data. Setelah tahap preprocessing, data dibagi menjadi data training dan testing. Selanjutnya masuk pada proses implementasi model CNN dan LSTM dan dilanjutkan dengan tahap pengujian serta evaluasi model. Tahap akhir adalah menganalisis perbandingan hasil penerapan algoritma yang telah diuji untuk diketahui performa dari masing-masing algoritma berdasarkan percobaan parameter yang dilakukan. Berikut merupakan desain dari tahapan penelitian yang dilakukan:



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Metode pengumpulan data dari penelitian ini yaitu dengan cara mengunduh dataset dari portal website Open Data Jakarta (<https://data.jakarta.go.id/>). Dataset ini yaitu Data TMA (Tinggi Muka Air) di DKI Jakarta Tahun 2020 yang dikelola oleh Dinas Sumber Daya Air DKI Jakarta. Data bersumber dari 13 lokasi penelitian dan 25 nama pintu air yang ada di wilayah DKI Jakarta. Data yang digunakan pada penelitian ini berupa data time series mengenai data TMA sungai/kali/laut yang ada di wilayah DKI Jakarta secara langsung (*real time*) dari 1 Januari 2020 – 31 Desember 2020. Jumlah data pada dataset ini yaitu sebanyak 323.493 data dan memiliki 7 atribut diantaranya nama pintu air, lokasi, latitude, longitude, tanggal, tinggi air, dan status siaga.

Tabel 1. Deskripsi Atribut Dataset

Atribut	Keterangan
nama pintu air	Nama pintu air untuk pengamatan
lokasi	Nama lokasi atau wilayah pengamatan contohnya: sungai, kali atau laut, dll
latitude	Garis lintang dari koordinat lokasi pengamatan
longitude	Garis bujur dari koordinat lokasi pengamatan
tanggal	Waktu pengukuran pengukuran yang berisi tanggal dan jam
tinggi air	Nilai tinggi air menggunakan satuan sentimeter (CM)
Status siaga	Status waspada berdasarkan nilai tinggi air

Tabel 2. Deskripsi Status Siaga

Atribut	Keterangan
Siaga I	Bencana
Siaga II	Kritis
Siaga III	Waspada
Siaga IV/Normal	Aman

2.2. Data Preprocessing dan Analisis Data

Data preprocessing merupakan sebuah proses yang berfungsi untuk mempersiapkan data mentah menjadi data yang dapat digunakan dalam membangun model pembelajaran computer[8]. Sebelumnya pada Tabel 1 telah dijelaskan atribut dan deskripsi data mentah sebelum dilakukan preprocessing. Untuk itu dilakukan pemilihan atribut yang akan dilakukan

prediksi, yaitu tanggal dan tinggi air (*univariate*)[9][10], [11]. Kolom tanggal adalah data waktu pengukuran dan tinggi_air adalah hasil pengukuran tinggi muka air dalam satuan sentimeter. Gambar 2 menunjukkan informasi statistik dari dataset yang meliputi nilai mean, standar deviasi, min, max, dan kuantil(25%, 50%, 75%)[12] dari tinggi muka air.

```
count    323493.000000
mean     1354.894882
std      1840.714311
min      -2650.000000
25%      400.000000
50%     1130.000000
75%     1900.000000
max     536650.000000
Name: tinggi_air, dtype: float64
```

Gambar 2. Deskripsi Statistik Data Tinggi Muka Air

Pada analisis time series, kualitas data memiliki pengaruh yang besar terhadap akurasi hasil prediksi[8], [12]. Berdasarkan karakteristik data tinggi muka air, maka dilakukan preprocessing yang meliputi:

Data Cleaning

Pada tahap ini dimaksudkan untuk membersihkan data dari kebisingan (noise) seperti duplikasi data, missing value, pencilan (outlier)[13]. Terdapat beberapa outlier pada data tinggi muka air yang kemungkinan disebabkan oleh kesalahan pengukuran, oleh karena itu dilakukan penghapusan pada outlier.

Data Resampling

Karena data yang digunakan tidak memiliki periode waktu interval yang sama maka dilakukan pengambilan sampel ulang (*resampling*) pada data tinggi muka air dengan mengambil rata – rata tinggi muka air per jam. Gambar 3 menunjukkan data sebelum *resampling* dan Gambar 4 menunjukkan data setelah *resampling*.

tanggal	tinggi_air
2020-01-01 00:10:00	470
2020-01-01 00:10:00	1670
2020-01-01 00:10:00	6390
2020-01-01 00:10:00	200
2020-01-01 00:10:00	3240

Gambar 3. Data Sebelum Resampling

tanggal	tinggi_air
2020-01-01 00:00:00	1557.41
2020-01-01 01:00:00	1391.71
2020-01-01 02:00:00	1527.30
2020-01-01 03:00:00	1847.35
2020-01-01 04:00:00	2088.48

Gambar 4. Data Sesudah Resampling

Normalisasi Data

Tahap selanjutnya yaitu menormalisasi data dengan mengkonversi data aktual ke nilai dengan rentang [0,1] menggunakan *Min-Max scaling*[13][5].

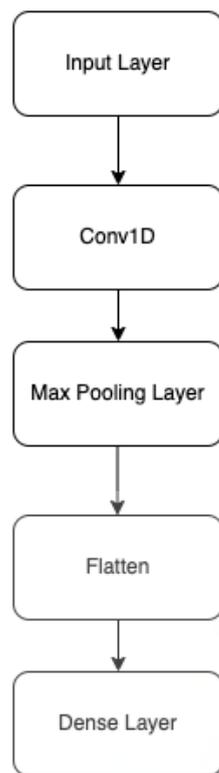
Pembagian Data

Dataset kemudian dibagi menjadi *train set* (data latih) dan *test set* (data uji)[14]. Dengan proporsi 80% *train set* dan 20% *train test*. Dari pembagian ini didapatkan data latih berjumlah 6945 data dan data uji berjumlah 1736 data.

2.3. Convolutional Neural Network (CNN)

CNN adalah algoritma yang dikembangkan dari Artificial Neural Network (ANN) dirancang untuk mengolah data dua dimensi[15]. Fitur berbeda dari CNN adalah penggunaan convolutional layer pada jaringan deep learning[16]. CNN menunjukkan kinerja yang baik dalam melakukan analisis yang sesuai dengan menggunakan convolutional layer 1D untuk data *time series* dalam satu dimensi[16]. CNN terdiri dari beberapa lapisan dimana strukturnya dirancang berdasarkan kasus. Lapisan pertama yang terlibat dalam CNN adalah lapisan konvolusi yang terdiri dari neuron dalam bentuk matriks filter. Pergeseran matriks filter akan direpresentasikan sebagai produk titik atau proses konvolusi antara input dan kernel dengan ukuran tertentu. Kemudian, proses akan menghasilkan output atau disebut peta aktivasi atau peta fitur. Lapisan (*layer*) adalah lapisan Rectified Linear Unit (ReLU) yang mengubah nilai negatif menjadi nol dan mempertahankan nilai positif. Layer ketiga adalah Pooling yang terdiri dari filter dengan ukuran dan stride tertentu. Pada pooling layer, operasi yang biasanya digunakan adalah operasi maksimum (max pooling) dan rata-rata (average pooling). Tujuan penggunaan pooling layer adalah untuk memperkecil dimensi dari peta fitur dan akibatnya meningkatkan kecepatan komputasi.

2.3.1 Implementasi CNN



Gambar 5. Arsitektur Model CNN

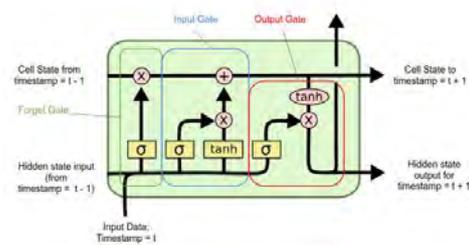
Adapun konfigurasi layer dari CNN yang akan digunakan pada eksperimen dalam penelitian ini terdiri dari layer konvolusi 1 dimensi, *max pooling layer*, dan *flatten layer* [14], [17]. Jumlah kernel diset sama dengan 1 karena prediksi yang dilakukan bersifat univariate (hanya 1 variabel masukkan). Konfigurasi parameter model ditunjukkan pada Tabel 3.

Tabel 3. Parameter CNN

Parameter	Nilai
<i>Filter convolutional layer</i>	64
<i>Kernel filter</i>	1
<i>Max Pooling layer size</i>	1
<i>Dense units</i>	1
<i>Learning rate</i>	0.01
<i>Optimizer</i>	Adam
<i>Loss function</i>	MSE
<i>Epochs</i>	100

2.4 Long Short Term Memory (LSTM)

LSTM adalah pengembangan dari arsitektur RNN [5], [13]. Hal yang membedakan LSTM dan RNN adalah LSTM dapat memilih informasi yang harus dibuang dan informasi yang akan tetap disimpan dalam *memory cell* [5], [18][19].



Gambar 6. Arsitektur LSTM

Secara umum LSTM memiliki empat proses pada setiap neuron. Proses pertama yaitu memilih informasi yang tidak berguna, dimana *forget gate* merupakan *sigmoid function* yang akan membaca nilai 0 dengan arti menunjukkan elemen yang harus dibuang atau nilai 1 yang menunjukkan bahwa informasi akan tetap disimpan. Proses selanjutnya, terdapat *input gate* sebagai gerbang yang menentukan informasi akan diperbarui kemudian *activation function tanh* akan membuat vector baru [6]. Kemudian *memory cell* akan memperbarui vector, yang kemudian dilanjutkan dengan proses terakhir yaitu *output gate* akan menerima bagian – bagian dari *memory cell* yang akan menjadi output.

2.4.1 Implementasi LSTM

Tahap perancangan model LSTM dilakukan setelah data preprocessing. Kemudian data dibagi menjadi *dataset* latih dan *dataset* uji, setelah itu dilakukan normalisasi menggunakan Min Max dengan range (0,1). Agar bisa diproses pada sel LSTM, data di reshape (menggunakan numpy) menjadi array tiga dimensi. Dilanjutkan dengan inisialisasi parameter dasar model yang digunakan untuk melatih model yang disajikan pada Tabel 4 dibawah [17].

Tabel 4. Parameter LSTM

Parameter	Nilai
<i>Hidden unit LSTM</i>	64
<i>Dense Layer</i>	1
<i>Learning rate</i>	0.01
<i>Optimizer</i>	Adam
<i>Loss function</i>	MSE
<i>Epochs</i>	100

2.5 Evaluasi Model

Untuk evaluasi kinerja model pada penelitian ini menggunakan Mean Percentage Error (MAPE).

MAPE adalah metode evaluasi yang menghitung rata – rata diferensiasi absolut antara nilai yang prediksi dan actual yang dinyatakan dalam bentuk persentase nilai aktual [13]. Pada prinsipnya, MAPE [20] berfungsi untuk menghitung persentase kesalahan antara nilai

prediksi dan nilai actual. Pada persamaan 1 adalah rumus untuk MAPE.

$$MAPE = \sqrt{\frac{1}{n} \sum_i^n (y_i - \hat{y}_i)^2} \quad (1)$$

Variabel y_i = Nilai aktual tinggi muka air, \hat{y}_i = Nilai hasil prediksi tinggi muka air dan n = Jumlah data[20].

3. Hasil dan Pembahasan

Eksperimen yang dilakukan pada penelitian ini didasarkan pada komposisi data training 80% (6945 baris) dan 20% data testing (1736 baris). Skenario pengujian yang dilakukan yaitu menggunakan parameter dasar dan parameter tuning dengan mengubah beberapa parameter seperti epochs, batch size, learning rate, jumlah neuron pada hidden layer LSTM dan jumlah filter konvolusi pada layer CNN.

3.1. Convolutional Neural Network (CNN)

Skenario pengujian pertama yaitu melakukan pengaturan pada epochs dan batch size. Hasil dari eksperimen dengan pengaturan epochs dan batch size ditunjukkan pada Tabel 5. Dari seluruh eksperimen pada pengaturan epochs dan batch size memberikan hasil MAPE terbaik dengan nilai terendah sebesar 4.3398 pada epochs 100, batch size 128 sedangkan hasil MAPE dengan nilai tertinggi didapat pada epochs 200 dan batch size 128 sebesar 5.1023. Berdasarkan penelitian ini, membuktikan bahwa CNN dengan epochs yang lebih kecil dan batch size yang tinggi dapat bekerja dengan baik dalam memprediksi tinggi muka air.

Tabel 5. Hasil Kinerja CNN dengan Kombinasi Epochs dan Batch Size

Batch Size	Epochs = 100	Epochs = 150	Epochs = 200
32	4.4619	4.4494	4.7649
64	4.4570	4.3465	4.4886
128	4.3398	4.4057	5.1023

Eksperimen selanjutnya yaitu, mengatur learning rate yang ditunjukkan pada Tabel 6. Hasil terbaik pada pengujian diperoleh pada learning rate 0.001, menghasilkan nilai MAPE yang lebih kecil dibandingkan learning rate lainnya dengan menggunakan batch size 128 dan epochs 100. Nilai MAPE yang dihasilkan yaitu 4.3403. Dengan menggunakan kecepatan pembelajaran yang tidak terlalu cepat ataupun lambat pada penelitian ini, terbukti dapat meningkatkan kinerja prediksi dari algoritma CNN.

Tabel 6. Hasil Kinerja CNN dengan Learning Rate Tuning

Learning Rate	Training	Testing
0.01	3.0677	4.3807
0.001	3.0465	4.3403
0.0001	3.0291	4.4863

Berdasarkan Tabel 7, menunjukkan hasil bahwa model CNN dengan jumlah filter konvolusi = 256, menghasilkan nilai MAPE yang lebih kecil pada saat pengujian dibandingkan dengan jumlah filter yang lain yaitu sebesar 4.3838. Pada penelitian ini, dengan jumlah filter konvolusi dengan nilai yang cukup besar, dapat meningkatkan kinerja dari CNN. Tidak ada aturan pasti dalam menentukan jumlah filter konvolusi, oleh karena itu dilakukan beberapa eksperimen dalam menentukan filter konvolusi paling optimal.

Tabel 7. Hasil Kinerja CNN dengan Kombinasi Jumlah Filter Konvolusi

Filter Konvolusi	Training	Testing
64	2.9599	4.4084
128	2.9571	4.3965
256	2.9568	4.3838

Pada tahap selanjutnya kami melakukan pengujian model CNN untuk prediksi tinggi muka air berdasarkan beberapa eksperimen yang sebelumnya telah dilakukan. Pada tahap ini kami menguji model CNN dengan menerapkan parameter dasar yang ditunjukkan pada Tabel 3 dan juga kami menguji semua pengaturan parameter yang memiliki hasil kinerja terbaik dari seluruh eksperimen. Dimana komposisi parameter terbaik ada pada epochs = 100, batch_size = 128, learning_rate = 0.001, filter = 256.

Dari hasil pengujian yang dilakukan dengan menggunakan parameter dasar untuk memprediksi tinggi muka air, menghasilkan nilai MAPE 4.9139 dengan waktu komputasi 42.152 detik. Sedangkan pengujian Ketika menggunakan parameter tuning menghasilkan nilai MAPE 4.5897 dengan waktu komputasi 18.444 detik. Dari nilai MAPE yang dihasilkan, terbukti parameter tuning dapat meningkatkan nilai MAPE sebesar 0.3242. Hal ini membuktikan, bahwa dengan menyetel beberapa parameter dapat mempengaruhi performa dan waktu komputasi dari CNN. Pada Gambar 7, menunjukkan visualisasi dari hasil prediksi dengan data aktual tinggi muka air menggunakan model CNN. Berdasarkan grafik visualisasi CNN mampu memprediksi data tinggi muka air dengan cukup baik.



Gambar 7. Visualisasi Hasil Prediksi Model CNN

tanggal	tinggi_air	Difference	Difference	Predictions
2020-10-19 12:00:00	1500.000000	-153.919312	153.919312	1346.080688
2020-10-19 13:00:00	1100.000000	324.913086	-324.913086	1424.913086
2020-10-19 14:00:00	1487.222222	-267.390557	267.390557	1219.831665
2020-10-19 15:00:00	812.500000	549.152832	-549.152832	1361.652832
2020-10-19 17:00:00	1889.677419	-659.168630	659.168630	1030.508789
...
2020-12-30 20:00:00	950.645161	152.280620	-152.280620	1102.925781
2020-12-30 21:00:00	1101.875000	-83.528625	83.528625	1018.346375
2020-12-30 22:00:00	1024.687500	48.676636	-48.676636	1073.364136
2020-12-30 23:00:00	1028.125000	27.085571	-27.085571	1055.210571
2020-12-31 00:00:00	1370.000000	-322.090210	322.090210	1047.909790

1736 rows x 5 columns

Gambar 8. Hasil Prediksi dan Data Aktual Model CNN

3.2. Long Short Term Memory (LSTM)

Berdasarkan Tabel 8, hasil skenario pengujian dengan mengatur epochs dan batch size. Dari seluruh eksperimen pada pengaturan epochs dan batch size memberikan hasil MAPE terbaik dengan nilai terendah sebesar 4.1818 pada epochs 100, batch size 64 sedangkan hasil MAPE dengan nilai tertinggi didapat pada epochs 150 dan batch size 32 sebesar 4.8799. Berdasarkan penelitian ini, membuktikan dengan epochs kecil dan batch size yang tidak terlalu besar merupakan kombinasi terbaik yang dapat meningkatkan kinerja LSTM dalam memprediksi data tinggi muka air.

Tabel 8. Hasil Kinerja LSTM dengan Kombinasi Epochs dan Batch Size

Batch Size	Epochs = 100	Epochs = 150	Epochs = 200
32	4.6077	4.8799	4.4691
64	4.1818	4.4023	4.7014
128	4.5349	4.4720	4.7683

Eksperimen selanjutnya yaitu, mengatur learning rate yang ditunjukkan pada Tabel 9. Hasil terbaik pada pengujian diperoleh pada learning rate 0.01, menghasilkan nilai MAPE yang lebih kecil dibandingkan learning rate lainnya dengan menggunakan batch size 64 dan epochs 100. Nilai MAPE yang dihasilkan yaitu 4.3248. Penerapan learning rate 0.01 pada penelitian ini, membuktikan bahwa LSTM dapat belajar dengan optimal dalam memprediksi tinggi muka air.

Tabel 9. Hasil Kinerja LSTM dengan Learning Rate Tuning

Learning Rate	Training	Testing
0.01	2.9826	4.3248
0.001	3.1854	4.6385
0.0001	3.2477	4.9366

Dapat dilihat hasil kinerja LSTM pada Tabel 10, bahwa LSTM memperoleh nilai MAPE sebesar 4.1832, dengan jumlah [14] hidden units LSTM = 64. Pada prediksi data tinggi muka air dengan jumlah neuron yang tidak terlalu besar pada penelitian ini, terbukti LSTM memberikan kinerja yang baik.

Tabel 10. Hasil Kinerja LSTM dengan Kombinasi Jumlah Neurons Hidden Units

Neuron	Training	Testing
64	2.9242	4.1832
128	2.7947	4.3396
256	2.8106	4.2599

Pada tahap selanjutnya kami melakukan pengujian model LSTM untuk prediksi tinggi muka air berdasarkan beberapa eksperimen yang sebelumnya telah dilakukan. Pada tahap ini kami menguji model LSTM dengan menerapkan parameter dasar yang ditunjukkan pada Tabel 4 dan juga kami menguji semua pengaturan parameter yang memiliki hasil kinerja terbaik dari seluruh eksperimen. Dimana komposisi parameter terbaik ada pada epochs = 100, batch_size = 64, learning_rate = 0.01, neurons hidden layer LSTM = 64.

Dari hasil pengujian yang dilakukan dengan menggunakan parameter dasar untuk memprediksi tinggi muka air, menghasilkan nilai MAPE 4.3551 dengan waktu komputasi 110.63 detik. Sedangkan pengujian Ketika menggunakan parameter tuning menghasilkan nilai MAPE 4.3015 dengan waktu komputasi 51.976 detik. Dari nilai MAPE yang dihasilkan, terbukti parameter tuning dapat meningkatkan nilai MAPE sebesar 0.0536. Hal ini membuktikan, bahwa dengan menyetel beberapa parameter dapat mempengaruhi performa dan waktu komputasi dari LSTM. Pada Gambar 9, menunjukkan visualisasi dari hasil prediksi dengan data aktual tinggi muka air menggunakan model LSTM. Berdasarkan visualisasi prediksi tinggi muka air menggunakan data uji, LSTM mampu memprediksi dengan baik.



Gambar 9. Visualisasi Hasil Prediksi Model LSTM

tanggal	tinggi_air	Difference	Difference	Predictions
2020-10-19 12:00:00	1500.000000	-134.567261	134.567261	1365.432739
2020-10-19 13:00:00	1100.000000	363.793335	-363.793335	1463.793335
2020-10-19 14:00:00	1487.222222	-214.279473	214.279473	1272.942749
2020-10-19 15:00:00	812.500000	568.516724	-568.516724	1381.016724
2020-10-19 17:00:00	1689.677419	-404.144094	404.144094	1285.533325
...
2020-12-30 20:00:00	950.645161	175.647319	-175.647319	1126.292480
2020-12-30 21:00:00	1101.875000	-58.667725	58.667725	1043.207275
2020-12-30 22:00:00	1024.687500	82.783325	-82.783325	1107.470825
2020-12-30 23:00:00	1028.125000	57.273315	-57.273315	1085.398315
2020-12-31 00:00:00	1370.000000	-302.438110	302.438110	1067.561890

1736 rows x 5 columns

Gambar 10. Hasil Prediksi Data Aktual Model LSTM

3.3. Perbandingan Hasil Pengujian

Tabel 11. Hasil Perbandingan Non Hyperparameter Tuning

Model	MAPE	Time Execution
CNN	4.9139	42.152s
LSTM	4.3551	110.63s

Tabel 12. Hasil Perbandingan Hyperparameter Tuning

Model	MAPE	Time Execution
CNN	4.5897	18.444s
LSTM	4.3015	51.976s

Berdasarkan nilai MAPE yang ditampilkan pada Tabel 12, model LSTM menunjukkan hasil yang lebih baik dari model CNN. Model LSTM menghasilkan nilai MAPE 4.3015. Sedangkan model CNN memperoleh nilai MAPE 4.5897. Pada model LSTM terdapat peningkatan sebesar 0.0536 setelah dilakukan *hyperparameter tuning*. Lalu pada model CNN terdapat peningkatan sebesar 0.3242 setelah dilakukan *hyperparameter tuning*. Meskipun LSTM lebih baik dari model CNN, tetapi perbedaannya tidak terlalu signifikan dibuktikan dengan selisih nilai MAPE yang hanya sebesar 0.2882, dimana LSTM lebih unggul. Model LSTM lebih unggul dikarenakan memiliki arsitektur memory cell untuk mempelajari informasi jangka panjang pada data[6]. Dimana mampu mengingat informasi untuk periode yang lebih lama sehingga cocok untuk prediksi data time series[5]. Sedangkan CNN, memiliki kelemahan dalam menentukan skala ekstraksi fitur, yang mana masih menjadi tantangan dalam pemilihan hyper parameter[17]. Grafik perbandingan hasil pengujian Model CNN dan LSTM menggunakan

non hyperparameter tuning yang ditunjukkan pada Gambar 11, dan grafik untuk membandingkan hasil pengujian model CNN dan LSTM menggunakan *hyperparameter tuning* yang disajikan pada Gambar 12.



Gambar 11. Perbandingan Hasil Pengujian Model Non Hyperparameter Tuning



Gambar 12. Perbandingan Hasil Pengujian Model Hyperparameter Tuning

4. Kesimpulan

Berdasarkan hasil analisis dan pengujian dari semua percobaan pada penelitian ini untuk mendapatkan model yang sesuai dalam memprediksi tinggi muka air. Dimana skenario pengujian yang dilakukan yaitu dengan membandingkan parameter dasar dan parameter tuning dengan mengubah beberapa parameter seperti epochs, batch size, learning rate, jumlah neuron pada hidden layer LSTM dan jumlah filter konvolusi pada layer CNN. Dari hasil pengujian, menunjukkan bahwa CNN dan LSTM memberikan kinerja yang hampir sama. Pada pengujian menggunakan parameter dasar, model CNN memperoleh nilai MAPE sebesar 4.9139 dengan waktu komputasi 42.152 detik, sedangkan model LSTM memperoleh nilai MAPE sebesar 4.3551 dengan waktu komputasi 110.63 detik. Pada pengujian parameter tuning nilai MAPE untuk LSTM sebesar 4.3015 dan CNN sebesar 4.5897, hal ini membuktikan parameter tuning dapat mempengaruhi dan meningkatkan akurasi dari algoritma. Tetapi dalam eksperimen pada setiap parameter yang

dilakukan, hasil yang didapatkan selalu berubah-ubah, karena masing-masing parameter dapat mempengaruhi kinerja dari algoritma. Selain itu model LSTM akan lebih efektif dalam memprediksi jika menggunakan hanya satu fitur input saja (tunggal), sedangkan CNN lebih efektif jika menggunakan lebih dari satu fitur input. Berdasarkan penelitian ini waktu komputasi model CNN lebih cepat daripada LSTM dikarenakan arsitektur CNN yang lebih sederhana dibandingkan dengan LSTM. Dapat disimpulkan dari penelitian ini, bahwa dengan karakteristik data *time series univariate* yang bersifat stasioner atau tidak memiliki tren tertentu, model CNN dan LSTM dapat dijadikan sebagai alternatif untuk memprediksi tinggi muka air dan model prediksi *realtime* dalam peringatan dini banjir dengan menentukan status siaga melalui proses klasifikasi berdasarkan standar yang ditetapkan oleh pemerintah DKI Jakarta. Kedepannya, percobaan pada setiap parameter harus lebih banyak dilakukan, agar mendapatkan parameter yang optimal. Selanjutnya, dapat juga mengimplementasikan metode lain selain hyperparameter tuning dalam meningkatkan kinerja algoritma misalnya dengan menerapkan metode feature selection dan ensemble learning.

Daftar Rujukan

- [1] M. Avand, H. Moradi, and M. R. lasboyee, "Using machine learning models, remote sensing, and GIS to investigate the effects of changing climates and land uses on flood probability," *Journal of Hydrology*, vol. 595, p. 125663, 2021, doi: 10.1016/j.jhydrol.2020.125663.
- [2] W. A. M. Prabuddhi and B. L. D. Seneviratne, "Long short term memory modelling approach for flood prediction: An application in deduru oya basin of Sri Lanka," *20th International Conference on Advances in ICT for Emerging Regions, ICTer 2020 - Proceedings*, no. ICTer, pp. 226–231, 2020, doi: 10.1109/ICTer51097.2020.9325438.
- [3] J. M. Moreno, J. M. Sánchez, and H. E. Espitia, "Use of computational intelligence techniques to predict flooding in places adjacent to the Magdalena River," *Heliyon*, vol. 6, no. 9, p. e04872, 2020, doi: 10.1016/j.heliyon.2020.e04872.
- [4] M. A. Priatna and E. C. Djamal, "Precipitation prediction using recurrent neural networks and long short-term memory," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 18, no. 5, pp. 2525–2532, 2020, doi: 10.12928/TELKOMNIKA.V18I5.14887.
- [5] S. Sen, D. Sugianto, and A. Rochman, "Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras," *ULTIMATICS*, vol. XII, no. 1, p. 35, 2020.
- [6] I. R. Widiyari, L. Edi Nugoho, and R. Efendi, "Context-based Hydrology Time Series Data for A Flood Prediction Model Using LSTM," in *Proceedings - 2018 5th International Conference on Information Technology*, 2018, pp. 385–390. doi: 10.1109/ICITACEE.2018.8576900.
- [7] I. Halimi, G. I. Marthasari, and Y. Azhar, "Prediksi Harga Emas Menggunakan Univariate Convolutional Neural Network," *Jurnal Repositor*, vol. 1, no. 2, p. 105, 2019, doi: 10.22219/repositor.v1i2.612.
- [8] A. Cahyaningsih, N. Prasetya Putra, A. Pradika Ekoputro Pratama, and R. Ramadhani, "Model Prediksi Jumlah Kumulatif Kasus COVID-19 di Indonesia Menggunakan Metode Neural Network," *Journal of Informatics, Information System, Software Engineering and Applications*, vol. 3, no. 1, pp. 76–83, 2020, doi: 10.20895/INISTA.V2I2.
- [9] I. Halimi, Y. Azhar, and G. I. Marthasari, "Prediksi Harga Emas Menggunakan Univariate Convolutional Neural Network," vol. 1, no. 2, pp. 105–116, 2019.
- [10] A. Satyo and B. Karno, "Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python," *ULTIMA InfoSys*, vol. XI, no. 1, 2020, [Online]. Available: <https://finance.yahoo.com>
- [11] F. M. Khan and R. Gupta, "ARIMA and NAR based prediction model for time series analysis of COVID-19 cases in India," *Journal of Safety Science and Resilience*, vol. 1, no. 1, pp. 12–18, Sep. 2020, doi: 10.1016/j.jnlssr.2020.06.007.
- [12] M. Pan *et al.*, "Water Level Prediction Model Based on GRU and CNN," *IEEE Access*, vol. 8, pp. 60090–60100, 2020, doi: 10.1109/ACCESS.2020.2982433.
- [13] E. S. Putri and M. Sadikin, "Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA," 1165.
- [14] C. N. Ihsan, "Klasifikasi Data Radar Menggunakan Algoritma Convolutional Neural Network (CNN)," *DoubleClick: Journal of Computer and Information Technology*, vol. 4, no. 2, pp. 115–121, Feb. 2021.
- [15] N. Kimura, I. Yoshinaga, K. Sekijima, I. Azechi, and D. Baba, "Convolutional neural network coupled with a transfer-learning approach for time-series flood predictions," *Water (Switzerland)*, vol. 12, no. 1, Jan. 2020, doi: 10.3390/w12010096.
- [16] K. Lee, C. Choi, D. H. Shin, and H. S. Kim, "Prediction of heavy rain damage using deep learning," *Water (Switzerland)*, vol. 12, no. 7, Jul. 2020, doi: 10.3390/w12071942.
- [17] H. Widiputra, Adele Mailangkay, and Elliana Gautama, "Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 3, pp. 456–465, Jun. 2021, doi: 10.29207/resti.v5i3.3111.
- [18] M. Q. Andiyantama, I. Zahira, and A. Irawan, "Prediksi Energi Listrik Kincir Angin Berdasarkan Data Kecepatan Angin Menggunakan LSTM," *JITCE (Journal of Information Technology and Computer Engineering)*, vol. 5, no. 01, pp. 1–7, Mar. 2021, doi: 10.25077/jitce.5.01.1-7.2021.
- [19] W. A. M. Prabuddhi and B. L. D. Seneviratne, "Long short term memory modelling approach for flood prediction: An application in deduru oya basin of Sri Lanka," in *20th International Conference on Advances in ICT for Emerging Regions, ICTer 2020 - Proceedings*, Nov. 2020, pp. 226–231. doi: 10.1109/ICTer51097.2020.9325438.
- [20] G. Najla, A. #1, and D. Fitriana, "Penerapan Metode Regresi Linear Untuk Prediksi Penjualan Properti pada PT XYZ," *Jurnal Telematika*, vol. 14, no. 2.
- [21] N. O. Syamsiah and I. Purwandani, "Penerapan Neural Network untuk Peramalan Data Time Series Univariate Jumlah Wisatawan Mancanegara," *Jurnal Mantik Penusa*, vol. 3, no. 3, pp. 100–106, 2019.

KERTAS KERJA

Ringkasan

Kertas kerja ini berisi tentang kelengkapan material dari artikel jurnal dengan judul “Analisis Kinerja Algoritma CNN dan LSTM untuk Memprediksi Tinggi Muka Air di DKI Jakarta, Indonesia”. Seluruh hasil penelitian Tugas Akhir yang tidak dimasukkan kedalam artikel jurnal. Pada kertas kerja ini disajikan: *literatur review*, analisis perancangan, *source code*, dataset yang digunakan, tahapan eksperimen dan seluruh hasil eksperimen.

- Bagian 1: *Literature Review* menjabarkan mengenai beberapa jurnal yang terkait dengan penelitian.
- Bagian 2: Analisis dan Perancangan menjabarkan analisis masalah dan analisis model.
- Bagian 3: *Source Code* menjabarkan kumpulan kode di setiap prosesnya mulai dari Membaca data, *Preprocessing*, Implementasi model, sampai pengujian dan evaluasi.
- Bagian 4: *Dataset* melampirkan pengambilan dataset.
- Bagian 5: Tahapan eksperimen berisi pengumpulan data, *Preprocessing*, Implementasi model, dan evaluasi model.
- Bagian 6: Hasil implementasi eksperimen secara keseluruhan yang mencakup jawaban dari skenario percobaan pengujian yang sudah disebutkan pada bagian 5. Bagian ini berguna untuk menemukan model prediksi terbaik yang dilihat dari beberapa pengujian berdasarkan nilai MAPE. Kemudian, hasil yang didapat digunakan sebagai pemodelan visualisasi tinggi muka air untuk bahan evaluasi atas kebijakan yang diterapkan.