

**IMPLEMENTASI JARINGAN SYARAF TIRUAN TEMPORAL  
CONVOLUTIONAL NETWORK (TCNs) UNTUK  
PERANCANGAN SISTEM PREDIKSI  
HARGA SAHAM BERBASIS WEB**

**SKRIPSI**

**DISUSUN OLEH**

**IRTANTI KARMINA CARONA**

**NPM. 2209020066**



**UMSU**

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI  
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI  
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

**MEDAN**

**2026**

**IMPLEMENTASI JARINGAN SYARAF TIRUAN TEMPORAL  
CONVOLUTIONAL NETWORK (TCNs) UNTUK  
PERANCANGAN SISTEM PREDIKSI  
HARGA SAHAM BERBASIS WEB**

**SKRIPSI**

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer  
(S.Kom) dalam Program Studi Teknologi Informasi pada Fakultas Ilmu  
Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

**IRTANTI KARMINA CARONA**

**NPM. 2209020066**

**PROGRAM STUDI TEKNOLOGI INFORMASI  
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI  
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

**MEDAN**

**2026**

**LEMBAR PENGESAHAN**

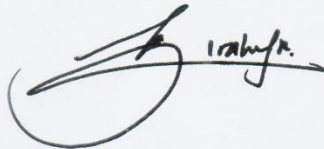
Judul Skripsi : **IMPLEMENTASI JARINGAN SYARAF TIRUAN  
TEMPORAL CONVOLUTIONAL NETWORK  
(TCNs) UNTUK PERANCANGAN SISTEM  
PREDIKSI HARGA SAHAM BERBASIS WEB**

Nama Mahasiswa : IRTANTI KARMINA CARONA

NPM : 2209020066

Program Studi : TEKNOLOGI INFORMASI

Menyetujui  
Komisi Pembimbing



**(Dr. Firahmi Rizky, S. Kom., M. Kom)**  
NIDN. 0116079201

**Ketua Program Studi**



**(Fatma Sari Hutagalung, M. Kom)**  
NIDN. 0117019301

**Dekan**



**(Assoc. Prof. Dr. Al-Khowarizmi, S.Kom., M.Kom.)**  
NIDN. 0127099201

**PERNYATAAN ORISINALITAS**

**IMPLEMENTASI JARINGAN SYARAF TIRUAN TEMPORAL  
CONVOLUTIONAL NETWORK (TCNs) UNTUK  
PERANCANGAN SISTEM PREDIKSI  
HARGA SAHAM BERBASIS WEB**

**SKRIPSI**

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, April 2026

Yang membuat pernyataan



Irtanti Karmina Carona

NPM. 2209020066

**KARYA ILMIAH UNTUK KEPENTINGAN  
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Irtanti Karmina Carona  
NPM : 2209020066  
Program Studi : Teknologi Informasi  
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksektif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

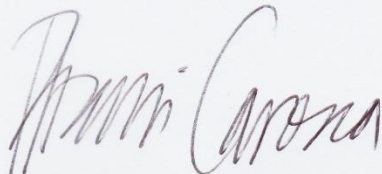
**IMPLEMENTASI JARINGAN SYARAF TIRUAN TEMPORAL  
CONVOLUTIONAL NETWORK (TCNs) UNTUK  
PERANCANGAN SISTEM PREDIKSI  
HARGA SAHAM BERBASIS WEB**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksektif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, April 2026

Yang membuat pernyataan



Irtanti Karmina Carona

NPM. 2209020066

## RIWAYAT HIDUP

### DATA PRIBADI

Nama Lengkap : Irtanti Karmina Carona  
Tempat dan Tanggal Lahir : Medan, 14 April 2004  
Alamat Rumah : Jl. Ir. H. Juanda LK IV No. 17  
Telepon/Faks/HP : 089636692578  
E-mail : [irtanticarona@gmail.com](mailto:irtanticarona@gmail.com)  
Instansi Tempat Kerja : -  
Alamat Kantor : -

### DATA PENDIDIKAN

SD : SD Kemala Bhayangkari 1 Medan TAMAT: 2012  
SMP : SMP Harapan 2 Medan TAMAT: 2018  
SMA : SMA Kemala Bhayangkari 1 Medan TAMAT: 2022

## KATA PENGANTAR



Assalamua'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah puji syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, serta nikmat kesehatan dan kesempatan yang telah diberikan, sehingga penulis dapat menyelesaikan penyusunan skripsi ini yang berjudul “Implementasi Jaringan Syaraf Tiruan Temporal Convolutional Network (TCNs) Untuk Perancangan Sistem Prediksi Harga Saham Berbasis Web” sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara. Penulis menyadari bahwa keberhasilan dalam penyusunan skripsi ini tidak terlepas dari dukungan dan bantuan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

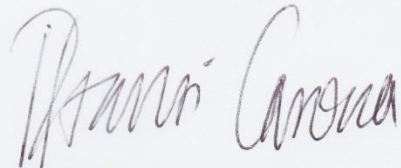
1. Bapak Prof. Dr. Akrim, M. Pd Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Assoc. Prof. Dr. Al-Khowarizmi, M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firahmi Rizky, S. Kom., M. Kom selaku Pembimbing skripsi Saya sekaligus Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
4. Bapak Muhammad Basri, S.Kom., M.Kom., selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
5. Ibu Fatma Sari Hutagaulung, M.Kom., selaku Ketua Program Studi Teknologi Informasi.
6. Bapak Okvi Nugroho, S. Kom., M. Kom., selaku Sekretaris Program Studi Teknologi Informasi.
7. Bapak Andi Zulherry, S. Kom., M. Kom selaku dosen pembimbing akademik.

8. Orang tua penulis, Ibu Bertha Witha Sitepu S. H., MARS dan Irfan yang telah merawat dan membersarkan penulis dari kecil hingga saat ini.
9. Teman penulis dengan NPM 2205160253 yang telah hadir dan berperan penting dalam proses penyusunan skripsi ini.
10. Bapak dan Ibu Dosen dan Pegawai Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU

Penulis menyadari bahwa dalam penyusunan laporan ini masih terdapat banyak kekurangan dan jauh dari kata sempurna. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun guna menjadi pensemperna skripsi ini.

Medan, Maret 2026

Penulis



Irtanti Karmina Carona

2209020066

# IMPLEMENTASI JARINGAN SYARAF TIRUAN TEMPORAL CONVOLUTIONAL NETWORK (TCNs) UNTUK PERANCANGAN SISTEM PREDIKSI HARGA SAHAM BERBASIS WEB

## ABSTRAK

Penelitian ini bertujuan untuk membangun sistem prediksi harga saham menggunakan pendekatan deep learning berbasis Temporal Convolutional Network (TCN) dengan memanfaatkan data historis harian saham periode 2018–2025 yang diperoleh melalui Yahoo Finance. Variabel yang digunakan dalam sistem hanya variabel harga penutupan (Close). Tahapan penelitian meliputi exploratory data analysis (EDA), preprocessing data, pelatihan model, evaluasi hasil prediksi, dan visualisasi hasil prediksi. Model TCN digunakan untuk melakukan prediksi satu langkah ke depan (*one-step ahead forecasting*), dan kinerjanya dievaluasi menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model mampu menangkap pola temporal pergerakan harga saham dan menghasilkan prediksi yang mendekati nilai aktual, sehingga sistem yang dikembangkan dapat menjadi alat bantu analisis dalam memahami dinamika harga saham.

Kata Kunci: Prediksi Harga Saham, Temporal Convolutional Network, Time Series Forecasting, Deep Learning, One-Step Ahead Prediction.

# IMPLEMENTATION OF TEMPORAL CONVOLUTIONAL NETWORK (TCNs) FOR THE DESIGN OF A WEB-BASED STOCK PREDICTION SYSTEM

## ABSTRACT

This study aims to develop a stock price prediction system using a deep learning approach based on the Temporal Convolutional Network (TCN) by utilizing daily historical stock price data from 2018 to 2025 obtained through Yahoo Finance. The system employs only the closing price (Close) variable as the input feature. The research stages include exploratory data analysis (EDA), data pre-processing, model training, prediction performance evaluation, and visualization of the prediction results. The TCN model is implemented to perform one-step ahead forecasting, and its performance is evaluated using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the proposed model can capture the temporal patterns of stock price movements and generating predictions that closely approximate the actual values. Therefore, the developed system can serve as a decision-support tool for analysing stock price dynamics.

Keywords: Stock Price Forecasting, Temporal Convolutional Network, Time Series Forecasting, Deep Learning, One-Step Ahead Prediction.

## DAFTAR ISI

<b>LEMBAR PENGESAHAN</b> .....	<b>i</b>
<b>PERNYATAAN ORISINALITAS</b> .....	<b>ii</b>
<b>PERNYATAAN PERSETUJUAN PUBLIKASI</b> .....	<b>iii</b>
<b>RIWAYAT HIDUP</b> .....	<b>iv</b>
<b>KATA PENGANTAR</b> .....	<b>v</b>
<b>ABSTRAK</b> .....	<b>vi</b>
<b>ABSTRACT</b> .....	<b>vii</b>
<b>DAFTAR ISI</b> .....	<b>ix</b>
<b>DAFTAR TABEL</b> .....	<b>xi</b>
<b>DAFTARGAMBAR</b> .....	<b>xii</b>
<b>BAB I. PENDAHULUAN</b> .....	<b>1</b>
1.1. Latar Belakang Masalah .....	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Masalah .....	5
1.4. Tujuan Penelitian .....	5
1.5. Manfaat Penelitian .....	6
<b>BAB II. LANDASAN TEORI</b> .....	<b>7</b>
2.1. Artificial Intelligence.....	7
2.1.1. Machine Learning .....	8
2.1.2. Artificial Neural Network .....	11
2.1.3. Deep Learning .....	13
2.2. Saham .....	14
2.3. Analisis Saham .....	14
2.4. Machine Learning Dalam Forecasting Harga Saham .....	15
2.5. Temporal Convolutional Network (TCN) .....	17
2.5.1. Causal Convolutional .....	17
2.5.2. Dilated Convolutional .....	17
2.5.3. Residual Connection .....	20
2.5.4. Activation Function, Normalization, dan Regularization .....	21
2.5.5. Arsitektur Akhir Temporal Convolutional Network.....	22
2.5.6. Perbandingan TCN Dengan RNN Dan LSTM .....	23
2.5.6.1 Kecepatan Pelatihan dan Parallelism .....	23
2.5.6.2 Kemampuan Menangkap Dependensi Jangka Panjang	24
2.5.6.3 Fleksibilitas Input .....	25
2.6. <i>Unified Modelling Language</i> (UML) .....	25
2.7. Implementasi Model Machine Learning Berbasis Web .....	26
<b>BAB III. METODOLOGI PENELITIAN</b> .....	<b>29</b>
3.1. Jenis Dan Sumber Data.....	32
3.1.1. Sumber Data.....	33
3.1.2. Rentang Dan Format Data.....	33
3.1.3. Alat Pengambilan Data.....	34
3.1.4. Karakteristik Data .....	35
3.2. Teknik Pengumpulan Data .....	35
3.3. Teknik Analisis Data .....	36
3.3.1. Preprocessing Data.....	36
3.3.2. Arsitektur Dan Pembentukan Model Temporal Convolutional Network (TCN) .....	37

3.4. Prosedur Pengujian dan Validasi .....	40
3.4.1. Prosedur Pelatihan Model .....	41
3.4.2. Prosedur Pengujian Model .....	41
3.4.3. Validasi Visual Hasil Prediksi.....	42
3.4.4. Interpretasi Hasil .....	42
3.5. Arsitektur Sistem Berbasis Web .....	43
3.6. Diagram Blok Sistem.....	44
3.7. <i>Unified Modelling Language</i> (UML) .....	45
3.8. Pengujian Sistem .....	45
<b>BAB IV. HASIL DAN PEMBAHASAN .....</b>	<b>47</b>
4.1. Deskripsi Data .....	47
4.2. <i>Exploratory Data Analysis</i> (EDA) .....	48
4.3. <i>Preprocessing Data</i> .....	50
4.4. Implementasi dan Arsitektur Model TCN .....	51
4.5. Hasil Evaluasi Kinerja Model .....	53
4.5.1. Hasil Evaluasi Kuantitatif .....	53
4.5.2. Visualisasi Hasil Prediksi .....	55
4.5.3. Hasil Prediksi Harga Hari Berikutnya .....	56
4.5.4. Validasi Hasil Dengan Teori dan Penelitian Terdahulu .....	57
4.5.5. Implikasi dan Keterbatasan Penelitian .....	57
4.6. Implementasi Aplikasi Prediksi Harga Saham .....	58
4.7. Hasil Black Box Testing Sistem .....	62
4.8. Kelebihan dan Kekurangan Sistem .....	64
4.8.1 Kelebihan Sistem .....	64
4.8.2 Kekurangan Sistem .....	65
<b>BAB V. PENUTUP .....</b>	<b>66</b>
5.1 Kesimpulan .....	66
5.2 Saran .....	67
<b>DAFTAR PUSTAKA .....</b>	<b>68</b>

## DAFTAR TABEL

TABEL 3.1 Contoh Tabel Dataset .....	34
TABEL 3.2 Proyeksi Skenario Black Box Testing .....	48
TABEL 4.1 Perbandingan Data Sebelum dan Sesudah Normalisasi .....	51
TABEL 4.2 Ringkasan Arsitektur Model TCN .....	52
TABEL 4.3 Hasil Evaluasi Kuantitatif Model TCN .....	54
TABEL 4.4 Hasil Black Box Testing .....	62

## DAFTAR GAMBAR

GAMBAR 2.1. Struktur Saraf Manusia .....	11
GAMBAR 2.2. Struktur Artificial Neural Network .....	12
GAMBAR 2.3. Dilated TCN Model .....	19
GAMBAR 2.4. TCN Sebelum Residual Connection .....	20
GAMBAR 2.5. TCN Sesudah Residual Connection .....	21
GAMBAR 2.6. Penambahan fungsi activation, normalization, regularization ....	22
GAMBAR 2.7. Arsitektur TCN .....	22
GAMBAR 3.1. Grafik Alur Penelitian .....	30
GAMBAR 3.2. Arsitektur Akhir TCN .....	38
GAMBAR 3.3. Diagram Blok Sistem .....	44
GAMBAR 3.4. Use Case Diagram .....	45
GAMBAR 4.1. Contoh Kode Pengambilan Data Dengan yfinance .....	48
GAMBAR 4.2. <i>Exploratory Data Analysis (EDA)</i> Pada Data Saham .....	48
GAMBAR 4.3. Hasil <i>Exploratory Data Analysis (EDA)</i> .....	49
GAMBAR 4.4. Visualisasi Harga Saham Penutupan (Close) .....	49
GAMBAR 4.5. Grafik Loss Proses Pelatihan dan Validasi Model TCN .....	53
GAMBAR 4.6. Visualisasi Perbandingan Harga Aktual Dengan Prediksi TCN ..	55
GAMBAR 4.7. Grafik Harga Aktual Saham BBRI .....	57
GAMBAR 4.8. Tampilan Awal Aplikasi .....	60
GAMBAR 4.9. Tampilan Aplikasi Melatih Model .....	60
GAMBAR 4.10. Tampilan Hasil Prediksi Harga Untuk Hari Berikutnya .....	61
GAMBAR 4.11. Tampilan Hasil Evaluasi Matriks Model .....	61
GAMBAR 4.12. Tampilan Grafik Perbandingan Harga Aktual Dengan Harga Prediksi .....	61

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Investasi saham merupakan salah satu instrumen investasi yang banyak diminati karena potensinya dalam memberikan keuntungan jangka panjang (Nasution & Al-khowarizmi, 2025). Selain itu, pergerakan harga saham juga kerap dijadikan indikator penting dalam menilai kondisi perekonomian suatu negara. Vanaga dan Sloka (2020, dalam Wathani et al., 2025) menyatakan bahwa dinamika pasar saham sering kali dianggap menjadi indikator penting dalam menilai kondisi ekonomi suatu negara dan merupakan isu yang sangat relevan dalam kajian ekonomi modern.

Namun, dalam praktiknya investor masih menghadapi tantangan dalam mengambil keputusan investasi yang akurat. Banyak investor yang masih mengandalkan intuisi semata dalam pengambilan keputusan investasi saham yang sering kali berujung pada keputusan spekulatif yang tidak berdasar. Di sisi lain, analisis teknikal yang dilakukan secara manual memiliki kelemahan berupa risiko *human error*, seperti kesalahan dalam menarik garis *support* dan *resistance* atau kekeliruan dalam menginterpretasikan pola pergerakan harga (*pattern recognition*) akibat bias kognitif.

Selain itu, analisis fundamental yang dianggap lebih komprehensif juga tidak lepas dari risiko kesalahan interpretasi. Kompleksitas laporan keuangan dan indikator makroekonomi sering kali menyebabkan investor menarik kesimpulan yang kurang tepat. Sebagai contoh, investor dapat terjebak pada kondisi *value trap* dengan menganggap saham murah berdasarkan nilai *Price to Earnings Ratio* (PER)

yang rendah, padahal secara struktural fundamental perusahaan sedang mengalami penurunan. Contoh lain adalah ketika investor hanya berfokus pada peningkatan laba bersih tanpa mempertimbangkan arus kas operasional yang negatif. Kombinasi antara faktor psikologis, keterbatasan kemampuan analisis, serta kompleksitas data inilah yang menyebabkan prediksi harga saham secara manual menjadi tidak konsisten dan kurang optimal.

Meskipun pergerakan harga saham bersifat acak dan sulit prediksi, berbagai penelitian menunjukkan bahwa pasar tidak sepenuhnya efisien. (Wang et al., 2020) menyatakan bahwa masih terdapat pola temporal dan keterkaitan antar saham yang dapat dipelajari melalui pendekatan *deep learning*, sehingga prediksi harga saham tetap dimungkinkan dalam batas tertentu. Penelitian lainnya juga menunjukkan bahwa pemanfaatan algoritma *machine learning* pada data *time series* saham mampu membantu investor dalam memahami pola pergerakan harga saham dan meminimalkan risiko pengambilan keputusan yang spekulatif (Putra et al., 2025). Kondisi tersebut mendorong peralihan menuju pendekatan yang lebih canggih melalui pemanfaatan *Artificial Intelligence* (AI). Dalam konteks ini, Jaringan Syaraf Tiruan (*Artificial Neural Network*) dan *Deep Learning* menawarkan kemampuan yang lebih unggul dalam mempelajari pola temporal pada data keuangan.

Seiring perkembangan *Deep Learning*, model berbasis *Recurrent Neural Network* (RNN), seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah banyak digunakan dalam prediksi data *time series*. Beberapa studi menunjukkan bahwa model GRU dan LSTM memiliki kemampuan yang baik dalam memodelkan dependensi temporal, khususnya ketika dikombinasikan

dengan teknik normalisasi data seperti *MinMax Scaler* (Switrayana et al., 2025). Meskipun demikian, pada studi yang dilaksanakan oleh Lea et al (2016) menyatakan arsitektur berbasis RNN/LSTM memiliki keterbatasan inheren, antara lain proses komputasi yang relatif lambat karena sifatnya yang sekuensial, permasalahan *vanishing gradient* pada data dengan panjang sekuens yang besar, serta model sulit untuk dilatih (*hard to train*). Michael dan Idowu (2025) menjelaskan bahwa meskipun LSTM unggul dalam memodelkan dependensi jangka panjang, arsitektur ini bersifat komputasi intensif dan cenderung kurang optimal dalam menangkap fitur temporal yang bersifat hierarkis.

Untuk mengatasi keterbatasan tersebut, diperkenalkan arsitektur *Temporal Convolutional Network* (TCN). TCN mengadopsi keunggulan *Convolutional Neural Networks* (CNN) yang memungkinkan pemrosesan data secara paralel, serta diadaptasi khusus untuk data sekuensial melalui mekanisme *dilated causal convolution* dan *residual connections* (Syahriel et al., 2025). Sejumlah penelitian sebelumnya menunjukkan bahwa TCN memiliki potensi yang baik dalam memodelkan data finansial yang bersifat dinamis dan kompleks (Munandar & Ghufon, 2025).

Meskipun demikian, masih terdapat kesenjangan penelitian berupa minimnya implementasi model prediksi ke dalam bentuk aplikasi yang dapat digunakan secara langsung oleh pengguna. Handayanto dan Herlawati (2020) menegaskan bahwa era industri 4.0 menuntut sistem pendukung keputusan agar dapat diakses secara fleksibel melalui platform berbasis web. Integrasi model *Machine Learning* ke dalam aplikasi web menjadi penting untuk menyediakan informasi prediksi secara *real-time* dan mudah diakses. Dani et al, (2022) menjelaskan bahwa kerangka kerja

(*framework*) web berbasis Python, seperti Flask dan Django efektif digunakan dalam proses *deployment* model *Machine Learning*, di mana Flask sesuai untuk aplikasi skala kecil hingga menengah, sedangkan Django cocok untuk aplikasi dengan kompleksitas yang lebih tinggi.

Berdasarkan penjelasan tersebut, penelitian ini mengusulkan pengembangan sistem prediksi harga saham PT Bank Rakyat Indonesia Tbk (BBRI) berbasis web dengan mengimplementasikan algoritma *Temporal Convolutional Network* (TCN). Fokus penelitian ini tidak hanya pada penerapan model prediksi, namun juga pembangunan sistem yang mampu menampilkan hasil prediksi dan menyediakan fungsionalitas yang sesuai dengan kebutuhan pengguna. Pengujian sistem dilakukan menggunakan metode *black box testing* untuk memastikan bahwa seluruh fungsi sistem berjalan sesuai dengan spesifikasi yang telah ditetapkan. Sistem yang dikembangkan diharapkan dapat menjadi sistem pendukung keputusan investasi yang mudah diakses, informatif, dan berbasis data.

## **1.2. Rumusan Masalah**

Berdasarkan latar belakang yang telah diuraikan, permasalahan dalam penelitian ini berfokus pada bagaimana merancang dan mengimplementasikan sistem prediksi harga saham PT Bank Rakyat Indonesia Tbk (BBRI) berbasis web dengan memanfaatkan algoritma *Temporal Convolutional Network* (TCN). Permasalahan selanjutnya berkaitan dengan bagaimana proses integrasi model prediksi berbasis TCN ke dalam aplikasi web sehingga sistem yang dikembangkan mampu menampilkan hasil prediksi serta menyediakan fungsionalitas yang sesuai dengan kebutuhan pengguna sebagai sistem pendukung keputusan investasi. Selain itu, skripsi ini juga mengkaji tingkat fungsionalitas dan keandalan sistem prediksi

harga saham yang dibangun dapat diuji dengan metode *black box testing* guna memastikan fitur dan layanan dalam sistem berjalan sesuai dengan spesifikasi yang telah ditetapkan.

### **1.3. Batasan Masalah**

Agar penelitian ini lebih terfokus dan terarah, maka ruang lingkup penelitian dibatasi pada penggunaan algoritma Temporal Convolutional Network (TCN) untuk prediksi harga saham terkhusus pada emiten dengan kode BBRI. Berbasis pada data historis yang diambil dari Yahoo Finance.

Data yang digunakan terbatas pada harga saham penutupan harian (*closing price*) dalam kurun waktu 1 Januari 2018 hingga 30 Desember 2025. Faktor eksternal seperti berita, kondisi ekonomi makro, atau sentimen pasar tidak tercakup pada program penelitian ini.

Penelitian ini memprediksi harga saham untuk satu hari kedepan, hanya membahas proses preprocessing data, pelatihan model, evaluasi kinerja model dengan metrik tertentu seperti RMSE, MAE, dan MAPE, serta visualisasi hasil forecasting melalui sistem berbasis web. Model lain seperti LSTM, ARIMA, CNN, GRU, atau Bi-LSTM tidak dibahas secara mendalam karena fokus utama adalah implementasi dan evaluasi model TCN.

### **1.4. Tujuan Penelitian**

Mengacu pada rumusan masalah tersebut, penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem prediksi harga saham PT Bank Rakyat Indonesia Tbk (BBRI) berbasis web dengan memanfaatkan algoritma *Temporal Convolutional Network* (TCN), dan juga mengintegrasikan model prediksi harga saham ke dalam sebuah aplikasi web sehingga sistem yang

dikembangkan mampu menampilkan hasil prediksi serta menyediakan fungsionalitas yang mendukung kebutuhan pengguna sebagai sistem pendukung keputusan investasi. Selain itu, penelitian ini bertujuan untuk menguji fungsionalitas dan keandalan sistem prediksi harga saham yang dibangun melalui metode *black box testing*, guna memastikan bahwa seluruh fitur sistem berjalan sesuai dengan spesifikasi yang telah ditetapkan dan dapat digunakan secara efektif oleh pengguna.

### **1.5. Manfaat Penelitian**

Manfaat yang diharapkan dari penelitian ini meliputi:

1. Memberikan kontribusi ilmiah dalam pengembangan metode prediksi harga saham menggunakan algoritma Temporal Convolutional Network (TCN), khususnya dalam konteks data *time series* saham yang memiliki karakteristik volatil dan non-linear.
2. Memberikan hasil evaluasi terperinci mengenai implementasi TCN pada data saham yang dapat dijadikan referensi bagi penelitian-penelitian selanjutnya mengenai prediksi harga saham.
3. Sebagai referensi utama dalam mengambil keputusan investasi berbasis web yang interaktif, mudah diakses, dan responsif, yang berfungsi sebagai alat bantu forecasting untuk investor dan pelaku pasar modal, khususnya pada saham BBRI.

## **BAB II**

### **LANDASAN TEORI**

#### **2.1. Artificial Intelligence**

Secara historis, fungsi utama komputer hanya terbatas pada penyelesaian tugas-tugas komputasi. Akan tetapi, sejalan dengan kemajuan teknologi di era digital, peran komputer telah bertransformasi secara signifikan menjadi instrumen esensial yang memfasilitasi berbagai dimensi kehidupan manusia. *Artificial Intelligence* (AI) atau kecerdasan buatan merupakan suatu disiplin ilmu komputer yang ditujukan untuk merancang mesin atau sistem agar mampu meniru kemampuan berpikir dan kecerdasan manusia dalam menyelesaikan berbagai masalah.

Selain itu dalam literatur yang ditulis oleh (Russell et al., 2021), definisi bidang AI tidaklah tunggal, melainkan terbagi ke dalam empat dimensi utama, yaitu berpikir layaknya manusia (*thinking humanly*), bertindak layaknya manusia (*acting humanly*), berpikir secara rasional (*thinking rationally*), dan bertindak secara rasional (*acting rationally*).

Secara sederhana, tugas-tugas yang dibangun dengan pendekatan *human centered* bertujuan untuk meniru perilaku dan kemampuan kognitif manusia. Pendekatan ini sering dikaitkan dengan Turing test. Turing test adalah teori dimana komputer dianggap cerdas jika menunjukkan perilaku yang tidak bisa dibedakan dari manusia, melalui percakapan teks dengan seorang penanya (interrogator) yang tidak tahu siapa lawan bicaranya manusia atau komputer.

Untuk mencapai kemampuan ini, sistem AI memerlukan integrasi dari berbagai kapabilitas utama, yaitu *Natural Language Processing* sebagai media

komunikasi dengan manusia, Knowledge Representation untuk menyimpan informasi yang diketahui atau didengar, *Automated Reasoning* untuk menjawab pertanyaan dan menarik kesimpulan baru dari informasi yang ada, dan *Machine Learning* untuk beradaptasi dengan situasi baru serta mendeteksi pola.

(Mubarik et al., 2024) menekankan aspek pembelajaran, penalaran, dan pemecahan masalah, yang sejalan dengan sejarah awal AI di mana peneliti berfokus pada penyelesaian masalah umum (*General Problem Solver*). Lebih lanjut, Ensiklopedia Britannica mendefinisikan AI sebagai cabang ilmu yang merepresentasi pengetahuan menggunakan simbol-simbol dan metode heuristik (Devianto & Dwiasnati, 2020). Hal ini merujuk pada era *Classical AI* atau *Symbolic AI*, di mana hipotesis sistem simbol fisik menyatakan bahwa tindakan cerdas dapat dicapai melalui manipulasi struktur simbol.

Dengan demikian, AI saat ini dapat dipahami sebagai ilmu yang berdiri dari berbagai disiplin ilmu termasuk di dalamnya matematika, neorosains, psikologi, teknik komputer, teori kontrol, dan linguistik yang bertujuan untuk membangun sistem cerdas yang mampu menerima persepsi dari lingkungan dan melakukan tindakan rasional untuk mencapai hasil atau tujuan yang diinginkan manusia.

### **2.1.1 Machine Learning**

*Machine Learning* merupakan salah satu cabang dari *Artificial Intelligence* (AI) yang berfokus pada pengembangan algoritma agar sistem komputasi mampu melakukan pengenalan pola dan menyesuaikan diri dengan situasi yang dinamis layaknya cara manusia belajar. Di era digital seperti sekarang, AI mengalami transformasi menjadi lebih ilmiah. Para peneliti mulai beralih ke metode yang terbukti secara matematis dengan penggunaan data. Penggunaan data menjadi aspek

penting agar sistem dapat belajar sehingga mendapat informasi yang dibutuhkan untuk melakukan tugasnya.

Untuk itu dikembangkan *machine learning*, konsepnya adalah melatih mesin menggunakan model algoritma matematika melalui data-data yang diberikan dengan tujuan memperoleh informasi dan memprediksi pola secara mandiri. Proses pembelajaran mesin untuk memperoleh kecerdasan terbagi menjadi dua tahapan, yaitu latihan (*training*), dan pengujian (*testing*).

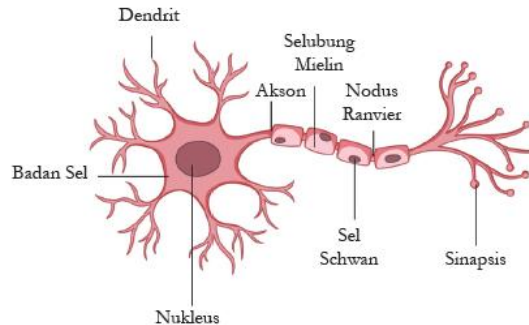
Machine Learning sendiri dapat dibagi menjadi tiga pilar pembelajaran utama, yaitu *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*. Berikut penjelasan lebih detail ketiga kategori tersebut:

- a. ***Supervised Learning*** merupakan metode pembelajaran mesin yang dilakukan dengan menggunakan data berlabel, sehingga setiap data telah memiliki output yang diketahui atau dataset yang sudah diketahui oleh pembuatnya. Menurut (Nurhalizah et al., 2024) *supervised learning* merupakan model pembelajaran yang menggunakan data berlabel sebagai dasar untuk prediksi atau klasifikasi. Pada metode ini, proses pembelajaran berlangsung dengan cara mesin menerima sejumlah pasangan data *input* dan *output* sebagai *data training*, lalu mesin akan mempelajari pola dari data tersebut untuk menghasilkan prediksi *output*. Hasil prediksi yang dihasilkan kemudian dibandingkan dengan data *output actual*. Apabila terjadi perbedaan, mesin akan melakukan penyesuaian secara bertahap untuk meminimalkan kesalahan hingga diperoleh hasil output yang akurat dan mendekati *output actual*.

- b. *Unsupervised Learning* merupakan metode pembelajaran mesin yang menggunakan data tanpa label, sehingga mesin tidak dibekali output yang benar agar mesin dapat melakukan eksplorasi pada data input yang diberikan untuk menemukan pola, struktur, atau hubungan tersembunyi di dalam data. Menurut (Nurhalizah et al., 2024) *unsupervised learning* merupakan model yang harus menemukan pola dari data tanpa bantuan label eksternal. Tujuan utama dari *unsupervised learning* adalah untuk mengekstraksi informasi yang tidak secara eksplisit terlihat, seperti kemiripan antara data atau pembentukan struktur data tertentu. Salah satu teknik yang paling lazim diterapkan dalam metode ini adalah *clustering* (penggugusan/pengelompokan). Pendekatan ini mempartisi sekumpulan data berdasarkan kesamaan atributnya, sedemikian rupa sehingga objek-objek di dalam satu klaster memiliki tingkat kemiripan yang tinggi (homogen), sementara objek antar-klaster memiliki perbedaan yang signifikan (heterogen).
- c. *Reinforcement Learning* adalah metode *machine learning* yang belajar melalui sistem poin untuk mencapai sebuah target, tanpa memerlukan data yang berlabel ataupun dikelompokkan. Hal ini dikonfirmasi dalam penelitian yang dilakukan oleh (Edy Prasetyo et al., 2025) yang menyatakan metode pembelajaran *reinforcement learning* tidak membutuhkan label atau supervise eksplisit (*explicit supervision*). Mesin ini memiliki kemampuan untuk belajar secara otonom guna mencapai tujuan yang ditetapkan, yakni dengan menerapkan metode uji coba (*trial and error*) secara iteratif di dalam lingkungan yang dinamis.

### 2.1.2 Artificial Neural Network

*Neural network* atau Jaringan Syaraf Tiruan (JST) merepresentasikan paradigma yang klasik namun terus berkembang secara mutakhir di bidang *Artificial Intelligence*. Pendekatan ini tidak beroperasi berdasarkan aturan logika atau formula matematika kaku, melainkan dirancang secara spesifik untuk mereplikasi arsitektur biologis jaringan saraf pada otak manusia. Ide yang mendasari *neural network* adalah cara kerja otak manusia yang bisa berpikir karena adanya miliaran sel saraf (*neuron*) yang saling terhubung. Menurut gambar 2.1 struktur biologis sistem saraf manusia terdiri dari dendrit, yaitu serat-serat yang menerima sinyal masuk, soma (Badan Sel), tempat memproses sinyal, skson, serat panjang yang mengirimkan sinyal keluar ke neuron lain. Dan sinapsis yang menjadi titik sambung antar neuron.




*Gambar 2.1 Struktur Saraf Manusia*

Sumber: (akupintar.id, 2025)

Pada tahun 1943, Warren McCulloch dan Walter Pitts mengusulkan model matematis neuron buatan untuk pertama kalinya. Mereka menyederhanakan cara kerja neuron menjadi seperti sakelar. Cara kerja ini terdiri dari tiga hal, yaitu input sebagai tempat sinyal masuk dari neuron lain. Proses sebagai tempat neuron menjumlahkan sinyal-sinyal yang masuk, dan output yang memiliki ketentuan jika

sinyal yang masuk cukup kuat (melebihi ambang batas tertentu), neuron akan “aktif” dan mengirim sinyal keluar. Jika tidak, neuron akan diam (*off*).



Gambar 2.2 Struktur Artificial Neural Network

Sumber: (socs.binus.id, 2025)

Kekuatan hubungan antar neuron ini disebut dengan bobot (*weight*). Menurut Russell et al., (2021), proses pembelajaran sebenarnya hanyalah proses mengubah-ubah kekuatan bobot koneksi antar neuron. Neural Network terdiri dari banyaknya lapisan-lapisan (*layers*). Biasanya struktur Neural Network terdiri dari *input layer* yang menerima data mentah, *hidden layers* (lapisan tersembunyi) yang berada ditengah yang memproses fitur-fitur rumit. Dan yang terakhir adalah *output layer* untuk memberikan hasil keputusan.

Pada tahun 1980-an ditemukan untuk pertama kalinya algoritma bernama *Back-propagation* (Propagasi Balik). Algoritma ini memungkinkan jaringan multi-lapisan untuk menyesuaikan diri dan meningkatkan akurasi prediksi secara otomatis. Secara garis besar, mekanisme algoritma ini terdiri dari tiga tahapan utama yang dilakukan secara berulang (*iterative*), yaitu:

1. **Fase Maju (*forward propagation*)** pada tahap awal, data input dimasukkan ke dalam jaringan. Data ini diproses melewati lapisan-lapisan neuron (*hidden layers*), di mana setiap neuron melakukan operasi matematis berdasarkan bobot (*weight*) yang dimiliki. Hasil pemrosesan ini diteruskan

hingga mencapai lapisan output, menghasilkan sebuah prediksi atau klasifikasi.

2. **Perhitungan Kesalahan (*Error Calculation*)** dilakukan setelah output dihasilkan, sistem membandingkan hasil prediksi tersebut dengan label data yang sebenarnya (target). Selisih antara prediksi jaringan dan kenyataan dihitung menggunakan fungsi kerugian (*loss function*). Pada tahap ini, sistem mengidentifikasi besarnya kesalahan (*error*) yang terjadi.
3. **Fase Mundur (*Backward Propagation*)** Inilah inti dari proses pembelajaran mesin. Sistem menelusuri kembali jaringan dari output ke input (mundur). Tujuannya adalah untuk mengidentifikasi neuron mana yang memberikan kontribusi terbesar terhadap kesalahan tersebut. Berdasarkan informasi ini, algoritma melakukan pembaruan bobot (*weight update*) pada koneksi antar neuron untuk meminimalisir kesalahan di masa depan.

### **2.1.3 Deep Learning**

*Deep Learning*, yang juga dikenal dengan istilah *deep structured learning*, merupakan subbidang *machine learning* yang berakar pada arsitektur *Artificial Neural Network* (Jaringan Syaraf Tiruan). Metode ini beroperasi dengan memanfaatkan tumpukan lapisan tersembunyi (*hidden layers*) guna melakukan ekstraksi fitur secara otomatis dan hierarkis. Tingkat kedalaman lapisan inilah yang memungkinkan sistem untuk memproses pembelajaran tingkat lanjut serta merepresentasikan pola data yang berdimensi tinggi dan sangat kompleks (Sarker, 2021).

Perbedaan mendasar antara *deep learning* dan *machine learning* terletak pada skala dan kompleksitas data yang digunakan. *Deep learning* mengeliminasi kebutuhan rekayasa fitur manual (*hand-crafted features*) yang umum pada ML, namun sebagai gantinya, ia menuntut volume data yang masif (*Big Data*) dan daya komputasi tinggi (seperti penggunaan GPU) untuk mencapai konvergensi model yang optimal (Janiesch et al., 2021).

## **2.2. Saham**

Saham merepresentasikan bukti kepemilikan modal individu maupun entitas terhadap sebuah perusahaan atau perseroan terbatas (Mahendra et al., 2022). Pihak yang memiliki saham ini secara umum dikenal sebagai pemegang saham (*stockholder*). Dalam dinamika pasar modal, pergerakan harga saham memiliki tingkat fluktuasi yang tinggi sehingga polanya cukup menantang untuk diprediksi. Nilai suatu saham pada dasarnya terbentuk dari mekanisme permintaan (*demand*) dan penawaran (*supply*). Tarik-menarik antara permintaan dan penawaran ini dipengaruhi oleh berbagai katalisator, mulai dari faktor internal seperti kinerja finansial dan tren industri perusahaan, hingga sentimen makroekonomi. Faktor makro yang turut mendikte pergerakan pasar tersebut mencakup tingkat suku bunga, laju inflasi, volatilitas nilai tukar mata uang, serta aspek non-ekonomi yang meliputi stabilitas sosial dan iklim politik di lingkungan operasional perusahaan.

## **2.3. Analisis Saham**

Dalam pasar modal, investor saham dihadapkan tantangan untuk melakukan keputusan investasi yang rasional, menguntungkan, dan minim resiko kerugian. Investasi saham termasuk sebagai investasi berisiko tinggi (*high-risk investment*). Karakteristik ini muncul karena harga saham bersifat *volatile*, menunjukkan

fluktuasi yang cepat dan signifikan. Ada banyak cara dalam menganalisa arah harga saham yang tepat, diantaranya analisa teknikal, dan analisa fundamental.

#### **2.4. Machine Learning Dalam Forecasting Harga Saham**

*Machine Learning* (ML) merupakan subdisiplin dari Kecerdasan Buatan yang menitikberatkan pada perancangan algoritma agar sebuah sistem komputasi mampu mengekstraksi pola secara otonom dari data masukan. Kemampuan belajar mandiri ini memungkinkan sistem untuk menghasilkan luaran yang ditargetkan, seperti pengambilan keputusan, tanpa memerlukan instruksi pemrograman secara eksplisit. Berdasarkan studi yang dilakukan oleh Janiesch et al., (2021) menyatakan bahwa *machine learning* dalam *forecasting* harga saham memberikan pendekatan baru yang lebih adaptif dan akurat dibandingkan metode statistic konvensional.

Kemampuan machine learning dalam memahami data time series yang kompleks menjadikannya pilihan yang tepat dibandingkan pendekatan lain seperti regresi linier atau ARIMA yang terbukti kurang efektif dalam menangkap pola-pola tersembunyi. Hal ini didukung dengan studi yang dilakukan (Gao et al., 2021) yang menyatakan *machine learning* memiliki peran penting dalam memahami data time series karena ia mampu belajar dari data historis dan menyesuaikan model berdasarkan pola yang terus berubah.

Mekanisme kerja algoritma *machine learning* pada dasarnya melibatkan pembagian data ke dalam dua himpunan, yaitu data pelatihan (*training set*) dan data pengujian (*testing set*). Proses pembelajaran pola relasi *input-output* terjadi secara intensif pada himpunan data pelatihan, sementara himpunan data pengujian berperan sebagai tolok ukur evaluasi untuk menguji keandalan model. Adapun

beberapa metode *machine learning* yang sering diaplikasikan dalam keperluan peramalan harga saham meliputi:

1. Decision Tree dan Random Forest
2. Support Vector
3. Artificial Neural Network (ANN)
4. Recurrent Neural Networks (RNN)
5. Long Short-Term Memory
6. Temporal Convolutional Network (TCN)

Dari berbagai pendekatan tersebut, model TCN menjadi salah satu model *machine learning* yang dapat digunakan untuk *forecasting* harga saham karena model ini diadaptasi khusus untuk data sekuensial melalui mekanisme *dilated causal convolution* dan *residual connections* (Syahriel et al., 2025). Sejumlah penelitian sebelumnya turut menyatakan bahwa TCN memiliki potensi yang baik dalam memodelkan data finansial yang bersifat dinamis dan kompleks (Munandar & Ghufron, 2025).

Kelebihan *machine learning* dalam *forecasting* harga saham tidak hanya dinilai dalam tingkat akurasi yang diberikan, namun juga pada kemampuannya untuk belajar secara adaptif terhadap data baru, sehingga model dapat terus diperbarui dan diperbaiki seiring waktu. Dengan begitu, *machine learning* menjadi pendekatan yang sangat relevan untuk *forecasting* harga saham yang memiliki sifat dinamis dan terus berubah.

## **2.5. Temporal Convolutional Network (TCN)**

Pada dasarnya Temporal Convolutional Network (TCNs) merupakan arsitektur jaringan syaraf tiruan berbasis Convolutional Neural Network (CNN) yang

dirancang khusus untuk menangani data *time series*. Menurut Yadav, (2024) TCN merupakan CNN yang dimodifikasi menjadi memanfaatkan operasi konvolusi satu dimensi. Operasi konvolusi satu dimensi (*1D convolution*) ini memungkinkan pemrosesan data secara parallel dan lebih efisien.

### 2.5.1 Causal Convolutional

Terdapat satu aturan yang menjadi pembeda paling jelas antara CNN dan TCN, yaitu sifat kausalitas. Dalam TCN *causal convolution* memastikan bahwa output pada waktu ke- $t$  hanya dipengaruhi oleh input pada waktu ke- $t$  dan waktu sebelumnya ( $t - 1, t - 2, \dots$ ), model dilarang untuk melihat input di masa depan ( $t + 1$ ). Hal ini mencegah terjadinya *data leakage* (kebocoran data) dari data masa depan ke masa lalu, sehingga model tetap valid untuk tugas prediksi deret waktu. Untuk mencegah hal ini TCN menggunakan *causal padding*, yaitu menambahkan nilai nol di awal urutan agar panjang data tetap sama tanpa melihat masa depan.

### 2.5.2 Dilated Convolutional

Model TCN juga memiliki *dilated convolution* yang memungkinkan model untuk memperluas receptive field tanpa harus menambah jumlah parameter atau kedalaman jaringan secara signifikan. TCN memanfaatkan *dilation factor* ( $d$ ) untuk menentukan seberapa jauh melihat angka kebelakang dengan pola eksponensial ( $1, 2, 4, 8, 16, \dots$ ). Secara matematis *dilated convolutional* dapat dinyatakan dalam rumus berikut ini:


$$y(t) = \sum_{i=0}^{k-1} f(i) \cdot x(t - d \cdot i)$$

Dimana

- $y(t)$  merupakan nilai output (hasil prediksi/fitur) pada waktu ke- $t$ ,
- $x$  merupakan data input,
- $f(i)$  merupakan fungsi filter (kernel) yang dipelajari oleh jaringan saraf dengan ukuran  $k$  (berapa banyak titik data yang diambil dalam satu kali operasi),
- $x(t - d.i)$  merupakan nilai input pada urutan waktu tertentu,
- $d$  merupakan faktor dilasi (*dilation factor*) yang menentukan jarak pengambilan data masukan.

Meskipun pada *dilated convolution* terlihat adanya jarak atau lompatan antar data input, TCN pada dasarnya tidak menghilangkan informasi temporal. Hal ini disebabkan oleh mekanisme penumpukan lapisan (*layer stacking*) yang dirancang secara sistematis.

Pada lapisan terbawah ( $d = 1$ ), TCN menggunakan konvolusi dengan faktor dilasi satu, sehingga setiap neuron hanya memproses data yang berdekatan secara langsung. Lapisan ini berperan dalam menangkap pola-pola lokal pada deret waktu tanpa adanya lompatan data. Informasi yang diperoleh pada tahap ini bersifat padat dan detail. Lapisan berikutnya ( $d = 2$ ), menerima input dari output lapisan sebelumnya. Meskipun lapisan ini menggunakan faktor dilasi yang lebih besar, proses konvolusi dilakukan terhadap representasi data yang telah diperkaya dari lapisan sebelumnya yang telah berisi informasi temporal penting.



Gambar 2.3 Dilated TCN Model

Sumber: (Lea et al., 2016)

Proses ini berlanjut pada lapisan-lapisan berikutnya, dimana setiap lapisan yang lebih tinggi mengintegrasikan informasi dari lapisan dibawahnya. Secara konseptual, mekanisme ini dapat dianalogikan sebagai struktur piramida, di mana lapisan atas merangkum informasi yang luas dari seluruh lapisan dibawahnya tanpada adanya celah informasi. Melalui pendekatan ini TCN mampu membentuk *receptive field* (jangkaun pandang) yang sangat luas dengan jumlah parameter dan biaya komputasi yang relatif efisien.

Penumpukan banyak lapisan konvolusi pada TCN bertujuan untuk memperluas jangkauan temporal model. Namun, arsitektur jaringan yang semakin dalam berpotensi menimbulkan permasalahan *vanishing gradient* (model susah untuk belajar). Menurut Yadav, (2024) untuk mengatasi permasalahan tersebut, TCN menerapkan *residual connection* dalam bentuk *residual blocks*. Pada mekanisme ini, input awal tidak hanya diproses melalui

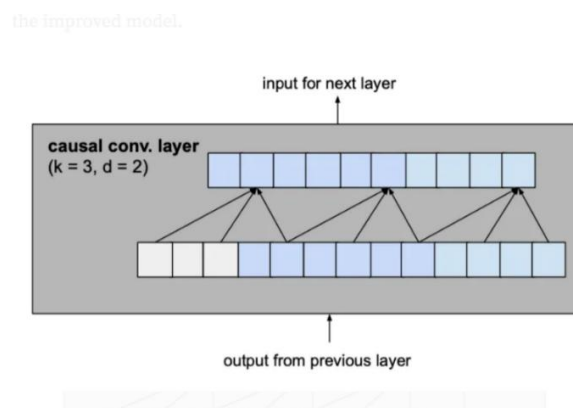
rangkaian dengan output hasil konvolusi. Secara matematis, proses ini dapat dinyatakan sebagai:

$$y = F(x) + x$$

di mana  $x$  merupakan input awal dan  $F(x)$  adalah hasil transformasi konvolusi

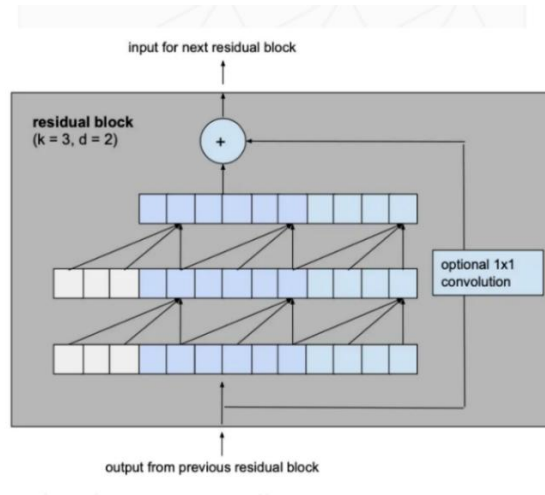
### 2.5.3 Residual Connection

*Residual connection* berfungsi sebagai jalur langsung bagi informasi gradien, sehingga proses pelatihan model menjadi lebih stabil. Dengan adanya jalur ini, model dijamin tidak mengalami penurunan performa dibandingkan dengan jaringan tanpa pemrosesan tambahan, serta memungkinkan optimasi yang lebih efektif pada jaringan dengan kedalaman yang besar (deep). Gambar 2.4 dan 2.5 menunjukkan perbedaan struktur TCN sebelum ditambah residual connection dan sesudahnya.



Gambar 2.4 TCN Sebelum Residual Connection

Sumber: (Lässig, 2020)



Gambar 2.5 TCN Sesudah Residual Connection

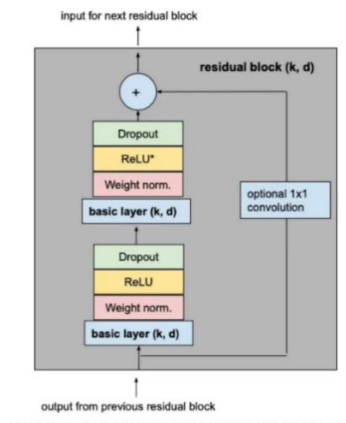
Sumber: (Lässig, 2020)

#### 2.5.4 Activation Function, Normalization, dan Regularization

Untuk memastikan model TCN tidak hanya berperan sebagai model regresi linear yang kompleks, diperlukan penambahan *activation function* diatas *convolutional layer*. *Activation function* yang umum digunakan adalah *Rectified Linear Unit (ReLU)*, yang berperan dalam memperkenalkan sifat non-linear pada model sehingga meningkatkan kemampuan representasi TCN (Bai et al., 2018).

Selain itu, guna menjaga stabilitas proses pelatihan dan menghindari permasalahan *exploding gradient*, ditambahkan teknik *weight normalization* pada setiap *convolutional layer*. Teknik ini membantu menormalkan bobot pada *hidden layer* sehingga proses optimasi menjadi lebih terkendali. Untuk mengurangi risiko *overfitting*, mekanisme *regularization* juga diterapkan melalui penggunaan *dropout function* pada bagian akhir setiap *convolutional layer*.

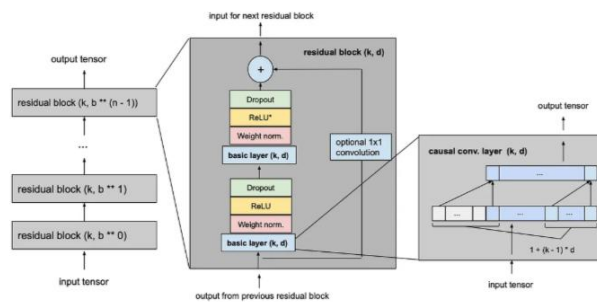
Dengan demikian, model TCN dapat menghasilkan performa yang lebih robust dan mampu melakukan generalisasi dengan lebih baik terhadap data yang belum pernah dilihat sebelumnya. Struktur TCN setelah ditambahkan ketiga fungsi tersebut dapat dilihat pada gambar 2.6.



Gambar 2.6 Penambahan fungsi activation, normalization, dan regularization

Sumber: (Lässig, 2020)

### 2.5.5 Arsitektur Akhir Temporal Convolutional Network



Gambar 2.7 Arsitektur TCN

Sumber: (Lässig, 2020)

Pada gambar 2.7 mengilustrasikan arsitektur akhir dari Temporal Convolutional Network (TCN). Pada bagian kiri, terlihat struktur jaringan yang tersusun dari tumpukan *residual blocks*, di mana faktor dilasi ( $d$ )

meningkat secara eksponensial seiring bertambahnya kedalaman lapisan. Hal ini bertujuan untuk memperluas *receptive field*.

Pada bagian tengah, terlihat komponen internal dari sebuah *residual blocks*. Setiap blok terdiri dari dua lapisan operasi yang identik (dilakukan dua kali), yaitu causal convolution, weight normalization, fungsi aktivasi ReLU, dan dropout untuk regularisasi. Fitur utama arsitektur ini adalah adanya *residual connection* (garis panah melengkung), yang menjumlahkan input asli dengan hasil transformasi konvolusi, memastikan stabilitas gradien pada jaringan yang dalam (deep).

Terakhir, pada bagian kanan memvisualisasikan mekanisme dari *causal convolution*, di mana filter melakukan konvolusi dengan melompati input sesuai faktor dilasi tertentu, serta mematuhi prinsip kausalitas (hanya melihat data masa lalu) guna mencegah kebocoran data masa depan (*data leakage*).

### **2.5.6 Perbandingan TCN dengan RNN dan LSTM**

Selama bertahun-tahun, *Recurrent Neural Network (RNN)* dan *Long Short-Term Memory (LSTM)*, menjadi pendekatan dominan dalam pemodelan data time series. Hal ini karena kemampuan RNN/LSTM dalam memodelkan dependensi temporal secara eksplisit melalui mekanisme pemrosesan berurutan. Namun, perkembangan arsitektur *convolution-based sequence modelling* melahirkan *Temporal Convolutional Network (TCN)* sebagai alternatif dari RNN dan LSTM. Perbandingan antara TCN dan RNN/LSTM dapat ditinjau dari beberapa aspek berikut.

### **2.5.6.1 Kecepatan Pelatihan dan Parallelism**

Perbandingan paling signifikan antara TCN dan RNN/LSTM terletak pada mekanisme komputasi saat proses pelatihan. RNN dan LSTM memproses data secara sekuensial, di mana perhitungan pada waktu ke- $t$  sangat bergantung pada hasil perhitungan pada waktu ke- $t-1$ . Ketergantungan ini menyebabkan proses pelatihan tidak dapat diparalelkan secara penuh, sehingga pemanfaatan perangkat keras seperti GPU menjadi kurang optimal dan waktu pelatihan relatif lebih lama.

Sebaliknya, TCN menggunakan operasi konvolusi satu dimensi (*1D convolutional*) yang memungkinkan pemrosesan seluruh urutan data secara paralel dan tetap menjaga kausalitas. Setiap filter konvolusi dapat dihitung secara bersamaan untuk seluruh langkah waktu, sehingga TCN mampu memanfaatkan kemampuan paralel GPU secara maksimal. Hasilnya, proses pelatihan TCN umumnya jauh lebih cepat dibandingkan RNN/LSTM pada dataset berukuran besar.

### **2.5.6.2 Kemampuan Menangkap Dependensi Jangka Panjang**

LSTM dirancang untuk mengatasi kelemahan RNN klasik dalam menangkap dependensi jangka panjang melalui mekanisme *gating*. Meskipun demikian, dalam praktiknya, sinyal gradien tetap harus melewati banyak langkah waktu secara berurutan, sehingga berpotensi mengalami pelemahan (*vanishing gradient*), terutama pada sekuens yang sangat panjang.

TCN mengatasi permasalahan ini melalui penggunaan *dilated convolution* dan *stacked layers*. Dengan konfigurasi dilasi yang meningkatkan secara eksponensial, TCN mampu membentuk *receptive field* yang sangat luas hanya dengan beberapa lapisan konvolusi. Selain itu, jalur propagasi gradien pada TCN relatif lebih pendek dibandingkan RNN/LSTM, sehingga informasi dari masa lalu yang jauh dapat diteruskan ke output dengan lebih stabil dan efektif.

#### **2.5.6.3 Fleksibilitas Input**

RNN dan LSTM secara alami dapat menerima input dengan panjang yang bervariasi tanpa memerlukan penyesuaian struktur jaringan, karena pemrosesan dilakukan langkah demi langkah berdasarkan urutan waktu. Sedangkan TCN memiliki struktur yang bergantung pada ukuran kernel dan panjang *receptive field*. Meskipun demikian, pendekatan TCN modern telah mengadopsi berbagai Teknik, seperti padding dinamis dan masking, untuk memungkinkan pemrosesan sekuens dengan Panjang yang berbeda. Oleh karena itu, perbedaan fleksibilitas antara TCN dan RNN/LSTM pada aspek ini menjadi semakin kecil dan dapat dianggap relatifimbang.

### **2.6. Unified Modelling Language (UML)**

*Unified Modelling Language* (UML) merupakan bahasa visual untuk pemodelan dan komunikasi di sekitar sistem yang menggunakan skema dan skrip pendukung (Elis & Voutama, 2022). Dalam pengembangan sistem perangkat lunak, UML berfungsi untuk memvisualisasikan, merancang, dan mendokumentasikan arsitektur sistem secara komprehensif sehingga meminimalisir kesalahan logika

desain. Berdasarkan penjelasan yang dilakukan oleh Viktoria, (2022) terdapat beberapa alat bantu yang biasa digunakan, yaitu:

1) *Use Case Diagram*

*Use case diagram* merupakan representasi visual yang memodelkan interaksi fungsional antara sistem dengan satu atau sekumpulan aktor yang terlibat di dalamnya. Diagram ini tidak menguraikan logika matematis algoritma, melainkan mendefinisikan batas hak akses dan aksi apa saja yang dapat dilakukan pengguna melalui antarmuka web.

2) *Class Diagram*

Digunakan untuk menunjukkan struktur statis dari sistem web, mencakup detail kelas, atribut, operasi, dan relasi antar entitas.

3) *Sequence Diagram*

Menjelaskan interaksi antar objek berdasarkan urutan waktu. Diagram ini memvisualisasikan bagaimana *request* dari antarmuka pengguna dikirim ke *server*, diproses oleh model prediksi di *backend*, dan respons akhirnya dikembalikan lagi ke layar pengguna (Elis & Voutama, 2022).

## **2.7. Implementasi Model *Machine Learning* Berbasis Web**

Implementasi model *deep learning* ke dalam sistem berbasis web merupakan tahapan penting untuk menjembatani hasil penelitian dengan kebutuhan pengguna akhir (*end-user*). Handayanto dan Herlawati (2020) menegaskan bahwa era industri 4.0 menuntut sistem pendukung keputusan agar dapat diakses secara fleksibel melalui platform berbasis web. Dalam konteks prediksi harga saham, model prediksi tidak hanya dituntut memiliki tingkat akurasi yang baik, tetapi juga harus dapat diakses secara mudah, cepat, dan informatif. Oleh karena itu, diperlukan

integrasi antara model *machine learning* dan aplikasi web sebagai sistem pendukung keputusan investasi.

*Temporal Convolutional Network* (TCN) sebagai salah satu arsitektur *deep learning* untuk data deret waktu (*time series*) memiliki karakteristik yang mendukung implementasi ke dalam sistem berbasis web. TCN menggunakan pendekatan konvolusional yang memungkinkan proses inferensi dilakukan secara paralel, sehingga lebih efisien dibandingkan model berbasis *Recurrent Neural Network* (RNN) yang bersifat sekuensial. Efisiensi ini menjadikan TCN lebih sesuai untuk diterapkan pada sistem berbasis web yang membutuhkan respons cepat dan stabil.

Implementasi model TCN dalam sistem berbasis web umumnya dilakukan dengan memisahkan proses pelatihan model dan proses penggunaan model (*inference*). Model TCN terlebih dahulu dilatih menggunakan data historis hingga diperoleh model terbaik, kemudian disimpan sebagai *pre-trained model*. Model tersebut selanjutnya diintegrasikan ke dalam aplikasi web, di mana sistem akan memanggil model yang telah dilatih untuk menghasilkan prediksi berdasarkan input data yang diberikan pengguna. Pendekatan ini meningkatkan *maintainability* sistem karena pembaruan model dapat dilakukan tanpa harus membangun ulang keseluruhan aplikasi.

Penelitian sebelumnya menunjukkan bahwa integrasi model *deep learning* ke dalam aplikasi web dapat memberikan manfaat praktis bagi pengguna. Bagastio et al., (2023) mengembangkan sistem prediksi harga saham berbasis web dengan mengintegrasikan model *deep learning* ke dalam framework web, di mana hasil prediksi dapat ditampilkan secara visual dan mudah dipahami oleh pengguna. Hasil

penelitian tersebut membuktikan bahwa pendekatan integrasi model prediksi ke dalam sistem web mampu meningkatkan aksesibilitas dan kegunaan hasil prediksi dalam pengambilan keputusan investasi.

Dalam implementasi sistem berbasis web, aplikasi berperan sebagai penghubung antara pengguna dan model TCN. Sistem menerima permintaan prediksi, memproses data yang diperlukan, menjalankan inferensi menggunakan model TCN, dan menyajikan hasil prediksi dalam bentuk informasi yang mudah dipahami. Dengan demikian, sistem berbasis web tidak hanya berfungsi sebagai media visualisasi, tetapi juga sebagai sistem pendukung keputusan (*decision support system*) yang memanfaatkan kecerdasan buatan.

Berdasarkan kajian tersebut, dapat disimpulkan bahwa implementasi model TCN ke dalam sistem berbasis web merupakan pendekatan yang relevan dan aplikatif untuk prediksi harga saham. Integrasi ini memungkinkan pemanfaatan keunggulan TCN dalam memodelkan data *time series* yang kompleks sekaligus menyediakan sistem yang praktis, mudah diakses, dan berorientasi pada kebutuhan pengguna. Pendekatan ini selaras dengan tujuan penelitian yang menekankan tidak hanya pada pengembangan model prediksi, tetapi juga pada penyediaan sistem pendukung keputusan investasi berbasis web.

## BAB III

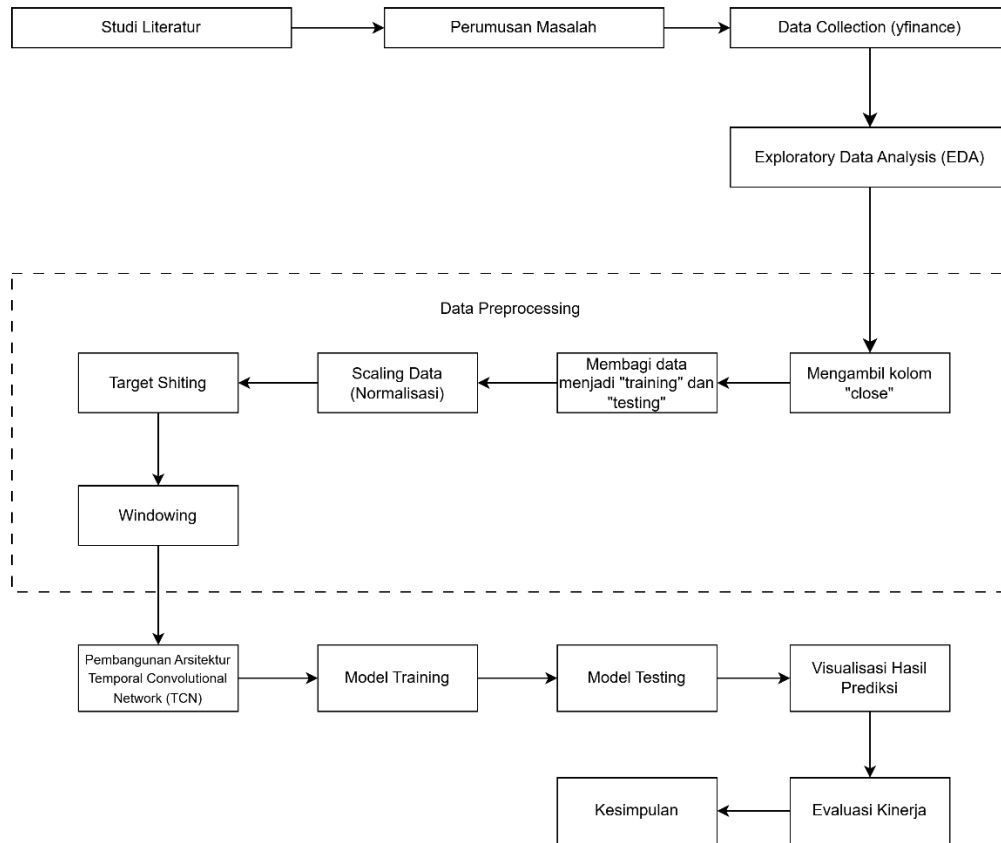
### METODOLOGI PENELITIAN

Penelitian ini mengadopsi pendekatan *Research and Development (R&D)*, yakni sebuah metode yang difokuskan pada perancangan, pengembangan, sekaligus pengujian efektivitas suatu produk. Adapun luaran utama yang dikembangkan dalam studi ini adalah sebuah aplikasi peramalan harga saham berbasis web yang mengimplementasikan pemodelan *Temporal Convolutional Network (TCN)*. TCN adalah sebuah arsitektur berbasis *Convolutional Neural Network (CNN)* yang dimodifikasi khusus untuk data sekuensial.

TCN memanfaatkan mekanisme *dilated causal convolutions* yang memungkinkan menangkap *long-term dependencies* dengan *receptive field* yang sangat luas tanpa mengalami masalah *vanishing gradient*, serta model TCN turut menawarkan efisiensi waktu pelatihan yang lebih cepat dibandingkan RNN/LSTM karena model TCN memiliki pemrosesan yang bersifat parallel. Hal ini didukung dengan penelitian yang dilakukan oleh (Putra et al., 2025; Bai et al., 2018). Ditinjau dari kerangka kerjanya, penelitian ini mengimplementasikan paradigma *supervised learning*. Dalam pendekatan ini, model diberikan pelatihan untuk memetakan sekuens data historis harga penutupan saham (*closing price*) sebagai variabel *input*, guna memproyeksikan target *output* berupa harga penutupan pada periode waktu selanjutnya ( $t+1$ ).

Diagram alir turut digunakan dalam penelitian ini guna memvisualisasikan langkah-langkah utama yang dilakukan dalam proses penelitian secara sistematis dan berurutan. Diagram ini menggambarkan alur logis dari mulai pengambilan data, preprocessing, pelatihan model, hingga penampilan grafik ke dalam sistem.

Diagram alir ini bertujuan untuk mempermudah pemahaman terhadap tahapan penelitian, serta menjadi dokumentasi visual dari proses eksperimen berbasis komputasi yang dilakukan dalam penelitian ini. Berikut penjelasan alur penelitian:



*Gambar 3.1 Grafik Alur Penelitian*

1. Studi literatur dilakukan untuk mengetahui penelitian terkini dari permasalahan.
2. Perumusan masalah dilakukan untuk menentukan masalah apa yang dihadapi dalam penelitian.
3. Pengambilan data saham dengan library Python yfinance. Dengan memanfaatkan library tersebut, proses pengambilan data menjadi lebih mudah, hanya dengan memasukkan kode emiten dari saham yang diinginkan.

4. Selanjutnya adalah proses Exploratory Data Analysis (EDA), yaitu proses memahami kondisi data yang digunakan dan menyiapkan data agar mampu dioleh oleh model algoritma. Dalam EDA terdapat beberapa proses yang akan dilakukan, yaitu cek dimensi dan jumlah data, cek tipe data, dan cek apakah terdapat data yang kosong (*missing value*).
5. Langkah selanjutnya adalah proses preprocessing data yang diawali dengan mengambil kolom harga penutupan (*close*).
6. Selanjutnya, data akan dibagi menjadi dua, data training dan data testing
7. *Scaling data* (normalisasi) dengan rentang 0 hingga 1 agar model algoritma tidak mengalami bias karena rentang harga aktual yang jauh saat proses prediksi berlangsung.
8. *Target Shifting* untuk one-step forecasting (1 hari kedepan) dengan  $y(t) = x(t + 1)$ , untuk mengubah data historis menjadi data prediksi.
9. *Sliding Window* menggunakan 60 data historis terakhir secara berurutan (*chronological sliding window*).
10. Selanjutnya melakukan pemodelan algoritma TCN.
11. Proses training dilakukan untuk melakukan pembelajaran pada model algoritma.
12. Lalu akan dilakukan proses testing untuk mengetahui hasil prediksi yang dilakukan.
13. Hasil prediksi akan divisualisasikan untuk mengetahui bagaimana perbandingan dengan harga aktual.

14. Lalu hasil prediksi akan dilakukan evaluasi kinerja dengan menghitung nilai error guna mendapatkan kesimpulan apakah model menghasilkan prediksi yang baik atau buruk.

15. Setelah didapatkan hasil prediksi dan perhitungan error, maka akan dihasilkan kesimpulan mengenai penelitian yang dilakukan.

### **3.1. Jenis dan Sumber Data**

Dalam penelitian ini, himpunan data saham yang dimanfaatkan terklasifikasi sebagai data kuantitatif sekunder. Adapun yang dimaksud dengan data sekunder adalah instrumen data yang bersumber dari publikasi pihak ketiga, bukan merupakan data primer yang dihimpun secara langsung oleh peneliti melalui proses observasi maupun eksperimen. (Switrayana et al., 2025). Data saham PT. Bank Rakyat Indonesia Tbk (BBRI) disediakan oleh website penyedia data saham yaitu *Yahoo Finance*. Data saham ini akan diambil menggunakan library python *yfinance*. Pemilihan Python dilakukan untuk menjaga reproducibility dan efisiensi. Pemanfaatan Yahoo Finance dipilih karena ketersediaan data historis yang luas dan kemudahan integrasi dengan alur pemograman Python, sebagaimana hal ini pernah serupa dilakukan pada penelitian sebelumnya (Sungkowo, 2025; Switrayana et al., 2025).

Pada penelitian ini hanya menggunakan data harga penutupan saham harian (closing price). Harga penutupan dipilih karena dianggap paling representative dalam mencerminkan consensus harga saham pada akhir sesi perdagangan dan paling banyak digunakan penelitian berbasis forecasting time series (Switrayana et al., 2025). Berbagai penelitian sebelumnya juga mendukung pemanfaatan harga penutupan sebagai input tunggal untuk model LSTM maupun TCN karena

kestabilannya dibandingkan harga tertinggi, terendah, atau harga pembukaan (Sungkowo, 2025; Hakim, 2021).

### **3.1.1 Sumber Data**

Sebagaimana telah diuraikan sebelumnya, penelitian ini memanfaatkan Yahoo Finance (<https://finance.yahoo.com/>), sebagai sumber data utama. Platform ini telah terbukti secara akademis dan lazim diimplementasikan dalam berbagai literatur peramalan (*forecasting*) harga saham, khususnya pada penelitian yang menggunakan arsitektur LSTM maupun TCN. (Switrayana et al., 2025; Sungkowo, 2025; Hakim, 2021).

Berdasarkan studi yang dilakukan oleh Switrayana et al. (2025), Yahoo Finance merupakan instrumen yang efisien dalam proses akuisisi data historis karena memiliki cakupan emiten saham yang sangat komprehensif. Selain itu, dataset yang dihasilkan memiliki kompatibilitas tinggi dengan *library* Python seperti *pandas* dan *NumPy*, yang berperan krusial sebagai fondasi utama dalam tahapan praproses data hingga implementasi model.

### **3.1.2 Rentang dan Format Data**

Data yang digunakan dalam penelitian ini mencakup periode 1 Januari 2018 hingga 30 Desember 2025. Rentang waktu ini dipilih karena mencerminkan pergerakan pasar saham terbaru dan mencakup satu siklus tahunan secara penuh. Data ini digunakan sebagai dasar pelatihan dan pengujian model TCN dalam melakukan forecasting harga saham untuk bulan selanjutnya di awal 2026.

Format data yang digunakan adalah data deret waktu (*time series*) dengan struktur kolom data:

1. Date, yang merupakan tanggal perdagangan,
2. Open, yang merupakan harga pembukaan,
3. High, yang merupakan harga tertinggi,
4. Low, yang merupakan harga terendah,
5. Close, yang merupakan harga penutupan,
6. Volume, yang merupakan jumlah saham yang diperdagangkan.

Tabel 3.1 Contoh Tabel Dataset

Tanggal	Open	High	Low	Close	Volume
02-01-2023	4.650	4.700	4.620	4.680	18.450.000
03-01-2023	4.680	4.720	4.660	4.700	21.300.000
...	...	...	...	...	...
05-01-2023	4.690	4.710	4.650	4.660	22.140.000

Namun hanya kolom close (harga penutupan) yang digunakan dalam penelitian ini sebagai input tunggal dalam model TCN, karena kolom ini dianggap paling representatif untuk menangkap dinamika harga saham, sebagaimana yang telah dilakukan pada penelitian sebelumnya (Switrayana et al., 2025; (Sungkowo, 2025; Hakim, 2021).

### 3.1.3 Alat Pengambilan Data

Pengambilan data dilakukan secara otomatis dengan bantuan library python *yfinance*, yang mempermudah penelitian ini untuk mengakses dan mengunduh data pasar dari Yahoo Finance ke dalam formata DataFrame. Library ini mendukung penyesuaian rentang waktu, frekuensi data (harian, mingguan, bulanan, atau tahunan), serta pemilihan simbol saham sesuai kebutuhan.

Proses ini dilakukan dalam lingkungan komputasi berbasis cloud dengan Google Collab, sehingga memungkinkan akses GPU dan kolaborasi secara daring. Data kemudian disimpan dalam format CSV dan selanjutnya diproses dengan pandas untuk seleksi dan pembersihan data.

### **3.1.4 Karakteristik Data**

Karakteristik data yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Jenis Data yang digunakan adalah Time series (data deret waktu),
2. Format Data yang digunakan adalah *Date, Open, High, Low, Close, Adj Close, dan Volume*,
3. Frekuensi data yang digunakan adalah harian (daily),
4. Rentang waktu yang dipilih adalah mulai dari tanggal 1 Januari 2018 – 30 Desember 2025,
5. Variabel utama yang digunakan adalah harga penutupan (*close*).

### **3.2. Teknik Pengumpulan Data**

Dalam penelitian ini pengumpulan data dilakukan secara otomatis dan terprogram menggunakan bahasa pemrograman Python dengan library *yfinance*. Metode ini dipilih untuk memastikan bahwa data yang diperoleh memiliki akurasi tinggi, minim kesalahan *input* manual, dan dapat direplikasi dengan langkah-langkah yang konsisten dari penelitian sebelumnya, sesuai dengan prinsip *reproducible research*.

Data yang dikumpulkan melalui library *yfinance* bertujuan untuk mengakses informasi pasar saham dari platform online Yahoo Finance secara langsung ke dalam lingkungan pemrograman Python. Pendekatan ini sangat relevan untuk

penelitian berbasis komputasi dan *artificial intelligence* karena memungkinkan integrasi data secara langsung ke dalam *pipeline preprocessing* dan pelatihan model.

### **3.3. Teknik Analisis Data**

Tahapan analisis data dalam riset ini dieksekusi secara sistematis dan terprogram berbasis pendekatan *Machine Learning*, dengan fokus utama pada penerapan arsitektur *Temporal Convolutional Network* (TCN). Rangkaian operasional komputasi ini dijalankan sepenuhnya menggunakan bahasa pemrograman Python di atas *environment* Google Colaboratory. Penggunaan platform tersebut memfasilitasi siklus pemrosesan secara komprehensif, mulai dari tahap integrasi data, komputasi numerik, pelatihan model (*model training*), hingga visualisasi luaran. Secara garis besar, alur analisis data ini diklasifikasikan ke dalam beberapa fase krusial, meliputi:

#### **3.3.1 Preprocessing Data**

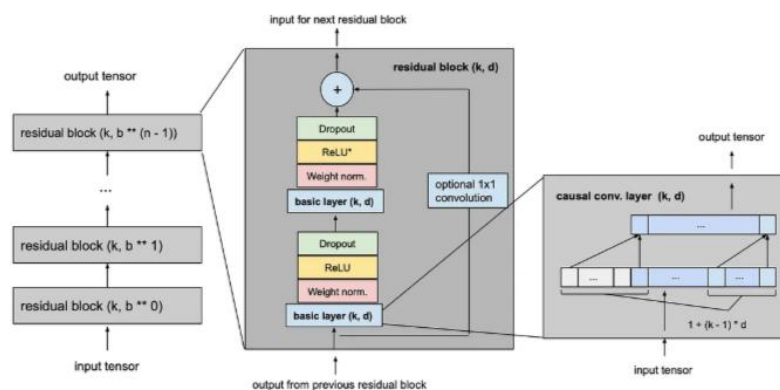
Preprocessing data dilaksanakan ketika data telah melalui proses Exploratory Data Analysis (EDA). Tahapan pra-pemrosesan (*preprocessing*) ini dilaksanakan guna mengondisikan dataset agar selaras dengan standar format *input* yang diwajibkan oleh arsitektur TCN. Langkah-langkah yang dilakukan anatara lain:

1. Pengambilan kolom Close sebagai variable utama.
2. Scalling Data (normalisasi) dengan metode Min-Max Scaling untuk mengubah skala nilai close ke rentang 0-1, guna mengoptimalkan model pembelajaran TCN dan menghindari dominasi nilai besar pada fungsi aktivasi.

3. Melakukan target shifting satu Langkah ke depan (*one-step ahead*) dengan rumus  $x(t) = y(t + 1)$ .
4. Melakukan sliding window dengan panjang 60 hari (60 timestep) data historis terakhir secara berurutan (*chronological sliding window*) untuk memforecasting harga untuk hari berikutnya.
5. Lalu melakukan data splitting untuk membagi-bagi data menjadi dua, yaitu data training dan data testing.

### 3.3.2 Arsitektur dan Pembentukan Model Temporal Convolutional Network (TCN)

Arsitektur model *Temporal Convolutional Network* (TCN) dalam studi ini dirancang secara khusus untuk mengakomodasi kompleksitas data runtun waktu (*time series*) pada pergerakan saham. Struktur jaringan yang dibangun bukan sekadar tumpukan lapisan (*layer*) komputasi biasa, melainkan sebuah sistem terintegrasi yang secara teoretis mumpuni dalam mengekstraksi, mempelajari, serta mempertahankan memori terkait pola historis dalam rentang waktu yang panjang.



Gambar 3.2 Arsitektur Akhir TCN

Temporal Convolutional Network (TCN) memiliki tiga ciri utama, yaitu ciri yang pertama adalah *causal convolutional* yang mencegah terjadinya *data leakage*. *Causal convolutional* memastikan bahwa prediksi pada waktu  $t$  hanya bergantung pada elemen input pada waktu  $t$  dan waktu-waktu sebelumnya, tanpa melibatkan informasi dari masa depan.

Ciri kedua adalah *dilated convolutional* yang merupakan operasi konvolusi di mana filter diterapkan pada area input yang lebih luas dengan cara melompati input dengan interval tertentu. Berikut adalah rumus matematis standar dari 1-D *dilated convolutional*:

$$y(t) = \sum_{i=0}^{k-1} f(i) \cdot x(t - d \cdot i)$$

Dan ciri yang ketiga adalah *residual connection* yang memungkinkan pembangunan jaringan yang sangat dalam (*deep networks*) dengan menjaga keutuhan informasi data asli agar tidak hilang atau rusak saat melewati proses komputasi yang panjang di dalam jaringan yang dalam (*deep neural network*), dengan cara menghubungkan input antar layer secara langsung.

Model TCN dibangun dengan menggunakan library Keras dan TensorFlow. Arsitektur yang digunakan terdiri dari:

1. Tiga Block TCN
2. Droput layer (0.2) di antara block untuk menghindari overfitting.
3. Optimizer yang digunakan adalah *Adaptive Moment Estimation* (Adam), karena adaptif terhadap data time series

Dalam penelitian ini, setiap *residual block* terdiri dari lapisan Conv1D, fungsi aktivasi ReLU, dan Dropout layer untuk mengurangi risiko overfitting.

Output dari blok terakhir kemudian diteruskan ke lapisan dense sebagai lapisan output untuk menghasilkan satu nilai prediksi harga saham (close). Model dilatih selama 80 epoch dengan ukuran batch 32, dan menggunakan *early stopping* berbasis validation loss untuk menghentikan pelatihan secara otomatis jika terjadi peningkatan performa.

Validasi dilakukan dengan memisahkan 10% data training sebagai validation set. Validation set berfungsi sebagai data pemantau yang tidak digunakan untuk melatih model, melainkan untuk mengukur performa model pada data yang belum pernah dilihatnya di setiap akhir epoch.

Performa pada validation set ini dipantau dengan mekanisme *early stopping*. Teknik ini akan menghentikan proses pelatihan secara otomatis jika tidak ada peningkatan performa (penurunan nilai validation loss) selama beberapa epoch berturut-turut. Hal ini bertujuan untuk mencegah overfitting dan memastikan model yang dihasilkan merupakan versi dengan kinerja paling optimal.

#### **3.4. Prosedur Pengujian dan Validasi**

Prosedur pengujian dan validasi dilakukan untuk mengevaluasi kemampuan model Temporal Convolutional Network (TCN) dalam melakukan prediksi harga penutupan saham satu langkah ke depan. Pengujian ini bertujuan untuk memastikan model tidak hanya mampu mempelajari data latih, tetapi juga memiliki kemampuan generalisasi yang baik ketika diterapkan pada data yang belum pernah dilihat sebelumnya.

Dataset historis saham periode 1 Januari 2018 hingga 30 Desember 2025 dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji

(*testing data*). Data testing diambil dari perhitungan rumus slovin, dan data training didapatkan dari pengurangan jumlah data dengan hasil rumus slovin.

Berikut adalah perhitungannya:

$$n = \frac{N}{1 + Ne^2}$$

Dimana,

N: ukuran populasi (total data yang diambil)

n : ukuran sampel (dalam kasus ini adalah data testing)

e : batas toleransi kesalahan

Jumlah data yang digunakan dalam penelitian ini adalah 1966 (2018-01-01 hingga 2025-12-31). Berdasarkan perhitungan rumus slovin tersebut didapatkan hasil:

$$n = \frac{1966}{1 + 1966(0,05)^2}$$

$$n = \frac{1966}{1 + 4,915}$$

$$n = \frac{1966}{5,915}$$

$$n = 332,4$$

$$n \approx 332$$

Berdasarkan hasil perhitungan rumus slovin tersebut didapat hasil data testing sebesar 332. Data training didapat dari pengurangan jumlah data dengan data testing, yaitu:

$$N - n$$

$$1966 - 332 = 1634$$

Berdasarkan perhitungan tersebut didapatkan hasil data training sebesar 1634.

### **3.4.1 Prosedur Pelatihan Model**

Model TCN dilatih menggunakan data latih dengan parameter yang telah ditentukan, yaitu batch size sebesar 32 dan jumlah epoch maksimum sebanyak 80. Selama proses pelatihan, sebagian data latih digunakan sebagai data validasi untuk memantau performa model pada setiap epoch.

Mekanisme *early stopping* diterapkan untuk mencegah overfitting dengan memonitor nilai *validation loss*. Proses pelatihan akan dihentikan secara otomatis apabila tidak terjadi peningkatan performa pada data validasi dalam beberapa epoch berturut-turut. Model terbaik kemudian disimpan berdasarkan nilai *validation loss* terendah.

### **3.4.2 Prosedur Pengujian Model**

Setelah proses pelatihan selesai, model diuji menggunakan data uji yang tidak terlibat dalam proses pembelajaran. Pada tahap ini, model menghasilkan nilai prediksi harga penutupan saham untuk setiap data uji berdasarkan data historis sebelumnya.

Hasil prediksi kemudian dikembalikan ke skala asli menggunakan *inverse transform* dari metode normalisasi yang digunakan pada tahap preprocessing. Hal ini bertujuan agar nilai prediksi dapat dibandingkan secara langsung dengan data aktual.

### **3.4.3 Validasi Visual Hasil Prediksi**

Selain evaluasi numerik, dilakukan pula validasi visual melalui grafik perbandingan antara harga penutupan aktual dan hasil prediksi model.

Visualisasi ini digunakan untuk menilai kemampuan model dalam mengikuti pola pergerakan harga saham secara umum, khususnya dalam menangkap tren dan perubahan arah harga.

Analisis visual ini membantu mengidentifikasi kondisi di mana model bekerja dengan baik maupun kondisi di mana prediksi mengalami penyimpangan, seperti pada periode volatilitas pasar yang tinggi.

#### **3.4.4 Interpretasi Hasil**

Proses pelatihan model Temporal Convolutional Network (TCN) menunjukkan pola konvergensi yang stabil. Nilai *Loss* pada *data training* dan *data validation* mengalami penurunan yang stabil seiring bertambahnya jumlah epoch, menunjukkan bahwa model berhasil mempelajari pola data historis harga saham tanpa mengalami overfitting.

Penerapan *early stopping* berdasarkan nilai *validation loss* berperan penting dalam menghentikan proses pelatihan pada saat performa model telah mencapai kondisi optimal. Hal ini menunjukkan bahwa model tidak dipaksa untuk terus belajar ketika peningkatan performa sudah tidak signifikan, sehingga stabilitas dan kemampuan generalisasi model dapat terjaga.

Penggunaan window size sebesar 60 hari memberikan dampak yang signifikan terhadap karakteristik hasil prediksi. Dengan rentang data historis 60 *timestep*, model mampu menangkap pola pergerakan harga saham jangka menengah, sehingga prediksi yang dihasilkan cenderung lebih stabil dan tidak terlalu sensitif terhadap fluktuasi harga harian yang bersifat noise.

Pendekatan ini sesuai dengan karakteristik Temporal Convolutional Network yang memanfaatkan *dilated convolution* untuk menangkap

ketergantungan jangka panjang. Dengan demikian, window size 60 memungkinkan model memaksimalkan keunggulan arsitektur TCN dalam memodelkan data deret waktu dengan konteks historis yang luas.

### **3.5. Arsitektur Sistem Berbasis Web**

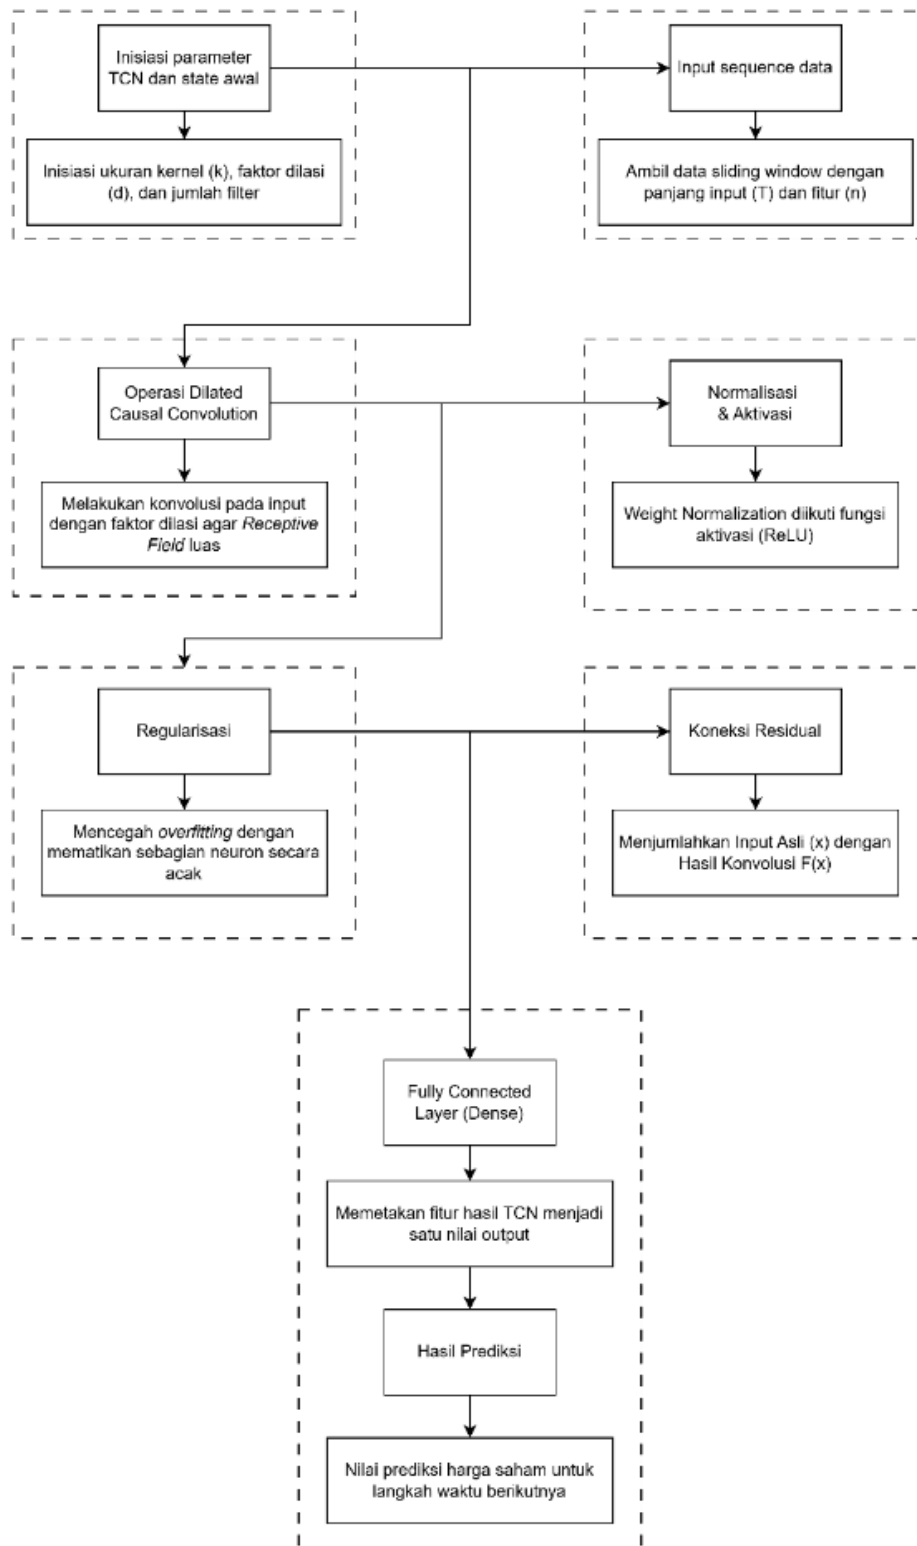
Sistem prediksi harga saham yang dikembangkan dalam penelitian ini merupakan sistem berbasis web yang mengintegrasikan model *Machine Learning* dengan antarmuka pengguna (*user interface*) berbasis Streamlit. Sistem dirancang dengan arsitektur sederhana namun efektif untuk mendukung proses prediksi harga saham satu hari ke depan menggunakan model Temporal Convolutional Network (TCN).

Arsitektur sistem dibangun dengan pendekatan *single-server architecture*, di mana proses pengolahan data, pemuatan model, dan prediksi dilakukan pada sisi server, sedangkan pengguna berinteraksi dengan sistem melalui antarmuka web. Pendekatan ini dipilih untuk menjaga efisiensi sistem serta memastikan konsistensi hasil prediksi.

Alur data dalam sistem prediksi harga saham ini dimulai dari pengambilan data historis saham yang kemudian diproses melalui modul preprocessing. Data yang telah diproses selanjutnya digunakan sebagai input ke dalam model TCN untuk menghasilkan prediksi harga penutupan saham satu hari ke depan.

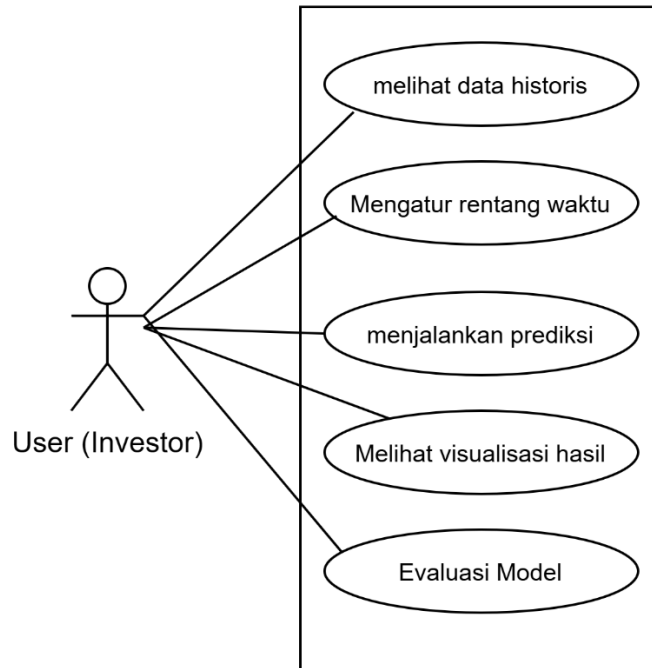
Hasil prediksi yang diperoleh dari model kemudian dikembalikan ke skala aslinya dan ditampilkan kepada pengguna melalui antarmuka web. Dengan alur ini, sistem mampu memberikan hasil prediksi secara langsung tanpa memerlukan proses komputasi yang kompleks di sisi pengguna.

### 3.6. Diagram Blok Sistem



Gambar 3.3 Diagram Blok Sistem

### 3.7. Unified Modelling Language (UML)



Gambar 3.4 Use Case Diagram

### 3.8. Pengujian Sistem

Fungsionalitas web prediksi harga saham pada penelitian ini akan diuji dengan metode black box testing. Metode *Black Box Testing* merupakan metode pengujian perangkat lunak yang berfokus pada pengujian fungsi sistem berdasarkan input dan output yang dihasilkan. Pada metode ini, penguji tidak perlu mengetahui detail implementasi internal sistem, melainkan hanya memeriksa apakah sistem memberikan keluaran yang sesuai dengan masukan yang diberikan.

Metode *Black Box Testing* merupakan metode pengujian perangkat lunak yang berfokus pada pengujian fungsi sistem berdasarkan input dan output yang dihasilkan. Pada metode ini, penguji tidak perlu mengetahui detail implementasi internal sistem, melainkan hanya memeriksa apakah sistem memberikan keluaran yang sesuai dengan masukan yang diberikan. Metode ini dipilih karena sesuai

dengan tujuan pengujian sistem, yaitu untuk memastikan bahwa seluruh fitur sistem dapat digunakan dengan baik oleh pengguna dan menghasilkan output yang benar sesuai dengan fungsinya.

Ruang lingkup pengujian sistem pada penelitian ini meliputi pengujian terhadap fungsi-fungsi utama sistem prediksi harga saham berbasis web, yaitu:

1. Pengambilan dan penampilan data harga saham.
2. Proses preprocessing data secara otomatis oleh sistem.
3. Proses pemuatan model.
4. Proses prediksi harga penutupan saham satu hari ke depan.
5. Penyajian hasil prediksi dan visualisasi grafik pada antarmuka web.

Pengujian tidak mencakup pengujian performa sistem secara mendalam maupun pengujian keamanan, karena fokus penelitian berada pada pengembangan dan evaluasi model *Machine Learning*.

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1. Deskripsi Data

Pada penelitian ini, data yang digunakan bersifat sekunder, kuantitatif, dan berbentuk data *time series*. Sumber data utama yang digunakan adalah *Yahoo Finance*, yaitu *platform* yang berisikan sumber data historis yang cocok untuk analisis dan *forecasting* harga saham dikarenakan data yang lengkap dan kemudahan dalam mengakses secara otomatis melalui antarmuka pemrograman (Switrayana et al., 2025). Berdasarkan sifatnya data harga saham bersifat dinamis dan dapat berubah secara *real time*. Hal ini disebabkan dari berbagai faktor, sehingga membentuk pola deret waktu yang kompleks (Janiesch et al., 2021).

Proses pengumpulan data dilakukan secara terprogram menggunakan library python *yfinance*. Penggunaan library ini mempermudah integrasi langsung data ke dalam *workflow* sistem *Machine Learning* yang akan dibuat pada penelitian ini tanpa memerlukan langkah-langkah manual. Data yang menjadi objek dalam penelitian ini adalah harga saham harian PT Bank Rakyat Indonesia Tbk (BBRI).

Periode data yang digunakan mencakup rentang waktu mulai dari 1 Januari 2018 hingga 30 Desember 2025, dengan total 1966 baris data harga saham harian. Setiap baris data terdiri dari lima atribut, yaitu harga penutupan (*Close*), harga tertinggi (*High*), harga terendah (*Low*), harga pembukaan (*Open*), dan volume perdagangan (*Volume*). Namun, dalam penelitian ini atribut yang digunakan hanya berfokus pada harga penutupan (*Close*), dikarenakan atribut ini dianggap paling umum dan cukup representatif dalam mencerminkan keadaan pasar saham pada

akhir sesi perdagangan (Switrayana et al., 2025). Implementasi pengambilan data dapat dilihat pada Gambar 4.1.

```
#install library yfinance
!pip install yfinance

#import library
import yfinance as yf

#kode saham BBRI
ticker = "BBRI.JK"

#tentukan periode data
start_date = '2018-01-01'
end_date = '2025-12-31'

#download data saham
df = yf.download(ticker, start=start_date, end=end_date, interval="1d", auto_adjust=True)

# menampilkan data
df.head()
```

Gambar 4.1 Contoh Kode Pengambilan Data Dengan yfinance

#### 4.2. *Exploratory Data Analysis (EDA)*

Dikarenakan data yang digunakan dalam penelitian ini sudah tersusun dengan rapi dan baik maka proses EDA tidak terlalu banyak dilakukan. Proses EDA dilakukan untuk mengetahui karakteristik data yang digunakan sebelum nantinya ke tahap selanjutnya (*preprocessing data*). Proses EDA juga dilakukan untuk melihat ada atau tidaknya pola dan trend, missing value, dan mengetahui jumlah dan rentang waktu data yang digunakan. Implementasi proses *Exploratory Data Analysis (EDA)* dapat dilihat pada Gambar 4.2.

```
# mengetahui kolom dan baris, jumlah missing value, dan rentang waktu
df.info()
df.isnull().sum()
df.index.min(), df.index.max()


# melihat pola dan Trend
df['Close'].plot()
```

Gambar 4.2 *Exploratory Data Analysis (EDA)* Pada Data Saham

Berdasarkan proses *Exploratory Data Analysis* (EDA) didapat beberapa *insight*, yaitu jumlah baris data 1966 dengan 5 kolom dengan kolom *date* menjadi indeks data tersebut. Selanjutnya, tipe data yang terdapat pada kolom *close*, *high*, *low*, dan *open* adalah tipe data *float64*, sedangkan kolom *volume* menggunakan tipe data *int64*, selanjutnya tidak terdapat data yang kosong. Serta rentang waktu data yang digunakan mulai dari 1 Januari 2018 hingga 30 Desember 2025. Kemudian data divisualisasikan untuk mengetahui pola atau trend yang ada. Hasil dari proses *Exploratory Data Analysis* (EDA) dapat dilihat pada Gambar 4.3 dan Gambar 4.4.

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 1966 entries, 2018-01-01 to 2025-12-30
Data columns (total 5 columns):
#   Column              Non-Null Count  Dtype
---  ---              -
0   (Close, BBRI.JK)    1966 non-null   float64
1   (High, BBRI.JK)    1966 non-null   float64
2   (Low, BBRI.JK)     1966 non-null   float64
3   (Open, BBRI.JK)    1966 non-null   float64
4   (Volume, BBRI.JK)  1966 non-null   int64
dtypes: float64(4), int64(1)
memory usage: 92.2 KB
(Timestamp('2018-01-01 00:00:00'), Timestamp('2025-12-30 00:00:00'))
```

Gambar 4.3 Hasil *Exploratory Data Analysis* (EDA)



Gambar 4.4 Visualisasi Harga Saham Penutupan (Close)

### 4.3. *Preprocessing Data*

Menindaklanjuti tahapan *Exploratory Data Analysis* (EDA), penelitian ini beralih pada fase *preprocessing* data guna mentransformasi dataset menjadi format yang lebih bersih, terstruktur, dan optimal sebelum diumpankan ke dalam model TCN. Prosedur pembersihan ini sangat krusial untuk menjamin bahwa data *input* terbebas dari *noise* (derau) dan memiliki standardisasi skala yang seragam, yang mana hal tersebut akan berkontribusi secara langsung terhadap peningkatan akurasi hasil prediksi.

Langkah pertama dalam proses *processing data* adalah mengambil kolom *Close*, pembagian *data training* dan *data set*, dan *Scalling Data* (normalisasi). Pemilihan kolom *Close* didasari dari studi literatur sebelumnya yang menyatakan bahwa harga penutupan (*Close*) merupakan indikator yang stabil dan representatif dalam mencerminkan consensus pasar pada akhir sesi perdagangan (Switrayana et al., 2025).

Selanjutnya, proses *scalling data* (normalisasi) yang mengubah skala data training ke dalam rentang [0, 1] menggunakan metode *MinMaxScaler* pada class *standartScaler* yang berada pada library *scikit-learn* (*sklearn*). Tujuan dari proses normalisasi ini adalah untuk mencegah fitur dengan nilai besar mendominasi proses training model, menstabilkan gradien selama proses training, dan mempercepat proses konvergensi. Normalisasi data turut dilakukan untuk data testing untuk menyeragamkan data. Proses normalisasi ini terbukti dapat meningkatkan stabilitas dan akurasi *forecasting* secara signifikan (Switrayana et al., 2025). Tabel 4.1 menunjukkan perbandingan beberapa baris data saham sebelum dan sesudah *scalling data* (normalisasi).

Tabel 4.1 Perbandingan Data Sebelum dan Sesudah Normalisasi

Date	Close	Close_Normalized
01/01/2018 00:00	220.699.560.546.875	0.18267184592262953
02/01/2018 00:00	22.009.326.171.875	0.1811913828752323
03/01/2018 00:00	2.188.806.396.484.370	0.17823039716607636
04/01/2018 00:00	21.524.267.578.125	0.16934720158116368
...	...	...
15/01/2018 00:00	21.524.267.578.125	0.16934720158116368
16/01/2018 00:00	2.188.806.396.484.370	0.17823039716607636
17/01/2018 00:00	22.009.326.171.875	0.1811913828752323
18/01/2018 00:00	2.194.869.384.765.620	0.1797108602134737

Selanjutnya adalah target shifting, target shifting dilakukan untuk membentuk skema supervised learning, dimana kolom target (y) digeser satu periode ke depan sehingga model dapat mempelajari model pola historis untuk memprediksi nilai periode berikutnya (prediksi hari besok). Tahap terakhir adalah windowing, data yang telah dinormalisasikan diubah strukturnya menggunakan sliding window dengan time step selama 60 hari. Maksudnya, 60 hari data historis digunakan sebagai fitur masukan (X) untuk memprediksi harga pada hari ke-61 sebagai target keluaran (y). Proses ini menghasilkan dataset akhir yang siap digunakan untuk pelatihan dan pengujian model.

#### 4.4. Implementasi dan Arsitektur Model TCN

Pada penelitian ini, model Temporal Convolutional Network (TCN) diimplementasikan menggunakan bahasa pemrograman Python dengan memanfaatkan beberapa *library* dan *framework*. TensorFlow dan keras sebagai

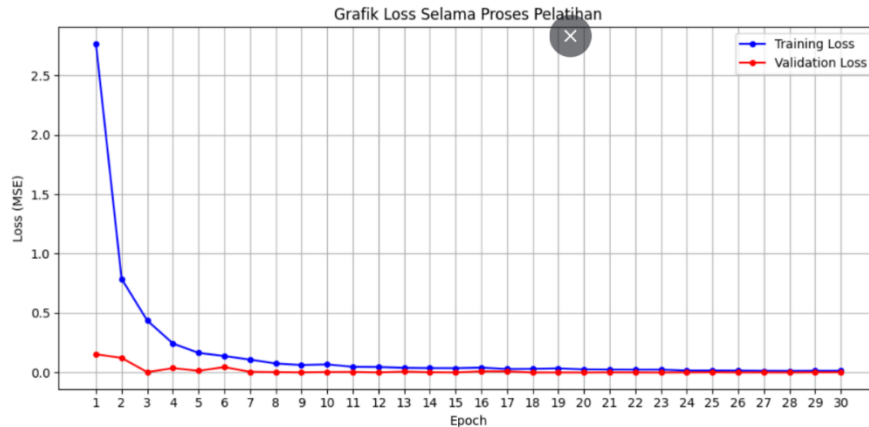
framework deep learning, keras-tcn sebagai implementasi arsitektur TCN, serta scikit-learn untuk proses preprocessing data. Pengembangan model sendiri dilakukan pada lingkungan Google Colaboratory dengan spesifikasi runtime Python 3.12.

Model TCN yang dibangun pada penelitian ini terdiri dari satu blok TCN dan satu lapisan Dense sebagai lapisan output. Di dalam blok TCN terdapat 6 *residual block* yang disusun secara bertingkat sesuai dengan konfigurasi dilasi [1, 2, 4, 8, 16, 32]. Ringkasan arsitektur model TCN dalam penelitian ini dapat dilihat pada tabel 4.2 berikut ini:

Tabel 4.2 Ringkasan Arsitektur Model TCN

Komponen	Detail
Input	(30, 1)
Jumlah Residual Block	6
Dilasi per Block	[1, 2, 4, 8, 16, 32]
Conv1D per Block	2 lapisan
Total Conv1D	12 lapisan
Filters	64
Kernel Size	3
Aktivasi	ReLU
Dropout	0.2
Output Layer	Dense (1)

Setelah model dibangun, model dilatih menggunakan data training yang telah dibagi pada tahap preprocessing data sebelumnya. Proses pelatihan model menerapkan mekanisme *Early Stopping*, yang menghentikan pelatihan secara otomatis jika tidak ada peningkatan performa pada data validasi setelah 10 *epoch* berturut-turut. Gambar 4.5 menampilkan grafik *loss* selama proses pelatihan.



Gambar 4.5 Grafik Loss Proses Pelatihan dan Validasi Model TCN

Berdasarkan Gambar 4.5, dapat diamati bahwa kurva *training loss* (garis biru) menunjukkan trend penurunan yang konsisten, menandakan bahwa model berhasil belajar dari data training. Sementara itu, kurva *validation loss* (garis merah) juga menunjukkan tren penurunan dan tetap stabil tanpa meningkat secara signifikan. Hal ini mengindikasikan bahwa tidak ada overfitting, proses pelatihan juga berhenti secara otomatis pada epoch ke-30, di mana model mencapai titik konvergensi yang optimal.

#### 4.5. Hasil Evaluasi Kinerja Model

Setelah model TCN selesai dibangun dan dilatih, tahap selanjutnya adalah melakukan evaluasi kinerja secara menyeluruh. Evaluasi ini merupakan langkah krusial untuk mengukur kemampuan generalisasi model, yaitu kemampuannya dalam *forecasting* yang akurat terhadap data baru yang tidak pernah dilihat sebelumnya (*unseen data*).

##### 4.5.1. Hasil Evaluasi Kuantitatif

Evaluasi kuantitatif bertujuan untuk memberikan ukuran numerik yang objektif terhadap tingkat kesalahan prediksi model. Dalam penelitian ini, digunakan empat matrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Root Mean Squared*

*Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil perhitungan keempat metrik tersebut dapat dilihat pada Tabel 4.3.

Tabel 4.3 Hasil Evaluasi Kuantitatif Model TCN

Metrik Evaluasi Kuantitatif	
<i>Mean Absolute Error</i> (MAE)	88,99
<i>Root Mean Squared Error</i> (RMSE)	118,76
<i>Mean Absolute Percentage Error</i> (MAPE)	2,72 %

Berdasarkan hasil evaluasi kuantitatif model TCN pada Tabel 4.3, model TCN menghasilkan hasil metrik evaluasi Mean Absolute Error (MAE) sebesar 88,99. Nilai MAE ini mengindikasikan bahwa secara rata-rata, prediksi harga saham yang dihasilkan model TCN memiliki selisih absolut sebesar Rp88,99 dari harga aktualnya. Artinya, model rata-rata meleset sekitar Rp89 dari harga sebenarnya dalam setiap prediksi.


Root Mean Squared Error (RMSE) yang dihasilkan model TCN ini adalah 118,76. Nilai RMSE yang lebih besar dibandingkan MAE (88,99) mengindikasikan adanya beberapa prediksi dengan error yang cukup besar, namun perbedaan yang relatif kecil menunjukkan bahwa error prediksi terdistribusi cukup merata tanpa banyak outlier ekstrem.

Nilai Mean Absolute Percentage Error (MAPE) sebesar 2,72% menjadi metrik yang paling representatif untuk menilai akurasi model prediksi harga saham. Nilai MAPE 2,72% menunjukkan bahwa rata-rata persentase kesalahan prediksi hanya sebesar 2,72% dari harga aktual. Berdasarkan standar interpretasi MAPE, nilai dibawah 10% dikategorikan “sangat akurat”. Dengan demikian, model TCN

yang dibangun memiliki tingkat akurasi yang sangat tinggi dalam memprediksi harga saham.

#### 4.5.2. Visualisasi Hasil Prediksi

Selain evaluasi kuantitatif, visualisasi hasil prediksi juga penting untuk memahami gambaran intuitif mengenai kemampuan model dalam menangkap tren pergerakan harga saham. Gambar 4.6 menampilkan visualisasi perbandingan antara kurva pergerakan harga saham aktual (garis biru), dan kurva hasil prediksi model TCN pada rentang waktu data testing (garis putus-putus warna merah).



Gambar 4.6 Visualisasi Perbandingan Harga Aktual Dengan Prediksi TCN

Berdasarkan visualisasi Gambar 4.6 secara keseluruhan kurva prediksi (garis putus-putus warna merah) mengikuti pola pergerakan kurva harga aktual (garis biru) dengan sangat baik. Kedua garis menunjukkan tren dan fluktuasi yang hampir identik, mengindikasikan bahwa model TCN berhasil menangkap pola pergerakan harga saham BBRI dengan akurat.

Pada rentang waktu Nov 2024, Sep 2025, Oct 2025, dan Nov 2025, prediksi model hampir berhimpit dengan harga aktual. Hal ini menunjukkan bahwa model sangat efektif dalam memprediksi pergerakan harga pada kondisi pasar yang relatif stabil dengan fluktuasi normal.

Pada periode awal (Juni – Agustus 2024), model TCN menunjukkan kemampuan mengikuti tren pergerakan harga dengan cukup baik. Namun terlihat adanya lag (keterlambatan respons) pada beberapa titik pergerakan harga saham, di mana harga prediksi sedikit tertinggal atau mendahului harga aktual. Pada periode September – Oktober 2024 harga aktual mencatat harga tertinggi sekitar Rp4.800 – Rp4.850. Model TCN berhasil menangkap tren kenaikan ini dengan baik, meskipun prediksi sedikit lebih rendah dari puncak harga aktual.

Keterbatasan model terlihat pada kondisi pergerakan harga yang ekstrem dan tiba-tiba (Maret 2025). Pada kondisi ini model cenderung underestimate dikarenakan pola tersebut tidak cukup terwakili dalam data historis pelatihan. Secara keseluruhan, kedua garis menunjukkan pola yang sejalan (*co-movement*), yang mengindikasikan bahwa model TCN memiliki kemampuan prediksi yang cukup baik untuk data time-series.

#### **4.5.3. Hasil Prediksi Harga Hari Berikutnya**

Tujuan akhir penelitian ini adalah memprediksi harga saham untuk hari berikutnya, yaitu satu hari setelah data terakhir pada dataset. Proses prediksi dilakukan dengan memberikan 60 hari data harga penutupan terakhir sebagai *input* model untuk menghasilkan estimasi harga saham pada hari selanjutnya. Berdasarkan hasil pengujian, diperoleh harga penutupan saham pada tanggal 2 Januari 2026 sebesar Rp3.598,50. Sementara itu, harga aktual saham BBRI pada tanggal yang sama adalah Rp3.640, sehingga terdapat selisih sebesar Rp41,50. Grafik harga aktual saham BBRI pada tanggal 2 Januari 2026 dapat dilihat pada Gambar 4.7.



Gambar 4.7 Grafik Harga Aktual Saham BBRI

#### 4.5.4. Validasi Hasil Dengan Teori dan Penelitian Terdahulu

Temuan dalam penelitian ini konsisten dengan studi sebelumnya yang telah membuktikan efektivitas model prediksi TCN dalam domain forecasting keuangan. Secara spesifik, performa model dapat dibandingkan dengan penelitian yang dilakukan oleh Syahriel et al. (2025), yang juga menggunakan model TCN pada data saham industri perbankan dan melaporkan nilai RMSE sebesar 167 dan nilai MAPE 2,58.

Pada penelitian ini, model yang dibangun menghasilkan nilai RMSE sebesar 118,76 dan nilai MAPE sebesar 2,72%. Jika dibandingkan dengan penelitian tersebut, nilai evaluasi matrik yang diperoleh dalam penelitian ini lebih tinggi, yang menunjukkan model yang dibangun dalam penelitian ini memiliki tingkat akurasi yang lebih baik dalam memprediksi pergerakan harga saham.

#### 4.5.5. Implikasi dan Keterbatasan Penelitian

Dari sisi implementasi, hasil dari penelitian ini menunjukkan bahwa model TCN berpotensi dimanfaatkan sebagai instrument pendukung dalam proses pengambilan keputusan investasi. Model tersebut mampu memberikan estimasi arah pergerakan harga saham sehingga investor dapat memperoleh gambaran

mengenai kecenderungan tren di masa mendatang. Selain itu, hasil prediksi berbasis data yang dihasilkan model dapat digunakan sebagai pelengkap dalam analisis fundamental dan teknikal.

Model yang dikembangkan hanya memanfaatkan satu variabel masukan, yaitu harga penutupan harian (*Close*), tanpa memasukkan faktor-faktor lain yang secara teoritis dapat memengaruhi pergerakan harga saham, seperti indikator makroekonomi, sentimen pasar, atau *news*. Selain itu, pengujian performa model dilakukan berdasarkan data historis sehingga belum sepenuhnya merepresentasikan kondisi pasar yang dinamis di masa mendatang. Keterbatasan tersebut dapat menjadi dasar bagi penelitian selanjutnya untuk mengembangkan model dengan variabel yang lebih beragam serta pendekatan evaluasi yang lebih komprehensif.

#### **4.6. Implementasi Aplikasi Prediksi Harga Saham**

Sebagai upaya untuk menghubungkan model *Machine Learning* dengan pengguna non-teknis, seperti investor, penelitian ini turut merealisasikan model ke dalam sebuah aplikasi berbasis web. Implementasi ini dirancang agar hasil prediksi dapat diakses melalui tampilan antarmuka yang intuitif dan mudah digunakan.

Pengembangan antarmuka ini bertujuan untuk menyajikan kemampuan prediktif model dalam bentuk yang lebih aplikatif, sehingga pengguna dapat memanfaatkan fitur yang tersedia tanpa harus memiliki pemahaman mendalam terkait pemrograman ataupun konsep *Machine Learning*. Dengan demikian, model yang dibangun tidak hanya berhenti pada tahap eksperimen, tetapi juga memiliki nilai guna secara praktis.

Antarmuka aplikasi dikembangkan menggunakan Streamlit, yaitu sebuah framework open source berbasis Python yang dirancang untuk mempermudah

pembuatan aplikasi web untuk bidang data science dan Machine Learning. Pemilihan Streamlit didasarkan pada kemampuannya dalam mentransformasikan skrip analisis data menjadi aplikasi web interaktif secara cepat dan praktis.

Pada aplikasi yang dirancang, pengguna diberikan keleluasaan untuk mengatur parameter prediksi melalui panel navigasi di bagian samping (sidebar).

Parameter yang dapat ditentukan meliputi:

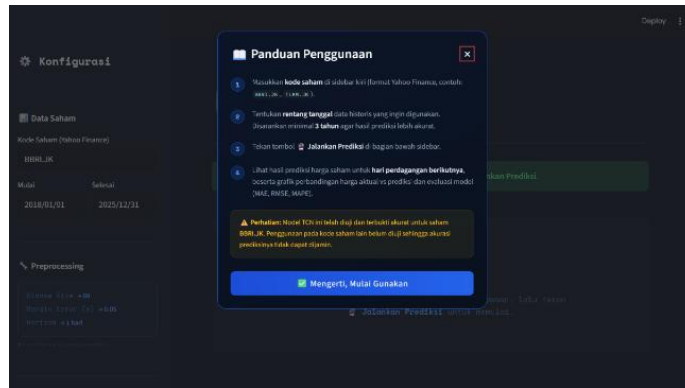
- a) kode saham (ticker) yang diambil dari data Yahoo Finance, serta
- b) Rentang tanggal awal dan akhir yang digunakan sebagai periode data historis dalam proses pelatihan dan pengujian model.

Setelah tombol “Mulai Prediksi” dipilih, sistem akan mengeksekusi seluruh tahapan secara otomatis di sisi backend, mulai dari proses pengambilan data, tahap *preprocessing data*, pelatihan model TCN, hingga evaluasi performa model. Selain itu, aplikasi dilengkapi dengan fitur validasi input untuk memastikan jumlah data yang tersedia memenuhi kebutuhan time step sebesar 60 hari. Apabila rentang waktu yang dipilih tidak mencukupi, sistem akan menampilkan notifikasi peringatan guna mencegah terjadinya kesalahan dalam proses komputasi. Hasil akhir yang ditampilkan kepada pengguna meliputi:

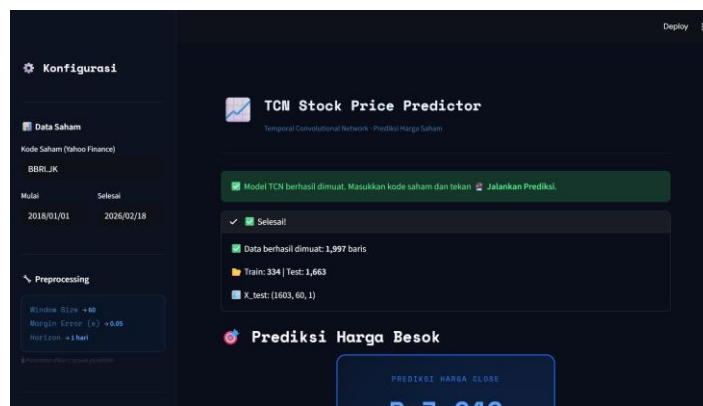
- a) Grafik Visual: Perbandingan antara harga saham aktual dengan harga saham yang diprediksi oleh model.
- b) Harga prediksi di hari berikutnya
- c) Tabel Evaluasi Matriks: Ringkasan performa model yang menyajikan nilai MAE, RMSE, dan MAPE.

Implementasi ini menunjukkan bagaimana model prediksi harga saham yang kompleks dapat disajikan dalam bentuk alat yang praktis dan dapat diakses oleh

banyak kalangan. Berikut tampilan awal saat pengguna membuka sistem prediksi harga saham yang dapat dilihat pada Gambar 4.8.




Gambar 4.8 Tampilan Awal Aplikasi



Gambar 4.9 Tampilan Aplikasi Melatih Model



Gambar 4.10 Tampilan Hasil Prediksi Harga Untuk Hari Berikutnya



Gambar 4.11 Tampilan Hasil Evaluasi Matriks Model



Gambar 4.12 Tampilan Grafik Perbandingan Harga Aktual Dengan Harga Prediksi

Pada grafik perbandingan harga aktual dengan harga prediksi yang ditampilkan sistem (Gambar 4.12) memiliki tampilan yang interaktif. Terdapat fitur Hover, dimana saat user arahkan kursor ke garis grafik, akan muncul informasi tanggal dan harga (aktual & prediksi) secara bersamaan dalam satu tooltip. Serta terdapat toolbar pada pojok kanan atas yang memungkinkan pengguna download grafik, zoom, menggeser grafik, dan reset tampilan grafik. Fitur ini pastinya memberikan pengguna pengalaman menggunakan sistem yang lebih baik.

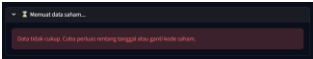
#### 4.7. Hasil Black Box Testing Sistem

Setelah sistem prediksi harga saham dalam penelitian ini yang telah dibangun oleh penulis selesai, penulis turut melakukan testing fungsi-fungsi (fitur) yang terdapat pada aplikasi web. Pada penelitian ini, penulis melakukan testing dengan

metode Black Box testing. Hal-hal yang diujikan dan hasil testing dapat dilihat pada Tabel 4.4 berikut ini:

Tabel 4.4 Hasil Black Box Testing

No	Fitur yang Diuji	Skenario Pengujian	Output yang Diharapkan	Output yang Dihasilkan	Status
1	Popup Panduan	Aplikasi pertama kali dibuka oleh pengguna	Popup panduan penggunaan muncul secara otomatis		<b>Berhasil</b>
2	Popup Panduan	Pengguna menekan tombol X di pojok kanan atas popup	Popup tertutup dan aplikasi dapat digunakan		<b>Berhasil</b>
3	Popup Panduan	Pengguna menekan tombol 'Mengerti, Mulai Gunakan'	Popup tertutup dan aplikasi dapat digunakan		<b>Berhasil</b>
4	Pemuatan Model TCN	Sistem dijalankan dengan file tcn_model.keras tersedia	Model TCN berhasil dimuat dan siap digunakan		<b>Berhasil</b>

5	Input Data Saham	Kode saham valid (BBRI.JK) dan rentang tanggal normal diinput	Data historis saham berhasil dimuat		Berhasil
6	Input Data Saham	Kode saham tidak valid (XXXXX.JK) diinput	Muncul pesan error bahwa data tidak ditemukan		Berhasil
7	Input Data Saham	Rentang tanggal terlalu sempit (kurang dari 3 bulan) diinput	Muncul pesan bahwa data tidak cukup untuk diproses		Berhasil
8	Preprocessing Data	Data valid diinput dan tombol prediksi ditekan	Data berhasil diproses (scaling, windowing) tanpa error		Berhasil
9	Prediksi Harga	Tombol Jalankan Prediksi ditekan dengan input valid	Nilai prediksi harga saham untuk hari berikutnya muncul		Berhasil

10	Prediksi Harga	Rentang tanggal diubah lalu prediksi dijalankan ulang	Nilai prediksi berubah sesuai data baru yang diinput		Berhasil
11	Informasi Tanggal Prediksi	Prediksi selesai dijalankan	Ditampilkan tanggal data terakhir dan tanggal hari perdagangan berikutnya		Berhasil
12	Evaluasi Model	Prediksi selesai dijalankan	Nilai MAE, RMSE, dan MAPE tampil pada kartu evaluasi		Berhasil
13	Visualisasi Hasil	Prediksi selesai dijalankan	Grafik perbandingan harga aktual vs prediksi tampil dengan benar		Berhasil
14	Visualisasi Hasil	Pengguna melakukan hover pada grafik	Tooltip menampilkan tanggal dan harga aktual serta prediksi		Berhasil

15	Visualisasi Hasil	Pengguna mengklik salah satu legenda pada grafik	Garis yang dipilih tersembunyi/ditampilkan kembali		<b>Berhasil</b>
16	Rentang Data	Pengguna memasukkan tanggal mulai lebih besar dari tanggal selesai	Menampilkan pesan warning		<b>Berhasil</b>

## 4.8. Kelebihan dan Kekurangan Sistem

### 4.8.1. Kelebihan Sistem

Adapun kelebihan yang terdapat pada sistem prediksi harga saham dalam penelitian ini adalah:

- 1) Penggunaan arsitektur *Temporal Convolutional Network* (TCN) yang modern menjadi nilai utama sistem ini. TCN dapat menangkap hubungan data jangka panjang tanpa ada masalah *vanishing gradient*. Selain itu, proses konvolusinya bisa berjalan secara parallel, yang secara teori lebih cepat saat tahap pelatihan model.
- 2) Sistem menggunakan tampilan yang modern berkat bantuan framework streamlit.

- 3) Sistem menampilkan transparansi metrik berupa hasil MAE, RMSE, dan MAPE. Ini menandakan sistem memiliki transparansi metrik, mengingatkan pengguna bahwa model memiliki margin error dan tidak 100% benar.
- 4) Sistem dalam penelitian ini telah masuk tahap deployment, menjadikan sistem dapat siap pakai oleh pengguna secara public.

#### **4.8.2. Kekurangan Sistem**

Selain kelebihan, sistem ini juga turut dalam beberapa kekurangan yang dapat menjadi bahan evaluasi untuk pengembangan sistem kedepannya, yaitu:

- 1) Model prediksi hanya menggunakan data masa lalu, mengakibatkan jika ada informasi aktual (BI rate naik atau krisis global) model tidak akan mengetahui hal tersebut.
- 2) Ketergantungan pada satu sumber data (Yahoo Finance), yang jika sewaktu-waktu API tersebut mengubah struktur data atau membatasi akses, sistem prediksi akan mengalami error.
- 3) Model prediksi hanya diuji pada satu emiten saham (BBRI), menjadikannya kurang cocok untuk emiten dengan volatilitas, dan industri yang berbeda.

## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Berdasarkan hasil dan pembahasan penelitian yang dilakukan oleh penulis mengenai implementasi jaringan syaraf tiruan Temporal Convolutional Network (TCNs) untuk perancangan sistem prediksi harga saham berbasis web, maka dapat ditarik kesimpulan sebagai berikut:

1. Implementasi model *machine learning* menggunakan arsitektur *Temporal Convolutional Network* (TCN) untuk sistem prediksi harga saham telah berhasil dilakukan dengan parameter, 64 filter, kernel size 3, dilations [1, 2, 4, 8, 16, 32], dropout rate 0.2, dan fungsi loss Huber ( $\delta=1.0$ ). Sistem prediksi yang dihasilkan dapat berjalan disegala perangkat (*user friendly*).
2. Proses ini mencakup seluruh alur kerja mulai dari pengambilan data dari Yahoo Finance, pembagian data menggunakan rumus Slovin dengan margin error 5%, *preprocessing data*, data training, evaluasi, hingga visualisasi model.
3. Model TCN yang dibangun menunjukkan performa yang baik dalam memprediksi harga saham PT Bank Rakyat Indonesia Tbk (BBRI). Hal ini, terbukti secara kuantitatif dengan perolehan nilai Mean Absolute Error (MAE) sebesar 88,99, Root Mean Squared Error (RMSE) sebesar 118,76, dan Mean Absolute Percentage Error (MAPE) sebesar 2,72%. Nilai ini mengindikasikan tingkat kesalahan prediksi yang relative kecil.

4. Seluruh fitur yang terdapat pada sistem berhasil berjalan sesuai dengan output yang diharapkan, hal ini didapat dari hasil black box testing yang telah dilakukan penulis. Hasil black box testing dapat dilihat pada Tabel 4.4.

## 5.2. Saran

Berpijak pada kesimpulan serta keterbatasan penelitian yang telah dipaparkan, penulis merumuskan sejumlah rekomendasi yang diharapkan dapat menjadi rujukan bagi pengembangan riset di masa mendatang, sekaligus memberikan kontribusi pada implementasi praktis yang berkelanjutan, antara lain:

1. Guna penyempurnaan pada penelitian masa depan, penulis menyarankan untuk mengembangkan model dengan pendekatan multivariat. Tidak hanya menggunakan data harga penutupan (*Close*), tapi juga menambahkan variable lain yang relevan seperti volume perdagangan, indikator teknikal, atau data news, serta data sentiment publik. Penambahan fitur-fitur ini berpotensi meningkatkan konteks yang diterima model, sehingga dapat menghasilkan prediksi yang lebih akurat.
2. Dapat dilakukan penelitian lanjutan untuk menguji performa model TCN dengan arsitektur *deep learning* lainnya, seperti LSTM, Bi-LSTM, atau GRU. Perbandingan ini dapat memberikan wawasan mengenai model mana yang lebih optimal untuk karakteristik data *time series*.

## DAFTAR PUSTAKA

- Akbar Nasution, M. (2025). Data-Driven Portfolio Optimization using K-Means and Markowitz Model: Evidence from LQ45 Stocks. Dalam *Economic: Journal Economic and Business* (Vol. 4, Nomor 2).
- Bagastio, K., Oetama, R. S., & Ramadhan, A. (2023). Development of stock price prediction system using Flask framework and LSTM algorithm. *Journal of Infrastructure, Policy, and Development*, 7(3).  
<https://doi.org/10.24294/jipd.v7i3.2631>
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). *An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling*.  
<https://doi.org/https://doi.org/10.48550/arXiv.1803.01271>
- Dani, H. (2022). Review on Frameworks Used for Deployment of Machine Learning Model. *International Journal for Research in Applied Science and Engineering Technology*, 10(2), 211–215.  
<https://doi.org/10.22214/ijraset.2022.40222>
- Devianto, Y., & Dwiasnati, S. (2020). Kerangka Kerja Sistem Kecerdasan Buatan dalam Meningkatkan Kompetensi Sumber Daya Manusia Indonesia. *Jurnal Telekomunikasi dan Komputer*, 10(1), 19–24.  
<https://doi.org/10.22441/incomtech.v10i1.7460>
- Edy Prasetyo, R., Sumanto, Chaidir, I., & Supriyatna, A. (2025). Reinforcement learning for bitcoin trading: A comparative study of PPO and DQN. *Jurnal Mandiri IT*, 14(2), 159–169. [www.ejournal.isha.or.id/index.php/Mandiri](http://www.ejournal.isha.or.id/index.php/Mandiri)

- Elis, & Voutama, A. (2022). Pemanfaatan UML (Unified Modeling Language) Dalam Perencanaan Sistem Penyewaan Baju Adat Berbasis Website. *Jurnal Informatika, Manajemen dan Komputer*, 14(2), 26–35.
- Francesco Lässig. (2020, Oktober 28). *Temporal Convolutional Networks and Forecasting*. Medium.
- Gao, Y., Wang, R., & Zhou, E. (2021). Stock Prediction Based on Optimized LSTM and GRU Models. *Scientific Programming*, 2021. <https://doi.org/10.1155/2021/4055281>
- Hakim Harry Akbar. (2021). Prediksi Tren Pergerakan Harga Saham Menggunakan Algoritma Temporal Convolutional Network (TCN).
- Handayanto, R. T., & Herlawati, H. (2020). Machine Learning Berbasis Desktop dan Web dengan Metode Jaringan Syaraf Tiruan Untuk Sistem Pendukung Keputusan. *Jurnal Komtika (Komputasi dan Informatika)*, 4(1), 15–26. <https://doi.org/10.31603/komtika.v4i1.3698>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Springer*. <https://doi.org/10.1007/s12525-021-00475-2/Published>
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2016). *Temporal Convolutional Networks for Action Segmentation and Detection*. <http://arxiv.org/abs/1611.05267>
- Mahendra, K., Satyahadewi, N., & Perdana, H. (2022). ANALISIS TEKNIKAL SAHAM MENGGUNAKAN INDIKATOR MOVING AVERAGE CONVERGENCE DIVERGENCE (MACD). Dalam *Buletin Ilmiah Math. Stat. dan Terapannya (Bimaster)* (Vol. 11, Nomor 1).

- Michael, I., & Idowu, M. (2025). *Hybrid Models Combining LSTM and TCN for Enhanced Stock Price Prediction*.  
<https://www.researchgate.net/publication/392131655>
- Mubarik, Hadjar, I., Meinarni, W., & Tawil, A. M. (2024). Pemanfaatan Teknologi Artificial Intelligence Dalam Proses Pembelajaran. Dalam *J. A. I: Jurnal Abdimas Indonesia*. <https://dmi-journals.org/jai/>
- Munandar, A. (2025). Prediksi Harga Mata Uang Kripto Menggunakan Algoritma Temporal Convolutional Network. *Jurnal Nusantara Of Engineering*, 8.  
<https://ojs.unpkediri.ac.id/index.php/noe>
- Nurhalizah, R. S., Ardianto, R., & Purwono. (2024). Analisis Supervised dan Unsupervised Learning pada Machine Learning: Systematic Literature Review. *Jurnal Ilmu Komputer dan Informatika (JIKI)*, 4(1), 61–72.  
<https://doi.org/https://doi.org/10.54082/jiki.168>
- Nurul Wathani, M., Bagja, A., Rodi, M., & Amri, Z. (2025). Penerapan Temporal Convolution Network (TCN) dalam Memprediksi Harga Saham PT Bank Central Asia Tbk Article Info. *GeoScienceEd*.  
<https://doi.org/10.29303/geoscienceed.v6i1.542>
- Russell, S. J. (2021). *Artificial intelligence: a modern approach* (4th Edition). Pearson.
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. Dalam *SN Computer Science* (Vol. 2, Nomor 6). Springer. <https://doi.org/10.1007/s42979-021-00815-1>

- Sungkowo, P. (2025). Implementasi Machine Learning Dengan Model LSTM Untuk Forecasting Harga Saham Menggunakan Data Yahoo Finance. Universitas Muhammadiyah Sumatera Utara.
- Switrayana, I. N., Hammad, R., Irfan, P., Sujaka, T. T., & Nasri, M. H. (2025). Comparative Analysis of Stock Price Prediction Using Deep Learning with Data Scaling Method. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 7(1), 78–90. <https://doi.org/10.35746/jtim.v7i1.650>
- Syahriël, R., Putra, M., Larasati, A., Salsabila, T. T., & Oktavia, A. T. (2025). *Perbandingan Algoritma Temporal Convolutional Neural (TCN) dan Long Short-term Memory (LSTM) untuk Memprediksi Harga Saham Menggunakan Time Series Data*.
- Tigran Aslam Tampati & Muchlis. (2024). *Dampak Nilai Fundamental terhadap Harga Saham pada Sektor Perbankan Tahun 2020-2022*.
- Viktoria, P. J. (2022). Penggunaan Model UML Dalam Sistem Informasi Pemesanan Pupuk Berbasis Web (Studi Kasus Pada UD. Bangun Tani Rantauprapat). *Manajemen Informatika Universitas Labuhanbatu*, 10, 98–111.
- Wang, X., Wang, Y., Weng, B., & Vinel, A. (2020). *Stock2Vec: A Hybrid Deep Learning Framework for Stock Market Prediction with Representation Learning and Temporal Convolutional Network*. <http://arxiv.org/abs/2010.01197>
- Yadav, A. (2024, Oktober 9). *Temporal Convolutional Network — An Overview*. Medium.

## LAMPIRAN

### Lampiran 1. SK-2 Penetapan Dosen Pembimbing



MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH  
**UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**  
**FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI**

UMSU Terakreditasi Unggul Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 174/SK/BIAN-PT/Ak.Pg/PT/2024  
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax (061) 6625474 - 6631003

Website: [www.umsu.ac.id](http://www.umsu.ac.id) Email: [info@umsu.ac.id](mailto:info@umsu.ac.id) Facebook: [umsu.medan](https://www.facebook.com/umsu.medan) Instagram: [umsu.medan](https://www.instagram.com/umsu.medan) Twitter: [umsu.medan](https://twitter.com/umsu.medan) YouTube: [umsu.medan](https://www.youtube.com/umsu.medan)

**PENETAPAN DOSEN PEMBIMBING**  
**PROPOSAL/SKRIPSI MAHASISWA**  
**NOMOR : 995/IL3-AU/UMSU-09/F/2025**

*Assalamu'alaikum Warahmatullahi Wabarakatuh*

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, berdasarkan Persetujuan permohonan judul penelitian Proposal / Skripsi dari Ketua / Sekretaris.

**Program Studi** : Teknologi Informasi  
**Pada tanggal** : 03 November 2025

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

**Nama** : Irtanti Karmina Carona  
**NPM** : 2209020066  
**Semester** : VII (Tujuh)  
**Program studi** : Teknologi Informasi  
**Judul Proposal / Skripsi** : Implementasi Jaringan Syaraf Tiruan Temporal Convolutional Network (TCNs) untuk Perancangan Sistem Prediksi Harga Saham BBRI Berbasis Web

**Dosen Pembimbing** : Dr. Firahmi Rizky, S.Kom.,M.Kom.

Dengan demikian di izinkan menulis Proposal / Skripsi dengan ketentuan

1. Penulisan berpedoman pada buku panduan penulisan Proposal / Skripsi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU
2. Pelaksanaan Sidang Skripsi harus berjarak 3 bulan setelah dikeluarkannya Surat Penetapan Dosen Pembimbing Skripsi.
3. **Proyek Proposal / Skripsi** dinyatakan " **BATAL** " bila tidak selesai sebelum Masa Kadaluarsa tanggal : **03 November 2026**
4. Revisi judul.....

*Wassalamu'alaikum Warahmatullahi Wabarakatuh.*

Ditetapkan di : Medan  
Pada Tanggal : 12 Jumadil Awwal 1447 H  
03 November 2025M



Dekan

**Dr. AF-Khowarizmi, M.Kom.**  
NIDN : 0127099201

## Lampiran 2. Turnitin

### IMPLEMENTATION OF TEMPORAL CONVOLUTIONAL NETWORK (TCNs) FOR THE DESIGN OF A WEB-BASED STOCK PREDICTION SYSTEM

#### ORIGINALITY REPORT

<b>28%</b>	<b>26%</b>	<b>11%</b>	<b>7%</b>
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

#### PRIMARY SOURCES

<b>1</b>	<b>repository.umsu.ac.id</b> Internet Source	<b>14%</b>
<b>2</b>	<b>dspace.uii.ac.id</b> Internet Source	<b>3%</b>
<b>3</b>	<b>docplayer.info</b> Internet Source	<b>&lt;1%</b>
<b>4</b>	<b>Hasriadi Hasriadi, Iqbal Iqbal. "Prediksi Harga Bitcoin Multivariat OHLC Berbasis Hybrid LSTM-GRU dan Sentimen Berita", Jurnal Minfo Polgan, 2026</b> Publication	<b>&lt;1%</b>
<b>5</b>	<b>Submitted to FAKULTAS ILMU KOMPUTER</b> Student Paper	<b>&lt;1%</b>
<b>6</b>	<b>Submitted to Universitas Tarumanagara</b> Student Paper	<b>&lt;1%</b>
<b>7</b>	<b>kc.umn.ac.id</b> Internet Source	<b>&lt;1%</b>
<b>8</b>	<b>Submitted to Universitas Islam Riau</b> Student Paper	<b>&lt;1%</b>
<b>9</b>	<b>jurnal.untag-sby.ac.id</b> Internet Source	<b>&lt;1%</b>
<b>10</b>	<b>Submitted to Universitas Islam Bandung</b> Student Paper	

		<1 %
11	<a href="http://jurnal.citanusantara.id">jurnal.citanusantara.id</a> Internet Source	<1 %
12	<a href="http://dqlab.id">dqlab.id</a> Internet Source	<1 %
13	<a href="http://jurnal.polibatam.ac.id">jurnal.polibatam.ac.id</a> Internet Source	<1 %
14	Submitted to Universitas Sumatera Utara Student Paper	<1 %
15	<a href="http://repository.its.ac.id">repository.its.ac.id</a> Internet Source	<1 %
16	Roni Saputra. "A Comparative Analysis of Univariate and Multivariate LSTM Models for Nokia (NOK) Stock Price Prediction", Jurnal Komtika (Komputasi dan Informatika), 2025 Publication	<1 %
17	Submitted to Tarumanagara University Student Paper	<1 %
18	<a href="http://repository.ppns.ac.id">repository.ppns.ac.id</a> Internet Source	<1 %
19	Diva Arifal Adha, Adam Ramadhan, Habil Maulana, Patlan Putra Humala Harahap, Edi Ismanto. "Peramalan Harga Emas Berbasis Time Series Menggunakan Arsitektur LSTM Deep Learning", Jurnal CoSciTech (Computer Science and Information Technology), 2025 Publication	<1 %
20	<a href="http://journal.udn.ac.id">journal.udn.ac.id</a> Internet Source	<1 %

21	jurnal.poliupg.ac.id Internet Source	<1 %
22	Ichsani Mursidah, Remi Sanjaya, Bambang Yulianto, Dhian Sweetania, Puji Sularsih. "Klasifikasi Sentimen Google Play Store Aplikasi ChatGPT Berbahasa Indonesia Berbasis IndoBERT", Jurnal Minfo Polgan, 2025 Publication	<1 %
23	Rahmawan Bagus Trianto, Kukuh Muhammad, Joko Purwanto, Adlan Nugroho. "Peramalan Penggunaan Bandwidth Internet dengan Pendekatan Time Series ARIMA Menggunakan Optimasi Parameter", Journal of Computer Science and Technology (JCS-TECH), 2025 Publication	<1 %
24	digilib.uin-suka.ac.id Internet Source	<1 %
25	jiki.jurnal-id.com Internet Source	<1 %
26	Submitted to Liverpool John Moores University Student Paper	<1 %
27	Nia Andriani Laila. "Optimasi Parameter Support Vector Regression (SVR) Menggunakan Algoritma Grey Wolf Optimizer (GWO)", Jurnal Ilmiah Matematika, 2025 Publication	<1 %
28	Nova Juliyana Bonarate, Tajuddin Abdillah, Rampi Yusuf. "Perancangan Sistem Informasi POSREDU (Posyandu, Posremaja, Posbindu)	<1 %

Berbasis Website (Studi Kasus: Desa Bunto)",  
Journal Automation Computer Information  
System, 2025

Publication

29	Submitted to Universitas Putera Batam Student Paper	<1 %
30	eprints.untirta.ac.id Internet Source	<1 %
31	repo.itera.ac.id Internet Source	<1 %
32	repositori.uma.ac.id Internet Source	<1 %
33	repository.upnjatim.ac.id Internet Source	<1 %
34	Submitted to Fakultas Teknik Student Paper	<1 %
35	Ines Heidiani Ikasari, Perani Rosyani, Resti Amalia. "Klasifikasi Jenis Buah Menggunakan Metode CNN", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
36	Muhamad Rizki, Aditya Eka Danneswara, Yesa Dwi Aprilia, Muhammad Fatir Rizky Al Fajri, Yayan Hendrian, Shynde Limar Kinanti. "Prediksi Harga Saham Bank BRI dan Bank BCA dengan Menggunakan Model LSTM", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
37	core.ac.uk Internet Source	<1 %

38	Arkananta Emier, Daffa Arief, Aqila Adam, Jubel Hiero Oktovan Lumban Gaol et al. "Penerapan Aplikasi Kasir Berbasis Web Untuk Mengoptimalkan Layanan Transaksi Pada UMKM", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1 %
39	I Made Bayu Sastra Wiguna, Ketut Agus Suputra, Agus Aan Jiwa Permana. "Implementasi Mobile Homecare Berbasis User Centered Desain (UCD)", MASALIQ, 2026 Publication	<1 %
40	Submitted to UPN Veteran Yogyakarta Student Paper	<1 %
41	Submitted to Universitas Katolik Musi Charitas Student Paper	<1 %
42	docobook.com Internet Source	<1 %
43	eprints.undip.ac.id Internet Source	<1 %
44	repositori.telkomuniversity.ac.id Internet Source	<1 %
45	Submitted to Academic Library Consortium Student Paper	<1 %
46	Erika Sita Dewi, Ariella Chandra Naya, Yuyun Umaidah. "Analisis Sentimen Komentar Instagram terkait Isu Sosial pada Akun Detikcom", Jurnal Pendidikan Tambusai, 2026 Publication	<1 %

47	Submitted to Institut Bisnis dan Teknologi Indonesia (INSTIKI) Student Paper	<1 %
48	Nurin Hafizah, Evi Noviani, Hendra Perdana. "ANALISIS TEKNIKAL SAHAM LQ-45 MENGGUNAKAN INDIKATOR BOLLINGER BANDS", Bimaster : Buletin Ilmiah Matematika, Statistika dan Terapannya, 2019 Publication	<1 %
49	Submitted to Universitas Muhammadiyah Surakarta Student Paper	<1 %
50	<a href="http://ejurnal.provisi.ac.id">ejurnal.provisi.ac.id</a> Internet Source	<1 %
51	Hafidz Al Fadil, Erni Rouza, Dafit Suhenra, Andriansyah Andriansyah, Zakinul Mutaqqin, Kelvin Putra Mahendra, Khairul Abdi. "Implementasi Artificial Neural Network (ANN) Untuk Memprediksi Cuaca Harian Berdasarkan Data Suhu dan Kelembapan", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1 %
52	Hendy Kurniawan, L. Budi Handoko, Valentino Aldo. "The Implementation of AWS Cloud Technology to Enhance the Performance and Security of the Pharmacy Cashier Management System", INOVTEK Polbeng - Seri Informatika, 2025 Publication	<1 %
53	Submitted to Konsorsium Perguruan Tinggi Swasta Indonesia II Student Paper	<1 %

54	Submitted to SDM Universitas Gadjah Mada Student Paper	<1 %
55	docshare.tips Internet Source	<1 %
56	Submitted to poltekssn Student Paper	<1 %
57	repository.uksw.edu Internet Source	<1 %
58	Submitted to Universitas Negeri Padang Student Paper	<1 %
59	Submitted to Universitas Pamulang Student Paper	<1 %
60	sites.labic.icmc.usp.br Internet Source	<1 %
61	www.scribd.com Internet Source	<1 %
62	edoc.pub Internet Source	<1 %
63	id.123dok.com Internet Source	<1 %
64	repositori.unwira.ac.id Internet Source	<1 %
65	repository.ub.ac.id Internet Source	<1 %
66	www.coursehero.com Internet Source	<1 %
67	Nurzaenab Nurzaenab, Sulfahmi Sulfahmi, Agus Halid, Fitriana M. Sabir, Andi Sumardin, Asrul Asrul, Andi Ahmad Zacky Mulya.	<1 %

"Perbandingan Implementasi Layer CNN Untuk Akurasi Optimal Dalam Klasifikasi Jenis Sampah Organik dan Non Organik", Jurnal Minfo Polgan, 2026

Publication

68	<a href="http://beritawarganet.com">beritawarganet.com</a> Internet Source	<1 %
69	<a href="http://eprints.ums.ac.id">eprints.ums.ac.id</a> Internet Source	<1 %
70	<a href="http://garuda.ristekbrin.go.id">garuda.ristekbrin.go.id</a> Internet Source	<1 %
71	<a href="http://jurusan.tik.pnj.ac.id">jurusan.tik.pnj.ac.id</a> Internet Source	<1 %
72	<a href="http://lintar.untar.ac.id">lintar.untar.ac.id</a> Internet Source	<1 %
73	<a href="http://repository.ukwms.ac.id">repository.ukwms.ac.id</a> Internet Source	<1 %
74	Bagas Pratama, Lintang Yuniar Banowosari. "Perbandingan Metode Extreme Gradient Boosting (XGBOOST) Dengan Long Short-Term Memory (LSTM) Untuk Prediksi Saham Pt. Bank Mandiri Tbk. (BMRI)", Journal of Economic, Bussines and Accounting (COSTING), 2024 Publication	<1 %
75	Submitted to Universitas Kristen Duta Wacana Student Paper	<1 %
76	<a href="http://denylazor11.blogspot.com">denylazor11.blogspot.com</a> Internet Source	<1 %
	<a href="http://digilib.uinsby.ac.id">digilib.uinsby.ac.id</a>	

77	Internet Source	<1 %
78	e-journals2.unmul.ac.id Internet Source	<1 %
79	ejournal.unsrat.ac.id Internet Source	<1 %
80	eprints.upj.ac.id Internet Source	<1 %
81	repositori.buddhidharma.ac.id Internet Source	<1 %
82	repository.itpln.ac.id Internet Source	<1 %
83	repository.unsri.ac.id Internet Source	<1 %
84	rockingham.wa.gov.au Internet Source	<1 %
85	www.acadlore.com Internet Source	<1 %
86	Dian Islamiaty Puteri. "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah", Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi, 2023 Publication	<1 %
87	Dwi Nurmelly Handayani, Sayid Qutub. "Penerapan Random Forest Untuk Prediksi Dan Analisis Kemiskinan", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %

88	Ken William, Dionisia Bhisetya Rarasati. "Stock Price Prediction on IDX30 Index using Long Short-Term Memory Algorithm", Jurnal Informatika, 2024 <small>Publication</small>	<1%
89	Winnie Alison, Indah Lestari, Dadang Syarif Sihabudin Sahid. "Rancang Bangun Hanyu Shuiping Kaoshi (HSK) Mobile Learning Berbasis Android", Teknika, 2019 <small>Publication</small>	<1%
90	<a href="http://henkieskachandra.blogspot.com">henkieskachandra.blogspot.com</a> <small>Internet Source</small>	<1%

Exclude quotes  Off      Exclude matches  Off  
Exclude bibliography  Off

# IMPLEMENTATION OF TEMPORAL CONVOLUTIONAL NETWORK (TCNs) FOR THE DESIGN OF A WEB-BASED STOCK PREDICTION SYSTEM

GRADEMARK REPORT

FINAL GRADE

GENERAL COMMENTS

**/0**

PAGE 1

PAGE 2

PAGE 3

PAGE 4

PAGE 5

PAGE 6

PAGE 7

PAGE 8

PAGE 9

PAGE 10

PAGE 11

PAGE 12

PAGE 13

PAGE 14

PAGE 15

PAGE 16

PAGE 17

PAGE 18

PAGE 19

PAGE 20

PAGE 21

PAGE 22

PAGE 23

PAGE 24

PAGE 25

PAGE 26	
PAGE 27	
PAGE 28	
PAGE 29	
PAGE 30	
PAGE 31	
PAGE 32	
PAGE 33	
PAGE 34	
PAGE 35	
PAGE 36	
PAGE 37	
PAGE 38	
PAGE 39	
PAGE 40	
PAGE 41	
PAGE 42	
PAGE 43	
PAGE 44	
PAGE 45	
PAGE 46	
PAGE 47	
PAGE 48	
PAGE 49	
PAGE 50	
PAGE 51	
PAGE 52	
PAGE 53	
PAGE 54	
PAGE 55	
PAGE 56	

PAGE 57	
PAGE 58	
PAGE 59	
PAGE 60	
PAGE 61	
PAGE 62	
PAGE 63	
PAGE 64	
PAGE 65	
PAGE 66	
PAGE 67	
PAGE 68	
PAGE 69	
PAGE 70	