

**PENERAPAN MODEL *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE (VARIMA) – TEMPORAL
CONVOLUTIONAL NETWORK (TCN)* DALAM PERAMALAN
SAHAM PT MERCK TBK DAN PT KALBE FARMA TBK**

Skripsi

Oleh

**ARIZ FADILAH TANJUNG
NPM. 2117031074**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2025

ABSTRACT

APPLICATION OF THE HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA) – TEMPORAL CONVOLUTIONAL NETWORK (TCN) MODEL IN FORECASTING THE STOCKS OF PT MERCK TBK AND PT KALBE FARMA TBK

By

Ariz Fadilah Tanjung

Forecasting in stock investment plays a crucial role in understanding market trends, determining optimal transaction timing, and supporting more rational, data-driven investment decisions. The *hybrid* VARIMA–TCN model combines the strengths of linear and nonlinear approaches in time series forecasting, where VARIMA captures linear dependencies while TCN learns the nonlinear patterns from VARIMA residuals. Two *hybrid* variants are applied: VARIMA–E_TCN, which only utilizes residuals, and VARIMA–EP_TCN, which combines residuals with VARIMA predictions as input features. This *hybrid* approach enhances the model's ability to represent the complex dynamics of stock prices and improves forecasting accuracy. The study analyzes MERK and KLBF stock data from November 2020 to December 2025 using RMSE, MAPE, and accuracy as evaluation metrics. The results indicate that the *hybrid* models consistently outperform VARIMA and TCN models, with VARIMA–EP_TCN demonstrating the best performance across all three metrics. The Kolmogorov–Smirnov (KS) test for *goodness of fit* also confirms that the *hybrid* model better aligns with the data distribution. Overall, VARIMA–EP_TCN exhibits superior forecasting performance by effectively combining linear and nonlinear learning mechanisms.

Keywords : Forecasting, Stock Investment, Hybrid Model, Vector Autoregressive Integrated Moving Average (VARIMA), Temporal Convolutional Network (TCN), Time Series.

ABSTRAK

PENERAPAN MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (VARIMA) – *TEMPORAL CONVOLUTIONAL NETWORK* (TCN) DALAM PERAMALAN SAHAM PT MERCK TBK DAN PT KALBE FARMA TBK

Oleh

Ariz Fadilah Tanjung

Peramalan dalam investasi saham memiliki peran penting dalam memahami arah tren pasar, menentukan waktu transaksi yang optimal, serta mendukung pengambilan keputusan investasi yang lebih rasional dan berbasis data. Model *hybrid* VARIMA–TCN memadukan kekuatan pendekatan linear dan nonlinear dalam peramalan deret waktu, di mana VARIMA bertugas menangkap ketergantungan linear, sementara TCN mempelajari pola nonlinear dari residual prediksi VARIMA. Dua varian *hybrid* diterapkan, yaitu VARIMA–E.TCN yang hanya memanfaatkan residual, dan VARIMA–EP.TCN yang menggabungkan residual dengan prediksi VARIMA sebagai fitur masukan. Pendekatan *hybrid* ini meningkatkan kemampuan model dalam merepresentasikan dinamika kompleks harga saham serta memperbaiki akurasi peramalan. Penelitian ini menganalisis data saham MERK dan KLBF dari November 2020 hingga Desember 2025 dengan menggunakan metrik RMSE, MAPE, dan akurasi. Hasil evaluasi menunjukkan bahwa model *hybrid* secara konsisten menunjukkan performa yang lebih baik dibandingkan model VARIMA maupun TCN, dengan VARIMA–EP.TCN menampilkan kinerja terbaik berdasarkan ketiga metrik tersebut. Uji *Kolmogorov–Smirnov* (KS) untuk *goodness of fit* juga mengonfirmasi bahwa model *hybrid* mampu menyesuaikan distribusi data dengan lebih baik. Secara keseluruhan, VARIMA–EP.TCN menunjukkan performa peramalan yang unggul melalui penggabungan mekanisme pembelajaran linear dan nonlinear secara efektif.

Kata-kata kunci : Peramalan, Investasi Saham, Model *Hybrid*, *Vector Autoregressive Integrated Moving Average* (VARIMA), *Temporal Convolutional Network* (TCN), Deret Waktu.

**PENERAPAN MODEL *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE (VARIMA) – TEMPORAL
CONVOLUTIONAL NETWORK (TCN)* DALAM PERAMALAN
SAHAM PT MERCK TBK DAN PT KALBE FARMA TBK**

ARIZ FADILAH TANJUNG

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2025

Judul Skripsi : **PENERAPAN MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (VARIMA) – *TEMPORAL CONVOLUTIONAL NETWORK* (TCN) DALAM PERAMALAN SAHAM PT MERCK TBK DAN PT KALBE FARMA TBK**

Nama Mahasiswa : **Ariz Fadilah Tanjung**

Nomor Pokok Mahasiswa : **2117031074**

Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

MENYETUJUI

1. Komisi Pembimbing



Ir. Warsono, M.S., Ph.D
NIP. 198002062003121003



Dr. Dian Kurniasari, S.Si., M.Sc
NIP. 196903051996032001

2. Ketua Jurusan Matematika



Dr. Aang Nuryaman, S.Si., M.Si
NIP. 197403162005011001

MENGESAHKAN

1. Tim Penguji

Ketua : **Ir. Warsono, M.S., Ph.D**

Sekretaris : **Dr. Dian Kurniasari, S.Si., M.Sc**

Penguji:

Bukan Pembimbing : **Dr. Aang Nuryaman, S.Si., M.Si**

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: **10 Oktober 2025**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : Ariz Fadilah Tanjung
Nomor Pokok Mahasiswa : 2117031074
Jurusan : Matematika
Judul Skripsi : Penerapan Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA) – Temporal Convolutional Network (TCN)* Dalam Peramalan Saham PT Merck Tbk dan PT Kalbe Farma Tbk

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 16 Oktober 2025

Penulis,



Ariz Fadilah Tanjung

RIWAYAT HIDUP

Penulis bernama lengkap Ariz Fadilah Tanjung, lahir di Lahat pada 29 November 2002. Penulis merupakan anak ketiga dari empat bersaudara dari pasang Bapak Firdaus dan Ibu Falianis. Penulis mempunyai kakak bernama Taufiq Akbar Tanjung dan Al Zulmi Tanjung serta adik bernama Alif Azra Tanjung.

Penulis menempuh pendidikan Sekolah Dasar (SD) Muhammadiyah Lahat pada tahun 2008-2014, kemudian melanjutkan pendidikan ke Sekolah Menengah Pertama (SMP) Negeri 02 Lahat pada tahun 2014-2017, dan Sekolah Menengah Kejuruan (SMK) Negeri 1 Lahat tahun 2017-2020.

Pada tahun 2020 penulis berniat untuk melanjutkan studi Strata Satu (S1), tetapi tidak diterima di Universitas yang dipilih. Pada tahun 2021 penulis mendaftarkan pada pilihan Universitas Lampung dan Universitas Sriwijaya dengan jurusan yang sama yaitu jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis mengikuti beberapa organisasi internal yang ada di lingkungan kampus. Pada organisasi internal kampus, penulis menjadi Anggota Aktif Bidang Akademik dan Riset Rois FMIPA Unila dan Staf Ahli Dinas Isu dan Pergerakan BEM FMIPA Unila tahun 2022, Kepala Bidang Akademik dan Riset dan Staf Ahli Kementerian Kajian Isu Strategis BEM U KBM Unila 2023, Kepala Dinas Kajian dan Aksi Strategis tahun 2024, dan Menteri Kajian Isu Strategis BEM U KBM Unila tahun 2025.

Sebagai bentuk pengaplikasian ilmu yang didapat selama perkuliahan, pada bulan Desember 2023 hingga Februari 2024, penulis melaksanakan Kerja Praktik (KP) di Badan Pusat Statistik (BPS) Kabupaten Lahat, Provinsi Sumatera Selatan. Kemudian, pada bulan Juni hingga Agustus 2024, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Lehan, Kecamatan Sidomulyo, Kabupaten Lampung Timur, Provinsi Lampung.

KATA INSPIRASI

”Sesungguhnya bersama kesulitan ada kemudahan. Maka apabila engkau telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain). Dan hanya kepada Tuhanmulah engkau berharap”

(Q.S. Al-Insyirah: 6-8)

”Ilmu adalah cahaya yang menuntun langkah, kesabaran adalah jembatan menuju pencapaian, dan kerja keras adalah kunci untuk membuka setiap pintu keberhasilan”

(Al-Mujaddalah:11)

”Masa depan suatu bangsa sangat ditentukan oleh kualitas pendidikannya”

(B.J Habibie)

PERSEMBAHAN

Alhamdulillah rabbil ‘alamin, segala puji bagi Allah SWT atas limpahan rahmat, nikmat, dan hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Atas rasa syukur dan kebahagiaan yang mendalam, penulis mempersembahkan ucapan terima kasih yang tulus kepada:

Ayah, Ibu, Kakak, dan Adikku Tercinta

Ucapan terima kasih yang sebesar-besarnya penulis sampaikan kepada kedua orang tua, kakak, dan adikku yang telah memberikan kasih sayang, doa, dan dukungan yang tiada henti-hentinya. Penulis juga berterima kasih atas setiap pelajaran berharga yang telah diberikan tentang arti perjuangan dan perjalanan hidup, yang menjadi bekal penting agar kelak dapat menjadi pribadi yang bermanfaat bagi banyak orang.

Dosen Pembimbing dan Pembahas

Ucapan terima kasih penulis sampaikan kepada dosen pembimbing dan dosen pembahas yang telah banyak memberikan bimbingan, motivasi, arahan, serta ilmu yang sangat berharga selama proses penyusunan skripsi ini.

Sahabat-sahabatku

Penulis mengucapkan terima kasih kepada semua orang baik yang telah memberikan pengalaman berharga, semangat, motivasi, serta doa dan dukungan dalam berbagai hal selama proses penyusunan skripsi ini.

Almamater Tercinta

Universitas Lampung

SANWACANA

Alhamdulillah rabbil ‘alamin, segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat, karunia, dan hidayah-Nya sehingga skripsi yang berjudul “Penerapan Model *Hybrid Vector Autoregressive Integrated Moving Average* (VARIMA) – *Temporal Convolutional Network* (TCN) Dalam Peramalan Saham PT Merck Tbk dan PT Kalbe Farma Tbk” dapat diselesaikan dengan baik, lancar, dan tepat waktu. Shalawat serta salam senantiasa tercurah kepada junjungan Nabi Muhammad SAW beserta keluarga dan para sahabatnya.

Proses penyusunan skripsi ini terlaksana berkat bantuan banyak pihak yang telah memberikan bimbingan, dukungan, arahan, motivasi, serta saran yang berharga. Kesempatan ini menjadi momen bagi penulis untuk menyampaikan rasa terima kasih dan penghargaan yang tulus kepada:

1. Bapak Ir. Warsono, M.S., Ph.D. selaku Pembimbing I yang telah meluangkan banyak waktu untuk memberikan bimbingan, arahan, motivasi, serta dukungan berharga sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing II atas segala arahan, bimbingan, dan dukungan yang diberikan kepada penulis selama proses penyusunan skripsi ini.
3. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Penguji yang telah meluangkan waktu untuk memberikan kritik, saran, dan evaluasi yang membangun, sehingga penulis dapat memperbaiki dan menyempurnakan penelitian ini.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung atas segala dukungan dan arahnya.
5. Ibu Siti Laelatul Chasanah, S.Pd., M.Si. selaku dosen pembimbing akademik atas perhatian, arahan, serta bimbingan selama masa perkuliahan.


6. Seluruh dosen, staf, dan karyawan Jurusan Matematika FMIPA Universitas Lampung yang telah memberikan ilmu, pelayanan, serta bantuan selama penulis menempuh pendidikan.
7. Ayah Firdaus, Ibu Falianis, Taufiq Akbar Tanjung, Al Zulmi Tanjung, Alif Azra Tanjung, serta seluruh keluarga besar yang senantiasa memberikan kasih sayang, doa, dukungan moral, dan materiil yang tak ternilai harganya hingga penulis dapat menyelesaikan skripsi ini.
8. Pengurus Rois FMIPA Unila Periode 2022 atas pengalaman dan nilai-nilai positif yang telah diberikan sehingga menumbuhkan semangat penulis untuk terus berbuat kebaikan dan memberi manfaat bagi sesama.
9. Pengurus BEM FMIPA Unila Periode 2022 sebagai wadah diskusi yang membentuk pola pikir kritis dan kepekaan penulis terhadap berbagai isu di lingkungan kampus.
10. Pimpinan Rois FMIPA Unila Periode 2023 Kabinet Al-Muharib, Sayyid, Anam, Utami, Yulina, Harry, Retno, Rafif, Nurul, Daffa, Na'imah, Wisnu, Natia, Sayyida, Maulana, Azetya, Irvandi, Khomsatun, Ghulam, dan Adzia yang telah berjuang bersama dalam upaya menebar kebermanfaatan serta menegakkan nilai-nilai kebaikan.
11. Pengurus BEM U KBM Unila Periode 2023 atas kontribusinya dalam menumbuhkan semangat penulis untuk tetap berpegang pada nilai-nilai kebenaran.
12. Pimpinan BEM FMIPA Unila Periode 2024 Kabinet Gawi Aksara, Erwin, Abe, Talfa, Ririn, Yoeanda, David, Syakila, dan pimpinan lainnya yang telah bersama hingga akhir masa kepengurusan, berbagi perjuangan dan pengalaman berharga.
13. Pimpinan BEM U KBM Unila Periode 2025 Kabinet Unila Bangkit, Ammar, Aiman, Erwin, Almahda, Aqila, Salman, Okta, Raden, dan rekan lainnya yang telah memberikan dukungan serta berperan dalam membentuk karakter kepemimpinan penulis.
14. Sahabat penulis, para PANDAWA, Anam, Govin, Erwin, dan Sayyid, yang selalu hadir dalam suka dan duka, menjadi tempat berbagi cerita, berdiskusi, dan tumbuh bersama dalam perjalanan akademik maupun kehidupan.

15. Keluarga Madani 2021 yang menjadi tempat bernaung dari lelahnya dunia akademik, serta bagian penting dalam perjalanan bermakna selama menjadi mahasiswa.
16. Salahudin Al Ayyubi, Aiman, Anam, Anang, Erwin, Govindo, Fatir, Ihsan, Nabil, Rafly, Syarif, dan Wildan, rekan dalam kebaikan, penyusunan skripsi, dan pengembangan karier. Terima kasih telah kebersamai penulis untuk menjadi pribadi yang lebih baik.
17. Teman-teman seperbimbingan Pak Warsono dan Bu Dian, Andi, Anggy, Erwin, Dita, Maya, Mey, Nabila, Sherina, Adinda, Anastasia, Dina, Fathan, Lusiana, Rhea, dan Yulina yang senantiasa memberikan dukungan, bantuan, serta semangat dalam menyelesaikan skripsi ini.
18. Teman-teman Jurusan Matematika angkatan 2021 serta Abang Yunda atas kebersamaan, bantuan, dan dukungan selama masa perkuliahan.
19. Semua pihak yang telah membantu dalam penyusunan skripsi ini dan tidak dapat penulis sebutkan satu per satu, semoga Allah SWT membalas segala kebaikan dengan pahala yang berlipat ganda.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 16 Oktober 2025

Penulis,



Ariz Fadilah Tanjung

DAFTAR ISI

DAFTAR ISI	xiii
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
II TINJAUAN PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Deret Waktu	9
2.2.1 Analisis Deret Waktu	10
2.2.2 Peramalan Deret Waktu	10
2.3 Deret Waktu Univariat	11
2.3.1 <i>Autoregressive</i> (AR)	12
2.3.2 <i>Moving Average</i> (MA)	12
2.3.3 <i>Autoregressive Moving Average</i> (ARMA)	13
2.3.4 <i>Autoregressive Integrated Moving Average</i> (ARIMA)	13
2.4 Deret Waktu Multivariat	14
2.4.1 <i>Vector Autoregressive</i> (VAR)	14
2.4.2 <i>Vector Moving Average</i> (VMA)	15
2.4.3 <i>Vector Autoregressive Moving Average</i> (VARMA)	15
2.4.4 <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA)	15
2.5 Uji Asumsi	16
2.5.1 Stasioneritas Data	16
2.5.2 Uji <i>White Noise</i>	17
2.6 <i>Data Mining</i>	18
2.7 <i>Machine Learning</i>	18
2.7.1 <i>Scaling Data</i>	19
2.7.2 Fungsi Aktivasi	20

2.7.3	<i>Unscaling Data</i>	23
2.7.4	<i>Hyperparameter Tuning</i>	24
2.8	<i>Deep Learning</i>	24
2.8.1	<i>Convolutional Neural Network (CNN)</i>	25
2.8.2	<i>Temporal Convolutional Network (TCN)</i>	26
2.9	<i>Hybrid VARIMA-TCN</i>	31
2.10	<i>Evaluasi Model</i>	32
2.11	<i>Goodness Of Fit</i>	33
III	METODE PENELITIAN	35
3.1	Waktu dan Tempat Penelitian	35
3.2	Data dan Alat Penelitian	35
3.2.1	Data Penelitian	35
3.2.2	Alat Penelitian	36
3.3	Metode Penelitian	37
IV	HASIL DAN PEMBAHASAN	45
4.1	Input Data	45
4.2	Visualisasi Data	46
4.3	<i>Splitting Data</i>	47
4.4	<i>Preprocessing Data</i>	47
4.5	Prediksi dan Peramalan Model VARIMA	48
4.5.1	Uji Stasioneritas	48
4.5.2	Identifikasi Model	50
4.5.3	Estimasi Parameter Model	51
4.5.4	Prediksi Model VARIMA	52
4.5.5	Peramalan Model VARIMA	55
4.5.6	Residual Model VARIMA	56
4.6	Prediksi dan Peramalan Model TCN	58
4.6.1	<i>Scaling Data</i> Prediksi Model TCN	58
4.6.2	<i>Hyperparameter Tuning</i> Model TCN	59
4.6.3	Membangun Model TCN	60
4.6.4	Prediksi Model TCN	61
4.6.5	Peramalan Model Prediksi TCN	63
4.7	Prediksi dan Peramalan Model <i>Hybrid</i> VARIMA–E-TCN	64
4.7.1	<i>Scaling Data</i> Residual Model VARIMA	65
4.7.2	<i>Hyperparameter Tuning</i> Model E-TCN	65

4.7.3	Membangun Model E_TCN	66
4.7.4	Prediksi Model E_TCN	66
4.7.5	Prediksi Model <i>Hybrid</i> VARIMA–E_TCN	68
4.7.6	Peramalan Model E_TCN	70
4.7.7	Peramalan Model <i>Hybrid</i> VARIMA–E_TCN	71
4.8	Prediksi dan Peramalan Model <i>Hybrid</i> VARIMA–EP_TCN	73
4.8.1	<i>Scaling</i> Data Prediksi Model VARIMA	73
4.8.2	<i>Hyperparameter Tuning</i> Model P_TCN	73
4.8.3	Membangun Model P_TCN	74
4.8.4	Prediksi Model P_TCN	75
4.8.5	Prediksi Model <i>Hybrid</i> VARIMA–EP_TCN	77
4.8.6	Peramalan Model P_TCN	79
4.8.7	Peramalan Model <i>Hybrid</i> VARIMA–EP_TCN	80
4.9	<i>Goodness of fit</i>	82
V	KESIMPULAN	85
5.1	Kesimpulan	85
	DAFTAR PUSTAKA	87
	LAMPIRAN	92

DAFTAR TABEL

1.	Penelitian Terkait	9
2.	Data Penelitian	36
3.	<i>Input Data</i>	45
4.	Hasil Pengecekan <i>Missing Value</i>	47
5.	Hasil Korelasi Pearson	47
6.	Hasil Uji Stasioneritas Awal	48
7.	Hasil Uji Stasioneritas Setelah <i>Differencing</i>	49
8.	Hasil Pemilihan Model VARIMA	52
9.	Hasil Prediksi KLBF dan MERK	52
10.	Hasil Prediksi Model VARIMA Setelah <i>Undifferencing</i>	53
11.	Evaluasi Model VARIMA	54
12.	Hasil Peramalan Model VARIMA	55
13.	Residual Model VARIMA	57
14.	Hasil Uji <i>Ljung-Box</i>	58
15.	<i>Hyperparameter Tuning</i> Model TCN	59
16.	Hasil <i>Hyperparameter Tuning</i> Model TCN	60
17.	Hasil Prediksi MERK dan KLBF	61
18.	Hasil Prediksi Model TCN	61
19.	Evaluasi Model TCN	62
20.	Hasil Peramalan Model Prediksi TCN	63
21.	<i>Hyperparameter Tuning</i> Model E_TCN	65
22.	Hasil <i>Hyperparameter</i> Model E_TCN	66
23.	Prediksi Residual Model E_TCN	67
24.	Hasil Prediksi Model E_TCN	67
25.	Evaluasi Model E_TCN	68
26.	Hasil Prediksi Model <i>Hybrid</i> E_TCN	69
27.	Evaluasi Model <i>Hybrid</i> VARIMA–E_TCN	70
28.	Peramalan Residual E_TCN	70
29.	Hasil Peramalan Model <i>Hybrid</i> VARIMA–E_TCN	72
30.	<i>Hyperparameter Tuning</i> Model P_TCN	74

31.	Hasil <i>Hyperparameter Tuning</i> Model P_TCN	75
32.	Prediksi Model P_TCN	75
33.	Hasil Prediksi Model P_TCN	76
34.	Evaluasi Model P_TCN	77
35.	Hasil Prediksi Model <i>Hybrid</i> VARIMA EP_TCN	77
36.	Evaluasi Model <i>Hybrid</i> VARIMA–EP_TCN	78
37.	Hasil Peramalan Model P_TCN	79
38.	Hasil Peramalan Model <i>Hybrid</i> VARIMA–EP_TCN	81
39.	<i>Goodness of fit</i> MERK	82
40.	<i>Goodness of fit</i> KLBF	83

DAFTAR GAMBAR

1.	Fungsi Aktivasi ReLU (Wibawa, 2017)	21
2.	Fungsi Aktivasi <i>Leaky ReLU</i> (Layton <i>et al</i> ,2024)	22
3.	Fungsi Aktivasi Linear (Marimuthu,2022)	23
4.	Arsitektur CNN (Saxena,2022)	26
5.	Arsitektur TCN (Bai <i>et al.</i> ,2018)	28
6.	Visualisasi Perlebaran Pada <i>Layer</i> (Wan <i>et al.</i> ,2019)	28
7.	<i>Residual Block</i> (Bai <i>et al.</i> ,2018)	30
8.	<i>Residual Block</i> ($k = 3, d = 1$) (Bai <i>et al.</i> ,2018)	31
9.	<i>Flowchart</i> Model VARIMA	41
10.	<i>Flowchart</i> Model TCN	42
11.	<i>Flowchart</i> Model <i>Hybrid</i> VARIMA–E_TCN	43
12.	<i>Flowchart</i> Model <i>Hybrid</i> VARIMA–EP_TCN	44
13.	Visualisasi Data MERK	46
14.	Visualisasi Data KLBF	46
15.	<i>Differencing</i> Pertama MERK dan KLBF	49
16.	<i>Plot</i> ACF dan PACF MERK	50
17.	<i>Plot</i> ACF dan PACF KLBF	51
18.	Hasil <i>Plot</i> Prediksi Model VARIMA	54
19.	Hasil Peramalan Model VARIMA	56
20.	Hasil <i>Plot</i> Residual MERK dan KLBF	57
21.	Hasil Model TCN Data MERK dan KLBF	62
22.	Hasil Peramalan Model TCN	64
23.	Hasil Residual Model E_TCN	68
24.	Hasil Prediksi Model <i>Hybrid</i> VARIMA–E_TCN	69
25.	Hasil Peramalan Residual Model E_TCN	71
26.	Hasil Peramalan Model <i>Hybrid</i> VARIMA–E_TCN	72
27.	Hasil Prediksi Model P_TCN	76
28.	Hasil Prediksi Model <i>Hybrid</i> Model VARIMA–EP_TCN	78
29.	Hasil Peramalan Model P_TCN	80
30.	Hasil Peramalan Model VARIMA–EP_TCN	81

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Era globalisasi dan ekonomi modern telah menjadikan investasi sebagai kunci dalam strategi pengelolaan kekayaan. Instrumen investasi saham yang tersedia dapat menjadi pilihan populer bagi para investor. Alasan utama investor sering membeli saham adalah tingkat keuntungannya cukup menjanjikan. Namun, potensi keuntungan tersebut tidak terlepas dari resiko fluktuasi harga yang perlu diantisipasi dengan cermat. Hal ini diperlukan sebuah metode peramalan yang akurat agar dapat memproyeksikan pergerakan harga di masa mendatang. Peramalan sendiri didefinisikan sebagai proses estimasi nilai suatu variabel pada periode yang akan datang, berdasarkan pola historis yang terbentuk sebelumnya (Makridakis *et al.*, 1984).

Pada konteks investasi saham, peramalan menjadi peranan penting dalam membaca tren pasar, menentukan momen optimal untuk transaksi, dan mendukung pengambilan keputusan investasi yang lebih rasional dan berbasis data. Harga saham dipengaruhi oleh kondisi pasar, kinerja perusahaan, dan dinamika ekonomi global yang memicu fluktuasi signifikan. Memahami pola pergerakan harga menjadi kunci dalam pengambilan keputusan investasi. Salah satu metode untuk menganalisis pola tersebut adalah analisis deret waktu, yaitu urutan pengamatan berdasarkan kronologi waktu (Box *et al.*, 2015). Pendekatan ini memungkinkan investor mengidentifikasi tren dan pola historis harga saham. Oleh karena itu, dibutuhkan model deret waktu untuk memecahkan permasalahan tersebut.

Deret waktu dapat diklasifikasikan menjadi dua model yakni model univariat dan model multivariat, tergantung pada jumlah variabel yang dianalisis. Model univariat hanya menggunakan informasi dari satu variabel, seperti harga saham tunggal, sedangkan model multivariat melibatkan lebih dari satu variabel atau saham secara bersamaan (Jange, 2021). Pada analisis data univariat, model yang sering digunakan adalah *Autoregressive* (AR), sementara analisis data multivariat umumnya

menggunakan model *Vector Autoregression* (VAR) (Hardani dkk., 2016).

Pendekatan dalam model univariat, digunakan metode peramalan AR, *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA). Model AR merupakan model stokastik pada umumnya dapat berguna dalam merepresentasikan deret tertentu yang terjadi secara praktis. Model MA merupakan model yang secara teknis digunakan untuk merepresentasikan deret waktu yang diamati. Model ARMA merupakan model suatu tingkatan dengan fleksibilitas yang lebih tinggi dalam melakukan *fitting* terhadap deret waktu aktual. Model ARIMA merupakan model yang terdiri dari penggabungan dua proses yaitu proses AR dan MA dengan *differencing* orde d .

Pendekatan multivariat dalam peramalan meliputi beberapa model, yaitu *Vector Autoregressive* (VAR), *Vector Moving Average* (VMA), *Vector Autoregressive Moving Average* (VARMA), serta *Vector Autoregressive Integrated Moving Average* (VARIMA). Model VAR merepresentasikan keterkaitan sejumlah variabel deret waktu secara simultan, dengan nilai saat ini dipengaruhi oleh lag dari variabel itu sendiri maupun lag dari variabel lain dalam sistem, sehingga informasi historis digunakan untuk memprediksi nilai masa depan. Model VMA menekankan peran residual atau kesalahan acak pada periode sebelumnya yang memengaruhi nilai pada periode berjalan. Model VARMA merupakan kombinasi dari VAR dan VMA yang dirancang untuk menggambarkan dinamika hubungan antar variabel deret waktu secara lebih komprehensif. Model VARIMA dikembangkan sebagai perluasan dari ARIMA univariat agar dapat digunakan pada data multivariat.

Metode VARIMA telah diterapkan dalam berbagai bidang, salah satunya oleh Antaristi dkk. (2023) yang digunakan untuk menganalisis dan meramalkan data *well logging*, yakni data hasil pengukuran parameter fisik dan kimia batuan pada berbagai kedalaman lubang bor. Penerapan model VARIMA juga dilakukan oleh Jusmawati dkk. (2020) yang menggunakan data inflasi dan suku bunga untuk melihat keterkaitan antarvariabel ekonomi tersebut serta memprediksi pergerakan inflasi di masa depan berdasarkan hubungan dinamis dengan suku bunga. Penerapan model VARIMA secara umum hanya mampu menangkap hubungan antarvariabel yang bersifat linear. Menurut Box *et al.* (2015), model deret waktu berbasis ARIMA dan turunannya memang dirancang untuk menganalisis pola linier sehingga kurang optimal ketika diterapkan pada data dengan karakteristik nonlinear yang kompleks. Pergerakan harga saham pada kenyataannya tidak hanya dipengaruhi oleh faktor internal perusahaan, tetapi juga oleh sentimen pasar, kebijakan pemerintah, dan

kondisi global yang sering kali bersifat non-linear. Oleh karena itu, diperlukan pendekatan non-linear, seperti jaringan saraf tiruan atau metode *deep learning*, untuk menangkap dinamika pasar secara lebih menyeluruh (Olatayo & Ekerikevwe, 2022).

Machine learning merupakan salah satu cabang dari kecerdasan buatan *Artificial Intelligence* (AI) yang dikembangkan untuk meniru kemampuan manusia dalam menyelesaikan berbagai jenis permasalahan. Secara umum, *machine learning* adalah suatu sistem yang mampu belajar serta menjalankan tugas secara otomatis tanpa perlu diberikan instruksi secara langsung oleh pengguna (Wijoyo dkk., 2024). Pendekatan ini banyak dimanfaatkan untuk meningkatkan akurasi pemodelan, khususnya pada data yang bersifat nonlinier. Meskipun demikian, *machine learning* memiliki keterbatasan dalam mengenali pola pada data yang berurutan atau berbentuk deret waktu. Hal ini disebabkan karena banyak algoritma *machine learning* umumnya dirancang untuk tugas-tugas seperti regresi, klasifikasi, dan klusterisasi. Oleh karena itu, untuk mengatasi tantangan tersebut, digunakan pendekatan *deep learning* yang lebih efektif dalam mengolah data berurutan (Azhari dan Haryanto, 2024).

Pendekatan *deep learning* cenderung lebih sesuai digunakan pada data yang bersifat nonlinier dan tidak stasioner. Beberapa arsitektur yang umum dimanfaatkan dalam *deep learning* antara lain *Recurrent Neural Network* (RNN), *Convolutional Neural Network* (CNN), *Long Short-Term Memory* (LSTM), serta *Gated Recurrent Unit* (GRU). Masing-masing arsitektur tersebut memiliki keterbatasan tersendiri. RNN sering mengalami permasalahan *vanishing gradient*, sehingga kesulitan dalam menangkap ketergantungan jangka panjang. CNN pada dasarnya lebih cocok digunakan untuk pengolahan data spasial seperti citra, sehingga kurang optimal dalam memodelkan dinamika temporal. Penelitian dari Zhou *et al.* (2020) menyatakan bahwa pendekatan CNN tradisional relatif kurang efektif dalam mempelajari dependensi sekuensial, sehingga dibutuhkan model yang secara khusus dirancang untuk data temporal. LSTM dan GRU memang menawarkan solusi terhadap kelemahan RNN, namun keduanya memerlukan waktu komputasi yang lebih panjang serta kompleksitas model yang tinggi, terutama ketika diaplikasikan pada data deret waktu berdimensi besar. Kondisi tersebut menuntut adanya metode analisis yang mampu menangkap kompleksitas pola deret waktu, khususnya dalam konteks pergerakan harga saham. Salah satu pendekatan *deep learning* yang berkembang untuk peramalan deret waktu adalah *Temporal Convolutional Network* (TCN). Model TCN diperkenalkan oleh Bai *et al.* (2018) sebagai pengembangan

dari CNN yang secara khusus ditujukan untuk pemodelan data sekuensial, serta menunjukkan performa yang kompetitif dalam berbagai studi.

Pengembangan model TCN telah diaplikasikan dalam berbagai bidang, termasuk pemodelan pasar saham. Penerapan model TCN dalam bidang finansial dilakukan oleh Wathani dkk. (2025), yang menggunakan data historis saham Bank Central Asia (BCA) untuk memprediksi pergerakan harga dengan pendekatan univariat dan multivariat. Penerapan metode yang digunakan pada penelitian oleh Augusta dkk (2021) dalam menganalisis pergerakan harga saham farmasi, khususnya PT Kalbe Farma Tbk dengan memanfaatkan model LSTM.

Berdasarkan keunggulan masing-masing model, pendekatan *hybrid* menjadi pilihan yang tepat untuk memaksimalkan kemampuan prediksi (Zhang, 2003). Model *hybrid* VARIMA–TCN menggabungkan kekuatan model linear dan non-linear dalam analisis deret waktu. VARIMA menangkap pola linear pada data. TCN memodelkan pola non-linear yang tersisa dari residual hasil prediksi VARIMA. Residual VARIMA dijadikan nilai *input* bagi model TCN untuk dipelajari lebih lanjut. Prediksi akhir diperoleh dengan menjumlahkan hasil prediksi VARIMA dan TCN, sehingga data dapat direpresentasikan lebih menyeluruh. Terdapat dua varian pendekatan ini, yaitu VARIMA–E_TCN yang hanya memanfaatkan residual, serta VARIMA–EP_TCN yang menggunakan residual sekaligus prediksi VARIMA sebagai fitur tambahan. Pendekatan *hybrid* ini mampu menangkap dinamika linear dan non-linear pada pergerakan harga saham, sehingga meningkatkan akurasi peramalan (Rowan dkk, 2021).

Penelitian ini memanfaatkan model *hybrid* VARIMA–TCN untuk melakukan peramalan harga penutupan saham PT Merck Tbk (MERK) dan PT Kalbe Farma Tbk (KLBF). PT Merck Tbk dikenal sebagai perusahaan di sektor kesehatan yang berfokus pada industri farmasi, demikian pula PT Kalbe Farma Tbk yang bergerak di bidang yang sama. Adapun model yang dianalisis dalam penelitian ini mencakup VARIMA, TCN, *hybrid* VARIMA–E TCN, serta *hybrid* VARIMA–EP TCN. Model VARIMA hanya digunakan untuk menangkap hubungan linier antarvariabel. Model TCN diterapkan untuk memodelkan pola non-linier yang kompleks pada data deret waktu saham. Model *hybrid* VARIMA–E TCN memanfaatkan residual VARIMA sebagai masukan ke TCN untuk memodelkan pola non-linier, sedangkan model *hybrid* VARIMA–EP TCN menggunakan residual dan prediksi VARIMA secara bersamaan sebagai input TCN. Perbandingan keempat model ini dilakukan untuk menilai sejauh mana pendekatan *hybrid* dapat meningkatkan akurasi peramalan

harga saham.

1.2 Rumusan Masalah

Adapun rumusan masalah pada penelitian sebagai berikut :

1. Membangun model VARIMA, *hybrid* VARIMA-E_TCN, TCN, dan *hybrid* VARIMA-EP_TCN untuk memodelkan dan meramalkan data terkait di PT Merck Tbk dan PT Kalbe Farma Tbk.
2. Mengetahui hasil peramalan dari model VARIMA, TCN, *hybrid* VARIMA-E_TCN, dan *hybrid* VARIMA-EP_TCN yang diterapkan pada data PT Merck Tbk dan PT Kalbe Farma Tbk.
3. Membandingkan kinerja model VARIMA, TCN, *hybrid* VARIMA-E_TCN, dan *hybrid* VARIMA-EP_TCN dalam meramalkan data PT Merck Tbk dan PT Kalbe Farma Tbk.

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini sebagai berikut:

1. Membangun berbagai model peramalan, yaitu VARIMA, TCN, *hybrid* VARIMA-E_TCN, dan *hybrid* VARIMA-EP_TCN, yang khusus diterapkan pada data dari PT Merck Tbk dan PT Kalbe Farma Tbk.
2. Mengetahui dan menganalisis hasil peramalan dari setiap model yang telah dibangun pada konteks data PT Merck Tbk dan PT Kalbe Farma Tbk.
3. Melakukan perbandingan kinerja antar model VARIMA, TCN, *hybrid* VARIMA-E_TCN, dan *hybrid* VARIMA-EP_TCN dalam peramalan data PT Merck Tbk dan PT Kalbe Farma Tbk untuk menentukan model dengan kinerja terbaik di sektor kesehatan.

1.4 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan rekomendasi model peramalan yang akurat untuk mendukung pengambilan keputusan strategis guna meningkatkan pemahaman dalam pemodelan berbasis komputasi.

2. Memperkaya ilmu pengetahuan di bidang peramalan deret waktu melalui pengembangan dan perbandingan model VARIMA, TCN, *hybrid* VARIMA–E.TCN, dan *hybrid* VARIMA–EP.TCN.
3. Menjadi sebuah referensi dan dasar untuk penelitian selanjutnya dalam pengembangan atau penerapan model peramalan yang lebih kompleks.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian ini merujuk pada sejumlah studi yang dipilih secara selektif berdasarkan relevansi topik, pendekatan metode, dan kecocokan pada data. Sebagai bagian dari landasan metodologis, penelitian ini mengacu pada literatur yang membahas penerapan metode VARIMA, TCN, dan *Long Short-Term Memory* (LSTM). Evaluasi terhadap performa masing-masing metode dilakukan dengan menggunakan dua metrik umum dalam peramalan, yaitu *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE). Ringkasan penelitian-penelitian tersebut disajikan dalam Tabel 1 yang mencakup informasi mengenai penelitian, data, metode, serta hasil yang diperoleh sebagai berikut :

1. Penerapan model *Vector Autoregressive Integrated Moving Average* pada *data logging* (Antaristi dkk., 2023)

Penelitian ini dilakukan oleh Antaristi dkk., (2023) dengan tujuan menganalisis dan meramalkan *data well logging*. Data yang digunakan meliputi kedalaman 1,4 m hingga 98,8 m. Model yang dihasilkan adalah VARIMA (0,1,1) dengan hasil metrik MAPE sebesar 24,74%, 10,90%, dan 7,81% untuk data GR, LSD, dan SSD berturut-turut.

2. Penerapan Model *Vector Autoregressive Integrate Moving Average* dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia, (Jusmawati dkk., 2020)

Penelitian ini bertujuan untuk memodelkan dan meramalkan data laju inflasi dan suku bunga di Indonesia menggunakan metode VARIMA. Data yang digunakan adalah data bulanan dari Januari 2009 hingga Desember 2016. Model terbaik yang diperoleh adalah VARIMA (0,2,2) dengan nilai AIC terendah -42891. Hasil peramalan menunjukkan nilai MAPE untuk laju inflasi sebesar 6,04% dan suku bunga sebesar 1,84% yang mengindikasikan hasil peramalan yang sangat baik.

3. Prediksi pergerakan harga saham pada sektor farmasi menggunakan algoritma *Long Short-Term Memory* (LSTM), (Agusta dkk, 2021)

Penelitian ini membahas pergerakan harga saham pada sektor farmasi dengan menerapkan algoritma LSTM. Data penelitian dibagi menjadi dua bagian, yaitu 80% untuk data latih dan 20% untuk data uji. Evaluasi model menggunakan metrik RMSE dengan hasil sebesar 27.310, yang menunjukkan bahwa model LSTM mampu memberikan estimasi harga saham dengan tingkat kedekatan yang baik terhadap nilai aktual.

4. Penerapan *Temporal Convolution Network* (TCN) dalam Memprediksi Harga Saham PT Bank Central Asia Tbk (Wathani dkk., 2025)

Penelitian ini bertujuan untuk meningkatkan akurasi prediksi deret waktu finansial non-linear menggunakan data historis saham BCA. Data mencakup univariat (harga penutupan) dan multivariat (harga penutupan, pembukaan, tertinggi, terendah, dan volume). Model TCN dioptimalkan dengan algoritma Adam. Evaluasi menggunakan RMSE, MSE, dan MAE menunjukkan akurasi terbaik pada 10 *epoch* dan *batch size* sebesar 1, dengan RMSE sebesar 78, MSE sebesar 6213, dan MAE sebesar 49.

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Metode	Hasil	
				RMSE	MAPE
1.	Penerapan model <i>Vector Autoregressive Integrated Moving Average</i> pada data <i>logging</i> (Antaristi dkk., 2023)	Data penelitian ini berupa data <i>well logging</i> yang terdiri dari <i>Log Gamma Ray (GR)</i> , <i>Long spacing density (LSD)</i> , dan <i>Short Spacing Density (SSD)</i>	VARIMA	–	GR : 27.74% LSD : 10.90% SSD : 7.81%
2.	Penerapan Model <i>Vector Autoregressive Integrate Moving Average</i> dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia (Jusmawati dkk., 2020)	Data penelitian ini berupa data inflasi dan data suku bunga yang diawali tahun Januari 2009 hingga Desember 2016	VARIMA	–	Inflasi : 6,04 % Suku bunga : 1,84%
3.	Prediksi pergerakan harga saham pada sektor farmasi menggunakan algoritma <i>Long Short-Term Memory (LSTM)</i> (Agusta dkk, 2021)	Data penelitian ini menggunakan harga saham dengan jumlah 761 observasi	LSTM	27.310	–
4.	Penerapan <i>Temporal Convolution Network (TCN)</i> dalam Memprediksi Harga Saham PT Bank Central Asia Tbk (Wathani dkk., 2025)	Data yang digunakan berupa data PT Bank Central Asia Tbk dari tahun 2011–2020.	TCN	78	–

2.2 Deret Waktu

Menurut Box *et al.* (2015), deret waktu merupakan sekumpulan nilai pengamatan yang diperoleh pada titik waktu berbeda dengan selang waktu yang sama, di mana data tersebut diasumsikan saling berhubungan satu sama lain. Hasil pengamatan tersebut dapat dimanfaatkan sebagai dasar dalam pengambilan keputusan untuk melakukan peramalan pada periode mendatang. Pada perhitungan deret waktu, autokorelasi menjadi aspek yang sangat diperhatikan karena data yang digunakan melibatkan nilai masa kini dan masa lalu berdasarkan interval waktu tertentu.

2.2.1 Analisis Deret Waktu

Analisis deret waktu berhubungan dengan teknik-teknik analisis ketergantungan yang membutuhkan pengembangan model stokastik dan dinamis untuk data deret waktu serta penerapannya pada berbagai bidang (Box *et al.*, 2015). Terdapat dua model utama, yaitu univariat dan multivariat. Model univariat menekankan pada pengamatan satu variabel tunggal sepanjang periode tertentu dengan tujuan mengidentifikasi pola, tren, dan karakteristik variabel untuk mendukung peramalan, sedangkan model multivariat menggunakan dua variabel atau lebih secara simultan, termasuk dalam statistik multivariat yang menganalisis hubungan temporal antar variabel dependen (Tsay, 2014). Berbeda dengan univariat yang hanya mempertimbangkan satu variabel, pendekatan multivariat mampu menangkap interaksi dinamis antar variabel sehingga dapat meningkatkan akurasi prediksi (Sarfo *et al.*, 2015).

Pada analisis deret waktu, pola data dibedakan menjadi empat pola yaitu Makridakis *et al.*, (1984):

1. Pola horizontal terjadi ketika data berfluktuasi di sekitar rata-rata yang konstan, menunjukkan bahwa data tersebut tetap stabil terhadap nilai rata-ratanya.
2. Pola tren menggambarkan kecenderungan naik atau turun dalam data sepanjang periode waktu tertentu, yang mencerminkan perubahan jangka panjang dalam data tersebut.
3. Pola musiman terjadi ketika data menunjukkan fluktuasi yang berulang secara periodik dalam jangka waktu tertentu, seperti per kuartal, per bulan, atau per hari, yang mencerminkan dampak musiman terhadap data.
4. Pola siklis ditandai dengan fluktuasi data yang berulang, namun tidak teratur, sering kali dipengaruhi oleh siklus ekonomi atau faktor eksternal lainnya yang mempengaruhi data dalam jangka panjang.

2.2.2 Peramalan Deret Waktu

Peramalan merupakan sistem matematis yang digunakan untuk memprediksi kemungkinan terjadinya suatu peristiwa di masa depan (Heizer dan Render 2015). Peramalan berperan penting dalam pengambilan keputusan di bidang bisnis, ekonomi, dan sains. Proses ini dilakukan dengan menganalisis data historis dan tren saat ini untuk memperkirakan kondisi di masa mendatang. Menurut Montgomery *et al.* (2015), metode peramalan dapat dibagi menjadi dua kategori utama, yaitu :

1. Metode Peramalan Kuantitatif

Metode kuantitatif merupakan pendekatan yang menggunakan model matematis dan statistik untuk mengidentifikasi pola tren serta hubungan antarvariabel dalam data historis. Pendekatan ini mencakup teknik seperti regresi, analisis deret waktu, hingga model prediktif berbasis *machine learning*. Keunggulannya terletak pada kemampuan menghasilkan prediksi yang objektif, terukur, dan mampu menangani data dalam skala besar serta kompleks. Di sisi lain, keberhasilan metode ini sangat ditentukan oleh kualitas dan ketersediaan data, serta relevansi pola historis terhadap kondisi masa depan yang sering kali berubah secara dinamis.

2. Metode Peramalan Kualitatif

Metode kualitatif digunakan ketika data historis tidak tersedia atau tidak lagi relevan, seperti dalam kasus peluncuran produk baru atau perubahan pasar yang drastis. Keunggulan utama pendekatan ini terletak pada fleksibilitas dalam menghadapi ketidakpastian serta kemampuannya menangkap variabel non-kuantitatif. Namun, sifatnya yang subjektif dan ketidakkonsistenan hasil membuat metode ini kurang dapat diandalkan dibandingkan pendekatan kuantitatif.

Peramalan dapat dikategorikan berdasarkan rentang waktu sebagai berikut:

1. Jangka panjang (lebih dari 18 bulan), biasanya digunakan untuk perencanaan investasi, pembangunan fasilitas, serta kegiatan *research and development*.
2. Jangka menengah (3 hingga 18 bulan), umumnya dimanfaatkan dalam perencanaan produksi, proyeksi penjualan, dan pengelolaan tenaga kerja tidak tetap.
3. Jangka pendek (kurang dari 3 bulan), diterapkan dalam pengadaan bahan baku, penjadwalan kerja, serta penugasan karyawan.

2.3 Deret Waktu Univariat

Model deret waktu univariat melibatkan satu variabel deret waktu, di mana analisis dilakukan dengan menggunakan data historis dari variabel tersebut untuk memahami pola, tren, dan fluktuasi guna meramalkan nilai di masa depan. Model *Autoregressive Integrated Moving Average* (ARIMA) adalah salah satu pendekatan yang umum digunakan dalam analisis deret waktu univariat karena kemampuannya dalam menangkap struktur data yang kompleks. Menurut Wei, (2006) model ARIMA terdiri dari komponen *autoregressive* (AR), *differencing* (I), dan *moving*

average (MA) yang digunakan untuk memodelkan data deret waktu yang non-stasioner dengan cara mengubahnya menjadi stasioner melalui proses *differencing*. Pendekatan ini banyak diterapkan dalam berbagai bidang, termasuk keuangan, ekonomi, dan kesehatan yang membantu dalam pengambilan keputusan berbasis data.

2.3.1 Autoregressive (AR)

Model *autoregressive* digunakan untuk menggambarkan kondisi di mana nilai saat ini dari suatu rangkaian waktu bergantung pada nilai-nilai sebelumnya, yang menunjukkan adanya pergerakan secara acak (Wei, 2006). Proses ini dinyatakan dalam bentuk model AR (p), di mana p menunjukkan banyaknya *lag* atau keterlambatan yang digunakan dalam memprediksi nilai saat ini. Secara matematis, model AR (p) dapat dituliskan dalam Persamaan (2.1) sebagai berikut :

$$Z_t = \phi_1 S_{t-1} + \phi_2 S_{t-2} + \cdots + \phi_p S_{t-p} + u_t \quad (2.1)$$

Keterangan:

Z_t : Deret waktu yang bersifat stasioner.

ϕ_i : Koefisien pada komponen *autoregressive*.

S_{t-i} : Nilai lag atau observasi terdahulu dari deret waktu.

u_t : Residual pada periode ke- t .

2.3.2 Moving Average (MA)

Model *moving average* adalah suatu proses yang menggambarkan keadaan ketika sebuah peristiwa memberikan pengaruh langsung tetapi hanya bersifat sementara atau berlangsung dalam jangka waktu pendek (Wei, 2006). Model MA (q) menunjukkan banyaknya lag residual yang digunakan, sehingga semakin besar nilai q , semakin panjang nilai residual yang diperhitungkan dalam menentukan nilai saat ini. Rumus model MA (q) dapat dituliskan pada Persamaan (2.2) berikut:

$$Z_t = b_t - \theta_1 b_{t-1} - \theta_2 b_{t-2} - \cdots - \theta_q b_{t-q} \quad (2.2)$$

Keterangan:

- Z_t : Deret waktu stasioner.
- b_{t-1} : Residual masa lalu.
- θ_j : Parameter *moving average*.
- b_t : Residual pada waktu ke- t .

2.3.3 Autoregressive Moving Average (ARMA)

Proses *Autoregressive Moving Average* (ARMA) menggabungkan model AR(p) dan MA(q). Hal ini digunakan untuk merepresentasikan deret waktu stasioner yang memiliki pola ketergantungan terhadap nilai masa lalu dan error masa lalu secara bersamaan (Wei,2006). Secara matematis pada model ARMA dapat dijabarkan dalam bentuk Persamaan (2.3) sebagai berikut :

$$Z_t = (\phi_1 S_{t-1} + \dots + \phi_p S_{t-p}) + (b_t - \theta_1 b_{t-1} - \dots - \theta_q b_{t-q}) \quad (2.3)$$

Keterangan :

- Z_t : Deret waktu stasioner.
- S_{t-1} : Nilai masa lalu yang berhubungan.
- ϕ_p : Parameter *autoregressive* lag- i .
- θ_q : Parameter *moving average* lag- j .
- b_t : Residual pada waktu t .
- p : Orde *autoregressive*.
- q : Orde *moving average*.

2.3.4 Autoregressive Integrated Moving Average (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan pengembangan dari model ARMA yang digunakan untuk menganalisis deret waktu non-stasioner dengan mengintegrasikan proses diferensiasi agar menjadi stasioner (Wei,2006). Proses integrasi ini memungkinkan ARIMA untuk menangani tren dalam data yang tidak dapat dijelaskan oleh ARMA secara langsung. Rumus model ARIMA dapat dijabarkan dalam Persamaan (2.4) sebagai berikut :

$$\Delta^d Z_t = \phi_1 \Delta^d S_{t-1} + \dots + \phi_p \Delta^d S_{t-p} + b_t - \theta_1 b_{t-1} - \dots - \theta_q b_{t-q} \quad (2.4)$$

Keterangan :

- Z_t : Nilai deret waktu pada periode t .
- Δ^d : Operator diferensiasi.
- S_{t-p} : Nilai masa lalu yang berhubungan.
- ϕ_p : Koefisien *autoregressive*.
- b_{t-q} : Nilai residual pada masa lalu.
- θ_q : Koefisien *moving average*.
- b_t : Residual pada waktu t .

2.4 Deret Waktu Multivariat

Deret waktu multivariat memiliki sekumpulan dua atau lebih deret waktu yang diamati secara bersamaan dalam periode waktu yang sama, di mana setiap deret merepresentasikan satu variabel yang saling berinteraksi. Berbeda dengan deret waktu univariat yang hanya menganalisis satu variabel sepanjang waktu, pendekatan multivariat memungkinkan analisis hubungan dinamis antar variabel, sehingga sangat berguna dalam sistem yang kompleks seperti ekonomi, keuangan, energi, hingga bioinformatika. Metode yang digunakan dalam deret waktu multivariat adalah VAR, VMA, VARMA, dan VARIMA.

2.4.1 Vector Autoregressive (VAR)

Model *Vector Autoregressive* merupakan pengembangan dari model AR ke dalam bentuk multivariat. Pendekatan model VAR digunakan ketika setiap variabel dalam sistem dianggap sebagai variabel endogen, yaitu dipengaruhi oleh nilai masa lalu dari dirinya sendiri maupun variabel lainnya dalam sistem (Tsay, 2014). Setiap persamaan dalam model VAR merepresentasikan suatu variabel sebagai fungsi dari lag seluruh variabel yang ada dalam model. Secara umum model VAR dapat dinyatakan dalam Persamaan (2.5) sebagai berikut:

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \cdots + \Phi_p Z_{t-p} + b_t \quad (2.5)$$

Keterangan :

- Z_t : $[Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^\top$ vektor deret waktu stasioner ukuran $N \times 1$.
- $\Phi_1, \dots, \Phi_p$: Matriks koefisien *autoregressive* berukuran $N \times N$.
- b_t : $[b_{1,t}, b_{2,t}, \dots, b_{N,t}]^\top$ vektor residual ukuran $N \times 1$.

2.4.2 Vector Moving Average (VMA)

Model *Vector Moving Average* merupakan bagian dari MA dengan metode multivariat. Teknik estimasi untuk model VMA umumnya mengadaptasi metode yang digunakan dalam kasus univariat. Menurut Tsay, (2014), model ini digunakan untuk merepresentasikan hubungan linear saat ini dengan gangguan pada periode sebelumnya. Secara umum model VMA dapat dinyatakan dalam Persamaan (2.6) sebagai berikut :

$$\mathbf{Z}_t = \mathbf{b}_t - \Theta_1 \mathbf{b}_{t-1} - \Theta_2 \mathbf{b}_{t-2} - \cdots - \Theta_q \mathbf{b}_{t-q} \quad (2.6)$$

Keterangan :

- $\mathbf{Z}_t$: $[\mathbf{Z}_{1,t}, \mathbf{Z}_{2,t}, \dots, \mathbf{Z}_{N,t}]^\top$ vektor deret waktu stasioner ukuran $N \times 1$.
- $\Theta_1, \dots, \Theta_q$: Matriks koefisien *moving average* berukuran $N \times N$.
- $\mathbf{b}_t$: $[b_{1,t}, b_{2,t}, \dots, b_{N,t}]^\top$ vektor residual ukuran $N \times 1$.

2.4.3 Vector Autoregressive Moving Average (VARMA)

VARMA (*Vector Autoregressive Moving Average*) adalah perluasan dari model univariat ARMA(p, q) ke dalam bentuk multivariat (Wei, 2006). Model ini merupakan gabungan dari model *Vector Autoregressive* (VAR) dan *Vector Moving Average* (VMA) (Anggraeni dan Dewi, 2008). Secara umum model VARMA dapat dinyatakan dalam Persamaan (2.7) sebagai berikut :

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \cdots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{b}_t - \Theta_1 \mathbf{b}_{t-1} - \cdots - \Theta_q \mathbf{b}_{t-q} \quad (2.7)$$

Keterangan :

- $\mathbf{Z}_t$: $[\mathbf{Z}_{1,t}, \mathbf{Z}_{2,t}, \dots, \mathbf{Z}_{N,t}]^\top$ vektor deret waktu stasioner ukuran $N \times 1$.
- $\Phi_1, \dots, \Phi_p$: Matriks koefisien *autoregressive* berukuran $N \times N$.
- $\Theta_1, \dots, \Theta_q$: Matriks koefisien *moving average* berukuran $N \times N$.
- $\mathbf{b}_t$: $[b_{1,t}, b_{2,t}, \dots, b_{N,t}]^\top$ vektor residual ukuran $N \times 1$.

2.4.4 Vector Autoregressive Integrated Moving Average (VARIMA)

Model *Vector Autoregressive Integrated Moving Model Average* (VARIMA) merupakan model *time series* multivariat yang sudah melalui proses *differencing* dan digunakan untuk mengetahui hubungan antara sebagian variabel pada waktu

dengan periode sebelumnya (Wei, 2006). Model VARIMA dengan orde (p, d, q) secara matematis dapat dinyatakan dalam Persamaan (2.8) sebagai berikut :

$$\Delta^d Z_t = \Phi_1 \Delta^d Z_{t-1} + \dots + \Phi_p \Delta^d Z_{t-p} + b_t - \Theta_1 b_{t-1} - \dots - \Theta_q b_{t-q} \quad (2.8)$$

Keterangan :

- Δ^d : Operator diferensiasi
- Z_t : $[Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T$ vektor deret waktu stasioner ukuran $N \times 1$.
- $\Phi_1, \dots, \Phi_p$: Matriks koefisien AR berukuran $N \times N$.
- $\Theta_1, \dots, \Theta_q$: Matriks koefisien MA berukuran $N \times N$.
- b_t : $[b_{1,t}, b_{2,t}, \dots, b_{N,t}]^T$ vektor residual (*white noise*) ukuran $N \times 1$.

2.5 Uji Asumsi

Uji asumsi merupakan langkah pertama yang penting dalam analisis statistika untuk menilai kelayakan suatu model. Langkah pertama dalam uji asumsi adalah menguji stasioneritas data, karena model hanya dapat bekerja secara optimal jika data tidak memiliki tren atau perubahan variansi yang bersifat sistematis dari waktu ke waktu. Setelah memastikan data bersifat stasioner, maka dilakukan uji asumsi, yaitu uji *white noise* untuk menunjukkan bahwa informasi dalam data telah sepenuhnya ditangkap oleh model (Wei 2006).

2.5.1 Stasioneritas Data

Pada analisis deret waktu, syarat utama yang harus dipenuhi adalah sifat stasioneritas data. Data disebut stasioner jika memiliki rata-rata dan variansi yang konstan sepanjang waktu, sehingga pola yang terkandung tetap konsisten. Ketika data bersifat tidak stasioner, misalnya karena ada pola tren atau pola musiman, maka hubungan antar variabel dapat terganggu dan menghasilkan model yang bias atau kurang akurat. Oleh karena itu, transformasi seperti *differencing* sering digunakan untuk menjadikan data stasioner.

Menurut Montgomery *et al.* (2015) menyatakan bahwa suatu deret waktu dikatakan stasioner apabila sifat-sifat statistiknya tidak berubah terhadap pergeseran waktu. Salah satu uji stasioner yang sering digunakan yaitu uji *Augmented Dickey-Fuller Test* (ADF) dengan stasioner data terhadap rata-rata. Berdasarkan uji akar unit, yaitu uji ADF, prosedur pengujian stasioneritas data dilakukan dengan tahapan sebagai

berikut :

1. Hipotesis

- $H_0 : p \geq 1$ (deret waktu tidak stasioner).
- $H_1 : p < 1$ (deret waktu stasioner).

2. Taraf signifikansi

$$\alpha = 5\% = 0.05$$

3. Kriteria Uji

- Tolak H_0 jika $ADF_{hitung} > ADF_{tabel}$ atau $p - value < \alpha$.
- Terima H_0 jika $ADF_{hitung} < ADF_{tabel}$ atau $p - value > \alpha$.

4. Statistik Uji ADF

Statistik uji ADF merupakan nilai hasil perhitungan dari metode pengujian yang digunakan untuk menentukan apakah hipotesis nol dapat ditolak atau tidak. Nilai statistik uji tersebut dijabarkan dalam Persamaan (2.9) sebagai berikut :

$$\tau = \frac{\gamma}{SE(\gamma)} \quad (2.9)$$

Keterangan:

- γ : Koefisien dari model.
- $SE(\gamma)$: Standar *error* dari koefisien γ .
- τ : Nilai statistik uji ADF.

5. Pengambilan keputusan

6. Kesimpulan

Data yang tidak stasioner bisa diubah menjadi data yang stasioner dengan melakukan proses diferensiasi. Rumusnya disajikan dalam Persamaan (2.10) sebagai berikut :

$$\Delta^d Z_t = Z_t - Z_{t-d} \quad (2.10)$$

Keterangan:

- Z_t : Diferensiasi data.
- Z_t : Data periode saat ini.
- Z_{t-1} : Data periode sebelumnya.

2.5.2 Uji White Noise

Residual dapat dikatakan jika memenuhi asumsi *white noise* dengan residual tidak bersifat acak, tidak memiliki pola tertentu, dan nilai varians konstan. Pengujian

yang dilakukan untuk uji *white noise* ini adalah *Ljung-Box* (Wei, 2006). Metode ini digunakan apakah residual mempunyai saling berkorelasi signifikan pada lag tertentu. Statistik uji ini dirumuskan pada Persamaan (2.11) sebagai berikut :

$$Q = n(n+2) \sum_{k=1}^h \frac{r_k^2}{n-k} \quad (2.11)$$

Keterangan:

Q : Statistik *Ljung-Box*.

n : Jumlah data observasi.

h : Banyaknya lag yang diuji.

r_k : Koefisien autokorelasi sampel pada lag ke- k .

2.6 Data Mining

Data mining merupakan proses otomatis dalam mengidentifikasi informasi penting dari kumpulan data yang tersimpan (Tan *et al*, 2014). Proses ini dilakukan dengan menerapkan berbagai teknik analisis dan algoritma yang mampu mengeksplorasi data secara mendalam guna mengidentifikasi pola-pola tersembunyi yang sebelumnya belum diketahui. Informasi yang diperoleh tidak hanya berfungsi sebagai dasar dalam memahami struktur data, tetapi juga memiliki kemampuan prediktif yang dapat digunakan untuk meramalkan kecenderungan atau hasil pengamatan di masa yang akan datang. Oleh karena itu, *data mining* menjadi salah satu pendekatan penting dalam mendukung proses pengambilan keputusan berbasis data dalam berbagai bidang penelitian.

2.7 Machine Learning

Machine learning merupakan bagian dari cabang *Artificial Intelligence* (AI) yang berkembang pesat dalam konteks analisis data dan komputasi yang memungkinkan aplikasi dapat berfungsi dengan cara yang cerdas (Sarker, 2021). *Machine learning* memiliki tujuan utama yaitu mengembangkan metode yang dapat mendeteksi pola tersembunyi dalam data secara otomatis dan dapat membuat pola untuk dapat memprediksikan data agar mendapatkan wawasan dalam bidang ilmiah atau lainnya. Selain itu, *machine learning* berperan penting dalam mendukung pengambilan keputusan berbasis data dan meningkatkan efisiensi analisis. Teknologi ini juga mendorong inovasi pada berbagai bidang, seperti kesehatan, ekonomi, dan industri

modern.

Ada empat jenis dalam sistem *machine learning* yang digunakan yaitu Russell, (2018) :

1. *Supervised Learning*

Supervised learning atau pembelajaran yang terawasi merupakan bagian dari *machine learning* yang digunakan pada data untuk dapat mengklasifikasikan data yang berlabel. Contohnya yaitu memprediksi harga sebuah apartemen dengan fitur seperti lokasi, jumlah kamar, fasilitas yang disebut prediktor. Jenis tugas ini disebut regresi.

2. *Unsupervised Learning*

Berbeda halnya dengan *supervised learning*, *unsupervised learning* atau pembelajaran yang tidak terawasi digunakan pada data yang tidak berlabel. Contohnya yaitu pengunjung yang ada di restoran tertentu atau mencocokkan berbagai merek motor dengan modelnya. Jenis tugas ini disebut ekstraksi fitur.

3. *Semi-supervised Learning*

Semi-supervised learning adalah pendekatan pembelajaran mesin yang menggabungkan data berlabel dan data tidak berlabel dalam proses pelatihan model. Contohnya yaitu analisis sentimen di media sosial. Jenis tugas ini termasuk dalam kategori *Natural Language Processing* (NLP) yang berfokus pada teks klasifikasi.

4. *Reinforcement Learning*

Reinforcement learning adalah pembelajaran mesin di mana sebuah agen belajar untuk membuat keputusan dengan berinteraksi dengan lingkungannya. Contohnya adalah navigasi robot seperti permainan catur yang dilakukan oleh robot. Jenis tugas ini adalah tugas episodik atau tugas yang memiliki awal dan akhir yang jelas.

2.7.1 *Scaling Data*

Scaling data merupakan teknik untuk mengubah nilai numerik dalam suatu dataset ke dalam skala yang seragam tanpa mengubah distribusi relatif antar nilai (Ambarwari dkk., 2020). Teknik ini digunakan dalam tahap *data preprocessing* setelah proses pembersihan data, pemangkasan, dan pemilihan fitur (Ahsan *et al.*, 2021). *Scaling data* memiliki peran penting dalam mempercepat proses pembelajaran dalam *machine learning* serta meningkatkan kinerja model (Arifin *et al.*, 2022). Salah satu teknik yang umum digunakan adalah *Min-Max Scaler*, yang

mengubah nilai-nilai data dari skala aslinya menjadi berada dalam rentang 0 sampai

1. Rumus *Min Max Scaler* ditunjukkan pada Persamaan (2.12) sebagai berikut :

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.12)$$

Keterangan:

- x : Nilai setelah denormalisasi.
- x' : Nilai hasil normalisasi.
- $x_{\min}$: Nilai minimum dalam dataset asli.
- $x_{\max}$: Nilai maksimum dalam dataset asli.

Melalui pendekatan ini, metode *Min-Max Scaler* menjamin bahwa nilai terkecil menjadi nol dan nilai terbesar menjadi satu. Pada nilai atribut yang tidak mengandung *outlier* akan menghasilkan transformasi dari metode *Min-Max Scaler* yang cenderung mirip dengan yang dihasilkan oleh *Standard Scaler*.

2.7.2 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi non-linear yang berperan dalam proses pelatihan jaringan saraf tiruan dengan menentukan keluaran dari *neuron* berdasarkan sejumlah masukan yang diterima (Gustineli, 2022). Fungsi aktivasi digunakan untuk menghitung nilai keluaran berdasarkan nilai masukan dan bobot pada *neuron* (Wibawa, 2017).

Pada arsitektur model TCN, fungsi aktivasi ditempatkan setelah operasi konvolusi pada setiap lapisan. Fungsi aktivasi ini berperan penting dalam memperkenalkan non-linearitas ke dalam model, memungkinkan jaringan untuk mempelajari pola data yang kompleks. Berikut adalah fungsi aktivasi yang digunakan dalam penelitian ini :

1. *Rectified Linear Unit* (ReLU)

Fungsi aktivasi ReLU menjadi pilihan populer pada jaringan saraf tiruan, tidak hanya karena kesederhanaannya tetapi juga efektivitasnya dalam mengatasi persoalan *vanishing gradient* (Riski *et al.*, 2025). Fungsi ini mengembalikan nilai input jika positif, dan nol jika negatif. ReLU umum digunakan di lapisan tersembunyi (*hidden layer*) untuk meningkatkan efisiensi pelatihan. Aktivasi dari lapisan sebelum output dapat digunakan untuk mempelajari parameter bobot lapisan klasifikasi melalui *backpropagation* (Agarap, 2018).

Adapun rumus yang digunakan dalam penerapan fungsi aktivasi ReLU

dituliskan dalam Persamaan (2.13) sebagai berikut :


$$f(x) = \begin{cases} x, & \text{jika } x \geq 0 \\ 0, & \text{jika } x < 0 \end{cases} \quad (2.13)$$

Keterangan:

x : Nilai *input*.

$f(x)$: *Output* fungsi ReLU.

Menurut Agarap (2018), fungsi ReLU tidak hanya dapat dimanfaatkan sebagai fungsi aktivasi pada lapisan tersembunyi jaringan saraf, tetapi juga berpotensi digunakan sebagai mekanisme klasifikasi pada lapisan *output*. Secara sederhana, fungsi ini akan bernilai nol apabila $x < 0$, sedangkan pada kondisi $x \geq 0$ akan membentuk hubungan linier. Grafik fungsi aktivasi ReLU dapat direpresentasikan pada Gambar 1 berikut:




Gambar 1. Fungsi Aktivasi ReLU (Wibawa, 2017)

Gambar 1 menunjukkan bahwa fungsi ReLU menghasilkan keluaran nol untuk input negatif dan linier untuk input positif. Menurut Wibawa (2017), sifat ini membuat ReLU lebih efisien dibandingkan fungsi aktivasi lain serta membantu mengatasi masalah *vanishing gradient*, sehingga proses pelatihan jaringan menjadi lebih cepat.

2. *Leaky Rectified Linear Unit* (LReLU)

Leaky ReLU memiliki gradien yang selalu ada di seluruh domainnya, berbeda dengan fungsi ReLU standar yang tidak memiliki gradien pada bagian tertentu (Maas *et al*, 2013). Pendekatan ini membantu menghindari terjadinya *neuron* yang tidak aktif sepenuhnya akibat input negatif, yang merupakan

kelemahan umum pada ReLU. Selain itu, metode Leaky ReLU dinilai lebih responsif terhadap data deret waktu yang memiliki distribusi fitur tidak merata (Maniatopoulos & Mitianoudis, 2021). Grafik pada fungsi aktivasi LeakyReLU dapat divisualisasikan pada Gambar 2 berikut:



Gambar 2. Fungsi Aktivasi *Leaky ReLU* (Layton *et al*,2024)

Gambar 2 memperlihatkan perbandingan dua fungsi aktivasi, yaitu ReLU (garis hitam) dan LeakyReLU (garis biru). ReLU menghasilkan keluaran nol pada input negatif dan linier pada input positif, sedangkan LeakyReLU tetap memberikan keluaran kecil pada *input* negatif sehingga mencegah terjadinya *neuron dying*. Pendekatan ini membuat LeakyReLU lebih stabil dalam proses pelatihan jaringan. Rumus LeakyReLU ditunjukkan pada Persamaan (2.14) berikut:

$$f(x) = \begin{cases} x & , x \geq 0 \\ ax & , x < 0 \end{cases} \quad (2.14)$$

Keterangan :


x : Nilai input.

a : Kemiringan negatif kecil (*negative slope*).

$f(x)$: *Output* fungsi LeakyReLU.

3. Linear

Fungsi aktivasi linear merupakan fungsi yang tidak memiliki sifat non-linear, melainkan berperan sebagai fungsi identitas. Fungsi ini digunakan pada data berbentuk regresi pada hasil output layernya (Pratama dkk, 2019). Penggunaan fungsi linear pada *output layer* memudahkan model dalam menghasilkan prediksi yang bebas dalam rentang riil, tanpa pembatasan tertentu sebagaimana terjadi pada fungsi aktivasi lain seperti *sigmoid* atau *tanh*. Fungsi aktivasi linear ditampilkan pada Gambar 3 sebagai berikut :



Gambar 3. Fungsi Aktivasi Linear (Marimuthu,2022)

Gambar 3 memperlihatkan bentuk fungsi aktivasi linear. Grafik ditampilkan bahwa garis lurus yang melewati titik asal dengan kecenderungan meningkat secara proporsional terhadap nilai input. Visualisasi tersebut menunjukkan bahwa fungsi ini tidak melakukan transformasi nonlinear, sehingga nilai keluaran sama persis dengan nilai masukan. Karakteristik ini membuat fungsi linear banyak digunakan pada lapisan keluaran dalam permasalahan regresi, misalnya ketika memprediksi harga saham yang membutuhkan hasil kontinu tanpa adanya batasan tertentu.

Secara sistematis, fungsi aktivasi linear dapat dinyatakan dengan Persamaan (2.15) sebagai berikut :

$$f(x) = x \quad (2.15)$$

Keterangan :

x : Input.

$f(x)$: Output fungsi Linear.

Persamaan (2.15) menunjukkan bahwa fungsi hanya meneruskan nilai input menjadi output tanpa melakukan transformasi, sehingga model dapat memproyeksikan hasil prediksi ke dalam rentang bilangan riil tanpa batasan tertentu.

2.7.3 Unscaling Data

Unscaling data merupakan proses mengembalikan data yang masih ternormalisasi ke dalam bentuk angka desimal yang sebenarnya (Kuntarini, 2024). Proses *unscaling data* dimulai dengan mereduksi skema dasar menjadi sekelompok atribut yang tidak memiliki tabel utama, dan dengan memisahkan atribut-atribut majemuk.

Salah satu teknik *scaling data* yang umum digunakan adalah *Min-Max Scaler*, yang mengubah nilai data ke dalam rentang antara 0 hingga 1. Pada teknik ini, nilai minimum akan dipetakan menjadi 0, dan nilai maksimum menjadi 1. Proses transformasi ini ditunjukkan pada Persamaan (2.16) sebagai berikut :

$$x = x' \cdot (x_{\max} - x_{\min}) + x_{\min} \quad (2.16)$$

Keterangan:

- x : Nilai setelah *unscaling data*.
- x' : Nilai hasil *scaling data*.
- $x_{\min}$: Nilai minimum dalam *dataset* asli.
- $x_{\max}$: Nilai maksimum dalam *dataset* asli.

2.7.4 Hyperparameter Tuning

Hyperparameter tuning merupakan proses penentuan parameter yang ditetapkan sebelum pelatihan dan tidak diperbarui selama pembelajaran (Yu & Zhu, 2020). Optimasi *hyperparameter* berperan penting dalam menentukan arsitektur jaringan saraf dan meningkatkan kinerja model (Yang & Shami, 2020). Komponen yang umum digunakan meliputi *batch size* yang menentukan jumlah sampel dalam satu iterasi pembaruan bobot, *learning rate* yang mengatur besar langkah dalam proses optimasi, jumlah *epoch* sebagai banyaknya siklus pelatihan, *hidden layer* dan *neuron* yang memengaruhi kapasitas representasi model, *dropout rate* untuk mencegah *overfitting*, serta pemilihan algoritma optimasi seperti SGD, Adam, atau RMSprop.

Optimasi hyperparameter dapat dilakukan dengan berbagai metode, seperti *grid search*, *random search*, maupun *bayesian optimization*. *Optuna* yang berbasis *bayesian optimization* dinilai efektif karena mampu menyesuaikan pencarian secara dinamis dengan biaya komputasi lebih rendah.

2.8 Deep Learning

Deep learning merupakan cabang dari pembelajaran mesin yang memanfaatkan jaringan saraf sebagai pendekatan fungsi dengan penekanan pada penumpukan banyak lapisan komponen yang serupa secara struktural (Roberts *et al.*, 2021). Konsep ini berakar pada *Artificial Neural Network* (ANN), di mana *neuron* atau lapisan saling terhubung membentuk jaringan kompleks yang mampu meniru cara kerja otak

manusia (Raup *et al.*, 2022). Arsitektur *deep learning* terdiri atas tiga bagian utama, yaitu lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Metode ini efektif untuk mengolah data berukuran besar karena mampu menemukan pola nonlinier serta mengekstraksi fitur penting tanpa rekayasa manual. Peningkatan jumlah lapisan berkorelasi positif terhadap peningkatan tingkat akurasi model (Sapitri dkk., 2024).


Pengembangan *deep learning* berbasis jaringan saraf digunakan secara luas dalam berbagai bidang penelitian meliputi analisis deret waktu, analisis sentimen, pemrosesan bahasa alami, pengenalan visual, kecerdasan bisnis, keamanan siber, dan berbagai penelitian lainnya. Pada konteks analisis deret waktu, jaringan saraf tiruan konvensional memiliki keterbatasan karena tidak mampu mengintegrasikan informasi baru dengan data historis. Model *Temporal Convolutional Network* (TCN) muncul sebagai pendekatan efektif untuk mengatasi keterbatasan tersebut, dikembangkan dari model *Convolutional Neural Network* (CNN). Arsitektur CNN mengekstraksi fitur melalui beberapa lapisan, meliputi lapisan konvolusi yang berfungsi menyaring pola, lapisan aktivasi yang menambahkan sifat nonlinier, serta lapisan *pooling* yang mereduksi dimensi data tanpa kehilangan informasi penting. Prinsip-prinsip tersebut menjadi dasar pengembangan TCN yang dioptimalkan untuk analisis deret waktu, sedangkan CNN lebih sesuai untuk data visual atau berbasis citra (Bai *et al.*, 2018).

2.8.1 *Convolutional Neural Network* (CNN)

Convolutional neural network merupakan jaringan syaraf tiruan terbaru yang terdiri dari beberapa *neuron* yang dapat mengoptimalkan melalui pembelajaran mesin (Saxena, 2022). Kegunaan model CNN lebih sering diterapkan pada data citra dibandingkan data deret waktu (Pangestika & Josaphat, 2025). Seiring perkembangan model *deep learning* dapat digunakan dalam peramalan pada data saham. Model CNN memanfaatkan struktur jaringan konvolusional untuk menangkap pola temporal secara multikanal (Zheng *et al.*, 2014). Secara umum, model CNN terdiri dari dua lapisan utama, yaitu lapisan ekstraksi fitur dan lapisan yang terhubung penuh. Lapisan ekstraksi fitur, yang berada setelah lapisan input, mencakup *convolutional layer* dan *pooling layer*.

Convolutional layer menggunakan *kernel* yang bergerak melalui data input untuk mengekstraksi fitur lokal, meningkatkan nonlinieritas model melalui fungsi aktivasi. Sedangkan *pooling layer* digunakan untuk mengurangi dimensi spasial dari peta fitur, mengurangi kompleksitas komputasi dan mengurangi *overfitting* (Ding *et al.*, 2025).

Kedua lapisan ini bekerja secara sinergis dalam menyaring dan mengidentifikasi fitur penting dari data deret waktu, yang kemudian digunakan dalam lapisan-lapisan selanjutnya untuk membuat prediksi atau klasifikasi yang lebih akurat. Arsitektur CNN ditampilkan dalam Gambar 4 sebagai berikut :



Gambar 4. Arsitektur CNN (Saxena,2022)

Gambar 4 memperlihatkan lapisan *input* berfungsi sebagai penerima data yang akan diproses. Di lapisan konvolusional, filter diterapkan pada fitur yang masuk untuk menghasilkan peta fitur (*feature map*). Kemudian, lapisan *pooling* mengurangi dimensi peta fitur yang dihasilkan, dan lapisan *flatten* mengubah peta tersebut menjadi vektor satu dimensi (Saxena, 2022). Vektor ini kemudian diteruskan ke lapisan *fully connected*, di mana *Multi-Layer Perceptron* (MLP) digunakan untuk memproses data sehingga diperoleh hasil yang diinginkan.

2.8.2 Temporal Convolutional Network (TCN)

Temporal Convolutional Network adalah sebuah arsitektur jaringan saraf yang dirancang untuk memproses data deret waktu atau data urutan lainnya. Model TCN merupakan pengembangan dari model *Convolutional Neural Network* yang menggunakan konvolusi kausal dan dikombinasikan dengan dilatasi untuk memastikan bahwa tidak ada informasi dari masa depan yang bocor ke masa lalu (Bai *et al.*, 2018). Pada penelitiannya juga menjelaskan bahwa arsitektur model TCN dapat mengambil urutan dengan panjang *input* berapapun dan memetakannya ke urutan *output* dengan panjang yang sama, seperti halnya dengan *Recurrent Neural Network* (RNN). Kemudian dari penelitian Wan *et al.*, (2019), menjelaskan bahwa model TCN dapat menyaring model terbaik pada desain jaringan konvolusi dengan kerangka kerja yang fleksibel dan stabil untuk peramalan deret waktu multivariat. Adapun arsitektur dari model TCN sebagai berikut :

1. *Causal Convolutions*

Causal convolution pada model TCN memastikan bahwa proses prediksi deret waktu dilakukan tanpa kebocoran informasi dari masa depan ke masa lalu. *Output* pada waktu t hanya bergantung pada nilai masukan hingga waktu t dan tidak dipengaruhi oleh data setelah waktu tersebut. Operasi konvolusi kausal pada waktu t dinyatakan pada Persamaan (2.17) sebagai berikut:

$$y_t = \sum_{i=0}^{k-1} w_i \cdot x_{t-i} \quad (2.17)$$


Keterangan :

- y_t : *Output* pada waktu ke- t .
- x_{t-i} : *Input* pada waktu ke- $t - i$.
- w_i : Bobot *kernel* atau *filter* pada posisi ke- i .
- k : Ukuran *kernel* konvolusi.
- t : Indeks waktu pengamatan.

Persamaan (2.17) menunjukkan bahwa y_t merepresentasikan keluaran pada waktu t , x_{t-i} merupakan *input* pada waktu $t - i$, w_i adalah bobot *kernel* pada posisi i , dan k menyatakan ukuran *kernel* yang digunakan. Struktur ini membentuk jaringan konvolusional satu dimensi penuh (*one-dimensional fully convolutional network*) yang menjaga kesetaraan panjang antara *input* dan *output* melalui penerapan *zero padding* sebesar $k - 1$. Proses *zero padding* tersebut memastikan bahwa setiap posisi dalam deret waktu memiliki jumlah elemen konvolusi yang sama, sehingga panjang sekuens tetap konsisten setelah proses konvolusi.

2. *Dilated Convolutions*

Model TCN mengimplementasikan *dilated convolutions* untuk menangkap ketergantungan jangka panjang tanpa menambah jumlah lapisan secara signifikan. Mekanisme dilatasi pada *kernel* konvolusi memperluas *receptive field* secara bertahap sehingga pola temporal yang lebih panjang dapat dimodelkan secara efisien. Integrasi *dilated convolutions* meningkatkan kemampuan TCN dalam mengenali pola jangka panjang dalam data urutan dengan efisiensi komputasi lebih tinggi dibandingkan hanya menggunakan *causal convolutions*.



Gambar 5. Arsitektur TCN (Bai *et al.*,2018)

Gambar 5 menunjukkan penggabungan *causal* dan *dilated convolutions* pada TCN menghasilkan model yang efektif untuk pemodelan data urutan. Model TCN mampu mempertahankan kausalitas temporal sekaligus menangkap ketergantungan jangka pendek, menengah, dan panjang dalam data. Adapun rumus *dilated convolutions* pada Persamaan (2.18) sebagai berikut :

$$F(s) = \sum_{i=0}^{k-1} f(i)x_{s-d \cdot i} \quad (2.18)$$

Keterangan :

$F(s)$: Hasil konvolusi pada posisi s .

x : Data input.


f : Filter dengan panjang k .

d : Dilatasi.

k : Ukuran *filter*.

s : Posisi tertentu dalam *output*.

Proses konvolusi dilatasi yang ditunjukkan dengan memasukkan jarak antar elemen input berdasarkan tingkat dilatasi d . Visualisasi dari proses ini disajikan pada Gambar 6 sebagai berikut :



Gambar 6. Visualisasi Perlebaran Pada *Layer* (Wan *et al.*,2019)

Gambar 6 menunjukkan bagaimana faktor pelebaran (*dilation*) memengaruhi penempatan *kernel* konvolusi pada data satu dimensi. Saat $d = 1$, *kernel* ditempatkan secara berurutan tanpa jeda. Pada $d = 2$, setiap elemen *kernel* melompati satu sel di antara dua posisi *kernel*. Ketika $d = 4$, setiap elemen *kernel* melompati tiga sel di antara dua posisi *kernel* (Wan *et al.*, 2019). Semakin besar nilai d , semakin luas jangkauan (*receptive field*) konvolusi karena *kernel* dapat melompati lebih banyak titik data, sehingga mampu menangkap ketergantungan jangka panjang pada urutan. Kombinasi antara *dilated convolutions* dan *causal convolutions* membentuk *dilated causal convolutions*, yaitu pendekatan yang mempertahankan urutan waktu tanpa kebocoran informasi dari masa depan sekaligus memperluas cakupan pengamatan model terhadap konteks historis yang lebih panjang.

Luas jangkauan pengamatan jaringan atau *receptive field* menunjukkan seberapa banyak informasi historis yang dapat diakses oleh model saat melakukan prediksi. Nilai ini meningkat seiring bertambahnya ukuran *kernel*, jumlah lapisan, dan faktor dilatasi pada setiap lapisan, seperti yang ditunjukkan pada Persamaan (2.19) sebagai berikut:

$$R = 1 + (k - 1) \sum_{i=0}^{L-1} d_i \quad (2.19)$$

Keterangan:

R : Jangkauan pengamatan (*receptive field*).

k : Ukuran *kernel*.

L : Jumlah lapisan konvolusi.

d_i : Faktor dilatasi pada lapisan ke- i .

3. *Residual Block*


Model TCN menggunakan blok residual generik untuk meningkatkan kedalaman jaringan dan memperluas bidang reseptif (He *et al.*, 2015). Blok residual dasar diterapkan pada model TCN, tetapi koneksi lompatan (*skip connection*) dalam ResNet membuat hanya sebagian blok yang mampu mempelajari informasi penting. Struktur blok residual dasar belum optimal untuk prediksi deret waktu. Alternatifnya berupa peningkatan ukuran kernel konvolusi, tetapi hal ini secara signifikan menambah beban komputasi. Rumus blok residual ditunjukkan pada Persamaan (2.20) sebagai berikut:

$$o = \text{Activation}(x + F(x)) \quad (2.20)$$

Keterangan :


- o : *Output* dari blok residual.
- x : *Input* awal ke blok residual.
- $F(x)$: Fungsi yang mewakili transformasi nonlinear.

Fungsi data awal yang masuk ke blok, yaitu x , tidak hanya diproses melalui serangkaian operasi nonlinier yang diwakili oleh $F(x)$, tetapi juga langsung dijumlahkan kembali dengan hasil dari proses tersebut. Setelah penjumlahan, hasilnya kemudian dilewatkan ke fungsi aktivasi untuk menghasilkan *output* akhir o . Proses penjumlahan antara *input* dan hasil transformasi ini memungkinkan jaringan untuk belajar mengenali residual antara *input* dan target *output*, bukan mempelajari keseluruhan pemetaan secara langsung. Pendekatan seperti ini membantu mempercepat proses pelatihan dan mencegah turunnya akurasi ketika jaringan memiliki banyak lapisan. Visualisasi *residual block* akan ditampilkan pada Gambar 7 sebagai berikut :



Gambar 7. *Residual Block* (Bai *et al.*, 2018)

Gambar 7 menjelaskan struktur blok residual dalam arsitektur model TCN berdasarkan penelitian dari Bai *et al.*, (2018). Gambar ini menunjukkan cara *dilated convolution*, aktivasi ReLU, *dropout*, dan fitur lainnya yang digunakan secara terstruktur untuk memungkinkan pelatihan jaringan yang dalam tanpa kehilangan informasi penting dari *input* awal. *Residual block* menjadi elemen kunci dalam memastikan stabilitas dan efektivitas model TCN dalam menangkap dependensi jangka panjang pada data deret waktu. Sebagai contoh, akan ditampilkan Gambar 8 dengan menggunakan *kernel* sebesar 3 dan dilatasi sebesar 1 sebagai berikut :



Gambar 8. *Residual Block* ($k = 3, d = 1$) (Bai *et al.*, 2018)

Jalur utama (garis biru) menggunakan konvolusi kausal satu dimensi dengan ukuran kernel $k = 3$ dan laju dilasi $d = 1$. Proses ini menghasilkan fitur terproses $\hat{z}_T^{(1)}$. Jalur kedua, yang disebut *Identity Map* (garis hijau), adalah jalur pintas (*shortcut*) yang membawa input asli x_T dan menambahkannya ke output dari jalur konvolusi utama. Penambahan (*summation*) ini penting karena memastikan bahwa informasi input dapat mengalir dengan mudah melintasi blok, memitigasi masalah *vanishing gradient*, serta memungkinkan jaringan mempelajari informasi jangka panjang secara efektif.

2.9 Hybrid VARIMA-TCN

Metode *hybrid* merupakan perkembangan dari sebuah peramalan dalam deret waktu yang menggabungkan metode tunggal, salah satunya dengan mengombinasikan model VARIMA dan model TCN. Kedua metode ini digunakan untuk menangani permasalahan data yang bersifat linier maupun nonlinier. Pengembangan metode hibrida bertujuan untuk meningkatkan efisiensi dalam proses analisis peramalan deret waktu (Zhang, 2003).

Pendekatan ini diperlukan karena pola data dalam deret waktu sering kali tidak dapat dipastikan apakah bersifat linier atau nonlinier, sehingga penggunaan lebih dari satu metode dapat meningkatkan akurasi hasil prediksi. Secara umum, model *hybrid* yang menggabungkan dua metode dalam deret waktu dengan struktur autokorelasi linier dan nonlinier dapat direpresentasikan dengan Persamaan (2.21) sebagai berikut :

$$y_t = L_t + N_t \quad (2.21)$$

Keterangan:

- z_t : Nilai aktual pada waktu t .
- L_t : Komponen linier pada waktu t .
- N_t : Komponen nonlinier pada waktu t .
- t : Indeks waktu.

Residual memiliki peran penting dalam menilai seberapa baik suatu model linier bekerja. Pada konteks ini, pendekatan pemodelan residual dengan menggunakan model TCN memungkinkan untuk menangkap hubungan nonlinier dalam data deret waktu. Pemodelan residual dengan model TCN menggunakan n input dapat diformulasikan pada Persamaan (2.22) sebagai berikut :

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \epsilon_t \quad (2.22)$$

Keterangan:

- e_t : Nilai residual pada waktu t .
- f : Fungsi nonlinier dari model TCN.
- ϵ_t : Galat atau noise pada waktu t .

Hasil akhir dari penggabungan metode peramalan ini dituliskan pada Persamaan (2.23) sebagai berikut:

$$\hat{y}_t = L'_t + N'_t \quad (2.23)$$

Keterangan:

- $\hat{y}_t$: Prediksi dari model *hybrid* pada waktu t .
- L'_t : Prediksi komponen linier dari VARIMA pada waktu t .
- N'_t : Prediksi komponen residual dari TCN pada waktu t .

2.10 Evaluasi Model

Evaluasi model digunakan untuk melihat tingkat akurasi model. Pada teknik peramalan deret waktu, setiap model pasti memiliki nilai *error* atau kesalahan pada setiap tahapannya. Evaluasi ini bertujuan untuk mengukur sejauh mana model *hybrid* VARIMA-TCN menghasilkan prediksi yang akurat. Beberapa metrik yang umum digunakan dalam evaluasi kesalahan pada teknik peramalan deret waktu antara lain *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

1. *Root Mean Square Error* (RMSE)

Root Mean Square Error digunakan untuk menghitung nilai akar kuadrat dari data aktual dan data prediksi. Metode RMSE seringkali digunakan saat pada model

machine learning dan model *deep learning* untuk melihat nilai galat kuadrat terkecil pada suatu model. Berikut Persamaan metode RMSE pada (2.24) :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (P_t - A_t)^2} \quad (2.24)$$

Keterangan:

P_t : Nilai prediksi.

A_t : Nilai aktual.

n : Jumlah data.

2. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error sering digunakan dalam praktik karena interpretasi yang sangat intuitif dalam hal kesalahan yang relatif. Penggunaan metode MAPE relevan di bidang keuangan, misalnya, karena keuntungan dan kerugian sering kali dihitung dalam nilai relatif. (Myttenaere *et al.*, 2016). Adapun rumus metode MAPE yang disajikan pada Persamaan (2.25) sebagai berikut :

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (2.25)$$

Keterangan:

n : Frekuensi iterasi penjumlahan terjadi.

A_t : Nilai aktual.

F_t : Nilai perkiraan.

2.11 Goodness Of Fit

Konsep dari uji *goodness of fit Kolmogorov-Smirnov* adalah membandingkan fungsi distribusi kumulatif empiris dari data sampel dengan fungsi distribusi kumulatif teoritis dari populasi (Amelia dkk., 2024). Uji ini digunakan untuk mengevaluasi sejauh mana data mengikuti distribusi tertentu. Adapun perhitungan uji *goodness of fit* yang disajikan pada Persamaan (2.26) sebagai berikut:

$$KS = \sup_x \left| \hat{F}_n(x) - F_0(x; \theta) \right| \quad (2.26)$$

Keterangan:

KS : Statistik Kolmogorov-Smirnov.

$F_n(x)$: Fungsi distribusi kumulatif empiris dari data sampel.

$F(x)$: Fungsi distribusi kumulatif teoretis.

sup : Nilai maksimum dari selisih absolut kedua fungsi.

BAB III

METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada semester genap tahun akademik 2025/2026 dan terbagi ke dalam tiga tahapan utama sesuai dengan jadwal yang telah direncanakan. Tahap pertama mencakup kegiatan studi literatur, penentuan topik penelitian, pengumpulan data, penyusunan Bab I hingga Bab III, serta pelaksanaan seminar proposal yang berlangsung pada Februari hingga April 2025. Pada tahap kedua, fokus kegiatan adalah analisis dan pengolahan data awal (*preprocessing data*), pembangunan model VARIMA, penyesuaian *hyperparameter* pada model TCN, serta pengembangan dua model *hybrid* VARIMA–TCN, yang dilakukan pada periode April hingga Juni 2025. Tahap ketiga meliputi penyusunan Bab IV dan V, pelaksanaan seminar hasil, serta sidang komprehensif yang dijadwalkan berlangsung dari Juli hingga September 2025.

Penelitian ini dilakukan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung yang berlokasi di Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedong Meneng, Bandar Lampung.

3.2 Data dan Alat Penelitian

3.2.1 Data Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh melalui situs *Yahoo Finance*, berupa harga saham harian dari dua emiten farmasi besar di Indonesia, yaitu PT Kalbe Farma Tbk <https://finance.yahoo.com/quote/KLBF.JK/history/> dan PT Merck Tbk <https://finance.yahoo.com/quote/MERK.JK/history/>. Seluruh variabel yang digunakan termasuk dalam kategori endogen, dengan fokus utama pada harga penutupan saham PT Merck Tbk (MERK). Pengambilan data dilakukan melalui

library yfinance pada platform *Jupyter Notebook*. Rentang waktu data mencakup periode 02 November 2020 hingga 30 Januari 2025 dengan total observasi sebanyak 1027 data. Rangkaian data tersebut dirangkum pada Tabel 2 berikut:

Tabel 2. Data Penelitian

Periode	MERK	KLBF
02-11-2020	2269.9395	1322.3038
03-11-2020	2292.3403	1326.6537
04-11-2020	2284.8736	1339.7029
...	...	...
23-01-2025	3329.1819	1206.3162
24-01-2025	3329.1819	1191.6646
30-01-2025	3300.7273	1206.3162

3.2.2 Alat Penelitian

Peralatan yang digunakan dalam penelitian ini adalah:

1. Perangkat Keras (*Hardware*)

- *Laptop: Acer Aspire 4738Z, 64-bit operation system, x64-based processor.*
- *Processor: Intel(R) Pentium(R) CPU P6200 @ 2.13 GHz (2CPUs).*
- *Memory: 6GB (6144MB)*

2. Perangkat Lunak (*Software*)

- *Sistem Operasi: Windows 10 Pro*
- *Menggunakan Google Colaboratory*
- *Python versi Python 3.11*

Adapun *library* yang digunakan pada penelitian ini sebagai berikut :

- *Pandas 2.2.2* : Digunakan untuk manipulasi dan analisis data berbasis struktur *dataframe*.
- *NumPy 1.26.0* : Digunakan untuk komputasi numerik dan operasi array multidimensi.
- *Matplotlib 3.7.2* : Digunakan untuk membuat visualisasi data dalam bentuk grafik dua dimensi.
- *Seaborn 0.12.2* : Digunakan untuk memperbagus tampilan visualisasi pada *library matplotlib*.
- *Scikit-learn 1.4.2* : Digunakan untuk *preprocessing* data serta evaluasi model dengan metrik seperti RMSE dan MAPE.

- *Statsmodels* 0.14.4 : Digunakan untuk analisis statistik, digunakan dalam pembangunan dan estimasi model VARIMA.
- *TensorFlow* 2.19.0 : *Framework deep learning* untuk membangun dan melatih model TCN.
- *SciPy* 1.6.0 : Mendukung komputasi ilmiah termasuk optimisasi dan statistik lanjutan.
- *Keras-tcn* 3.5.6 : *Library* yang digunakan khusus pada model TCN.
- *Optuna* versi 4.5.0 : *library* untuk optimasi hiperparameter secara otomatis menggunakan metode pencarian berbasis *Tree-structured Parzen Estimator* (TPE).

3.3 Metode Penelitian

Tahap awal penelitian ini dilakukan melalui telaah referensi yang bersumber dari jurnal ilmiah, artikel, dan buku yang membahas pendekatan *hybrid* VARIMA–TCN. Telaah tersebut digunakan sebagai dasar konseptual untuk memahami teori, kerangka metodologis, serta temuan empiris terdahulu yang relevan dalam mendukung penyusunan proposal dan pelaksanaan analisis. Setelah landasan teori diperoleh, dilakukan percobaan awal terhadap data saham sebagai validasi pemahaman metodologi yang diterapkan. Percobaan ini bertujuan menilai kelayakan metode pada konteks data saham sekaligus menjadi pedoman dalam merancang tahapan analisis lanjutan. Selain itu, penelusuran referensi juga berperan dalam menentukan strategi *preprocessing*, pemilihan *hyperparameter*, serta rancangan evaluasi yang sesuai dengan karakteristik data dan sasaran penelitian.

Adapun langkah-langkah yang dilakukan dalam peramalan menggunakan model VARIMA, model TCN, dan model *hybrid* VARIMA-TCN adalah sebagai berikut :

1. Model VARIMA

- Data dimasukkan ke dalam bahasa pemrograman *Python* menggunakan *Google Colaboratory*.
- Visualisasi data dilakukan untuk mengamati keberadaan pola tren serta fluktuasi yang terdapat dalam data.
- Data dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian. Proporsi ini dipilih karena data pelatihan dianggap cukup dalam menangkap pola serta kompleksitas data, sementara data pengujian dinilai memadai untuk mewakili data baru. Skema pembagian ini juga menjaga kestabilan model terhadap risiko *overfitting* dan *underfitting*, sehingga

model mampu bekerja secara optimal pada data yang belum pernah dilihat sebelumnya.

- Proses *preprocessing* dilakukan pada data pelatihan dengan mengecek adanya *missing value* dan menganalisis korelasi antara variabel MERK dan KLBF.
- Uji stasioneritas dilakukan terhadap data pelatihan menggunakan metode *Augmented Dickey-Fuller (ADF)*. Jika data belum stasioner, maka dilakukan proses *differencing* agar data menjadi stasioner.
- Model VARIMA diidentifikasi dengan menganalisis *lag* yang melewati batas signifikansi berdasarkan plot *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)*, serta menentukan orde *differencing* untuk mencapai kestasioneran data.
- Parameter model VARIMA diestimasi menggunakan metode *Maximum Likelihood Estimation*. Model terbaik dipilih berdasarkan nilai *Bayesian Information Criterion (BIC)* terkecil, karena nilai BIC memberikan penalti lebih besar terhadap kompleksitas model dibandingkan nilai *Akaike Information Criterion AIC*, sehingga mendorong pemilihan model yang lebih sederhana namun tetap optimal.
- Prediksi dilakukan pada data pelatihan dan data pengujian menggunakan model VARIMA terbaik yang telah dipilih.
- Evaluasi terhadap model VARIMA dilakukan dengan menghitung nilai RMSE, MAPE, dan akurasi.
- Peramalan dilakukan menggunakan model VARIMA yang telah dibangun dan dievaluasi.
- Residual dari model VARIMA dihitung, kemudian diuji dengan menggunakan uji *Ljung-Box* untuk memastikan bahwa residual bersifat *white noise*.

2. Model TCN

- Data dimasukkan ke dalam bahasa pemrograman *Python* menggunakan *Google Colaboratory*.
- Visualisasi data dilakukan untuk mengamati pola tren dan fluktuasi yang terdapat dalam data.
- Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Pembagian ini mempertahankan kestabilan model terhadap risiko *overfitting* dan *underfitting*, sekaligus memastikan data pengujian cukup representatif.
- Proses *preprocessing* dilakukan dengan mengecek adanya *missing value* dan menganalisis korelasi antara variabel MERK dan KLBF.


- Data hasil *preprocessing* diskalakan menggunakan Min-Max Scaler agar nilai berada dalam rentang [0,1].
- Parameter model TCN seperti *nb_filters*, *kernel_size*, *dropout_rate*, dan parameter lainnya ditentukan melalui *hyperparameter optimization* menggunakan *Optuna*.
- Model TCN dibangun untuk menghasilkan prediksi dan peramalan.
- Prediksi dan peramalan dilakukan menggunakan model TCN yang telah dibangun.
- Hasil prediksi dalam skala [0,1] dikembalikan ke skala semula melalui metode *unscaling*.
- Evaluasi model dilakukan menggunakan metrik RMSE, MAPE, dan akurasi.
- Melakukan peramalan pada model TCN dengan menggunakan data *update* sebagai data aktual peramalan.

3. Model *hybrid* VARIMA-TCN


- Data dimasukkan ke dalam bahasa pemrograman *Python* menggunakan *Google Colaboratory*.
- Visualisasi data dilakukan untuk mengamati keberadaan pola tren serta fluktuasi yang terdapat dalam data.
- Data dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian. Proporsi ini dipilih karena data pelatihan dianggap cukup dalam menangkap pola serta kompleksitas data, sementara data pengujian dinilai memadai untuk mewakili data baru. Skema pembagian ini juga menjaga kestabilan model terhadap risiko *overfitting* dan *underfitting*, sehingga model mampu bekerja secara optimal pada data yang belum pernah dilihat sebelumnya.
- Proses *preprocessing* dilakukan pada data pelatihan dengan mengecek adanya *missing value* dan menganalisis korelasi antara variabel MERK dan KLBF.
- Uji stasioneritas dilakukan terhadap data pelatihan menggunakan metode *Augmented Dickey-Fuller (ADF)*. Jika data belum stasioner, maka dilakukan proses *differencing* agar data menjadi stasioner.
- Model VARIMA diidentifikasi dengan menganalisis *lag* yang melewati batas signifikansi berdasarkan plot *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)*, serta menentukan orde *differencing* untuk mencapai kestasioneran data.

- Parameter model VARIMA diestimasi menggunakan metode *Maximum Likelihood Estimation*. Model terbaik dipilih berdasarkan nilai *Bayesian Information Criterion* (BIC) terkecil, karena nilai BIC memberikan penalti lebih besar terhadap kompleksitas model dibandingkan nilai *Akaike Information Criterion* (AIC), sehingga mendorong pemilihan model yang lebih sederhana namun tetap optimal.
- Prediksi dilakukan pada data pelatihan dan data pengujian menggunakan model VARIMA terbaik yang telah dipilih.
- Residual dari model VARIMA dihitung, kemudian diuji dengan menggunakan uji *Ljung-Box* untuk memastikan bahwa residual bersifat *white noise*.
- Evaluasi terhadap model VARIMA dilakukan dengan menghitung nilai RMSE, MAPE, dan akurasi.
- Peramalan dilakukan menggunakan model VARIMA yang telah dibangun dan dievaluasi.
- Data residual dari model VARIMA disiapkan sebagai *input* untuk model E_TCN, sedangkan data prediksi model VARIMA digunakan sebagai *input* untuk model P_TCN.
- Data residual dan prediksi VARIMA diskalakan menggunakan metode *Min-Max Scaler* agar siap digunakan dalam proses pelatihan model.
- Proses *hyperparameter tuning* dilakukan terhadap model E_TCN dan model P_TCN untuk memperoleh parameter terbaik.
- Model E_TCN dan model P_TCN dibangun menggunakan parameter optimal yang telah diperoleh pada tahap sebelumnya.
- Prediksi dan peramalan dilakukan menggunakan model E_TCN dan model P_TCN.
- Hasil prediksi dan peramalan dari model E_TCN dan P_TCN dikembalikan ke skala semula melalui proses *unscaling*.
- Data hasil prediksi dan peramalan dari model VARIMA dan E_TCN digabungkan melalui penjumlahan untuk membentuk model *hybrid* VARIMA-E_TCN. Data hasil prediksi dan peramalan dari model E_TCN dan P_TCN juga digabungkan dengan cara yang sama untuk membentuk model *hybrid* EP_TCN.
- Evaluasi akhir dilakukan terhadap kedua model *hybrid* dengan menghitung nilai RMSE, MAPE, dan akurasi untuk menilai performa model dalam melakukan prediksi dan peramalan.


Berikut ini merupakan *flowchart* model *hybrid* VARIMA-TCN :




Gambar 9. *Flowchart* Model VARIMA



Gambar 10. *Flowchart Model TCN*



Gambar 11. Flowchart Model Hybrid VARIMA–E_TCN



Gambar 12. Flowchart Model Hybrid VARIMA–EP_TCN

BAB V

KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah diperoleh pada penerapan model *hybrid* VARIMA-TCN pada peralaman harga saham MERK dan KLBF, dapat ditarik kesimpulan sebagai berikut:

1. Model VARIMA yang terbaik diperoleh adalah VARIMA (1,1,1). Hasil prediksi dan peramalan tidak terlalu berbeda signifikan. Hasil evaluasi metrik pada model VARIMA yaitu RMSE sebesar 32,8155, MAPE sebesar 0,0102%, dan akurasi sebesar 99,9898%.
2. Model TCN dibangun dengan parameter optimal berupa *batch_size* 16, *nb_filters* 64, *kernel_size* 2, *learning_rate* 0.00160, *dilation* [1,2,4], *dropout_rate* 0.16990853949684684, serta *hidden_units* 1 dan 2 masing-masing 32 dan 32. Hasil evaluasi metrik yang diperoleh pada model TCN yaitu RMSE sebesar 33,7722, MAPE sebesar 0,0126%, dan akurasi sebesar 99,9874%.
3. Model *hybrid* VARIMA–TCN dikembangkan melalui dua pendekatan, yaitu VARIMA–E_TCN yang mengombinasikan VARIMA dengan E_TCN, serta VARIMA–EP_TCN yang merupakan gabungan E_TCN dan P_TCN. Kedua pendekatan ini dibangun menggunakan parameter terbaik hasil *hyperparameter tuning* dengan *optuna optimizer*, dengan rincian sebagai berikut:
 - a. Model E_TCN dibangun dengan parameter optimal berupa *batch_size* 16, *nb_filters* 16, *kernel_size* 3, *learning_rate* 0.00155, *dilation* [1,2,4,8], *dropout_rate* 0.16990853949684684, serta *hidden_units* 1 dan 2 masing-masing 16 dan 32.

- b. Model P_TCN dibangun dengan parameter terbaik berupa *batch size* 16, *nb filters* 64, *kernel size* 5, *learning rate* 0.00985, *dilation* [1,2,4,8], serta *hidden units* 1 dan 2 masing-masing 64 dan 64.
4. Model *hybrid* VARIMA–E_TCN menghasilkan nilai evaluasi berupa RMSE sebesar 33,2151, MAPE sebesar 0,0120%, dan akurasi sebesar 99,9881%. Model *hybrid* VARIMA–EP_TCN memperoleh nilai evaluasi RMSE sebesar 52,3908, MAPE sebesar 0,011%, serta akurasi sebesar 99,9802%.
5. Hasil peramalan selama 16 hari kerja ke depan (02 Februari 2025–24 Februari 2025) dengan model *hybrid* VARIMA–EP_TCN menunjukkan kinerja yang lebih baik dibandingkan VARIMA maupun VARIMA–E_TCN. Model VARIMA hanya menghasilkan pola linear sehingga tidak mampu menangkap fluktuasi data aktual, sedangkan model VARIMA–E_TCN mulai menunjukkan variasi pola meski belum optimal. Berbeda dengan keduanya, model VARIMA–EP_TCN mampu merepresentasikan fluktuasi data secara lebih baik, sehingga dapat dinyatakan sebagai model paling optimal pada periode tersebut.
6. Berdasarkan uji *goodness of fit* menggunakan metode *Kolmogorov–Smirnov*, model dengan nilai statistik uji paling kecil adalah VARIMA–EP_TCN. Sementara itu, model VARIMA dan VARIMA–E_TCN masih belum mampu mengikuti pola maupun fluktuasi data *update* yang menjadi acuan peramalan.

DAFTAR PUSTAKA

- Agarap, A. F. 2018. Deep learning using rectified linear units (ReLU). *arXiv e-prints*.
- Agusta, A., Ernawati, I., & Muliawati, A. 2021. Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory. *Informatik: Jurnal Ilmu Komputer*, **17**(2), 164–173.
- Ahsan, M. M., Mahmud, M. A. P., Saha, P. K., Gupta, K. D., & Siddique, Z. 2021. Effect of data scaling methods on machine learning algorithms and model performance. *Technologies*, **9**(3), 52.
- Aisyah, S., Angraini, Y., Sadik, K., Sartono, B., & Dito, G. A. 2024. Technical Analysis of the Indonesian Stock Market with Gated Recurrent Unit and Temporal Convolutional Network. *JUITA: Jurnal Informatika*, **12**(2): 187–196.
- Ambarwari, A., Adrian, Q. J., dan Herdiyeni, Y. 2020. Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning untuk Identifikasi Tanaman. *Rekayasa Sistem Dan Teknologi Informasi (RESTI)*, **4**(3): 117–122.
- Amelia, R., Somayas, W., Alfian, dan Ruslan. 2024. Uji Goodness of Fit untuk Distribusi Geometrik Menggunakan Uji Statistik Kolmogorov-Smirnov. *Jurnal Matematika, Komputasi Dan Statistika*, **4**(1): 491–497.
- Anggraeni, W., dan Dewi, L. K. 2008. Peramalan Menggunakan Metode Vector Autoregressive Moving Average (VARMA). *Jurnal Ilmiah Teknologi Informasi*, **7**(2): 107–114.
- Antaristi, S. A., Yundari, dan Perdana, H. 2023. Penerapan model vector autoregressive integrated moving average pada data logging. *Buletin Ilmiah Math. Stat. Dan Terapannya (Bimaster)*, **12**(3): 291–300.
- Arifin, W. A., Ariawan, I., Rosalia, A. A., Lukman, L., & Tufailah, N. 2022. Data scaling performance on various machine learning algorithms to identify abalone sex. *Jurnal Teknologi dan Sistem Komputer*, **10**(1): 26–31.

- Azhari, I. C., dan Haryanto, T. 2024. Modeling Of Hyperparameter Tuned RNN-LSTM and Deep Learning For Garlic Price Forecasting In Indonesia. *Journal of Informatics and Telecommunication Engineering*, **7**(2): 502–513.
- Bai, S., Kolter, J. Z., & Koltun, V. 2018. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint*.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. 2015. *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.
- Ding, H., Hou, H., Wang, L., Cui, X., Yu, W., & Wilson, D. I. 2025. Application of Convolutional Neural Networks and Recurrent Neural Networks in Food Safety. *Foods*, **14**(2): 247.
- Gustineli, M. 2022. A Survey on Recently Proposed Activation Functions for Deep Learning. <https://arxiv.org/abs/2204.02921>.
- Hardani, P. R., Hoyyi, A., dan Sudarno. 2016. Peramalan Laju Inflasi, Suku Bunga Indonesia, dan Indeks Harga Saham Gabungan Menggunakan Metode Vector Autoregressive (VAR). *Jurnal Gaussian*, **6**(1): 101–110.
- Hassani, H., & Silva, E. S. 2015. A Kolmogorov-Smirnov based test for comparing the predictive accuracy of two sets of forecasts. *Econometrics*, **3**(3): 590–609.
- He, K., Zhang, X., Ren, S., & Sun, J. 2015. Deep Residual Learning for Image Recognition. *arXiv preprint*.
- Heizer, J dan Render, B. 2009. *Manajemen Operasi: Manajemen Keberlangsungan dan Rantai Pasokan*. Salemba Empat: Jakarta Selatan
- Jusmawati, Hadijati, M., dan Fitriyani, N. 2020. Penerapan Model Vector Autoregressive Integrate Moving Average dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia. *Eigen Mathematics Journal*, **3**(2): 73–82.
- Jange, B. 2021. Prediksi Harga Saham Bank BCA Menggunakan Prophet. *Journal of Trends Economics and Accounting Research*, **2**(1): 1–5.
- Kuntarini, A. A. W. 2024. Pendekatan Neural Network dalam Peramalan Jumlah Penduduk Kota Semarang dengan Menggunakan Metode Backpropagation. *ESTIMASI: Journal of Statistics and Its Application*, **5**(2): 230–239.
- Layton, O. W., Peng, S., & Steinmetz, S. T. 2024. ReLU, Sparseness, and the Encoding of Optic Flow in Neural Networks. *Sensors*, **24**(23).

- Maas, A.L., Hannun, A.Y. and Ng, A.Y. 2013. Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of the 30th International Conference on Machine Learning*, **28**(3): 1–6.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R.J. 1983. *Forecasting: Methods and Application*. Second Edition. Jhon Wiley & Sons, Inc., Hokoben, New Jersey.
- Maniatopoulos, A., & Mitianoudis, N. 2021. Learnable Leaky ReLU (LeLeLU): An Alternative Accuracy-Optimized Activation Function. *Information (Switzerland)*, **12**(513): 1-16.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting* (2nd ed.). WILEY.
- Marimuthu, P., 2022. *How Activation Functions Work in Deep Learning*. <https://www.kdnuggets.com/2022/06/activation-functions-work-deep-learning.html>.
- Myttenaere, A. D., Golden, B., Grand, B. L, & Rossi, F. 2016. Mean Absolute Percentage Error for Regression Models. *Neurocomputing*, **192**: 38–48.
- Ng, Y. N., Lim, H. Y., Cham, Y. C., Bakar, M. A. A., & Ariff, N. M. 2024. Comparison Between LSTM, GRU and VARIMA in Forecasting of Air Quality Time Series Data. *Malaysian Journal of Fundamental and Applied Sciences*, **20**(6): 1248–1260.
- Olatayo, T. O., & Ekerikevwe, K. I. 2022. Performance Measures for Evaluating the Accuracy of Time Series Hybrid Model Using High Frequency Data. Britain International of Exact Sciences (BIOEx) Journal, **4**(3): 244–259.
- Pangestika, Z., & Josaphat, B. P. 2025. Predicting Stock Price Using Convolutional Neural Network and Long Short Term Memory (Case Study: Stock of BBKA). *Jurnal Indonesian Mathematical Society*, **31**(1): 1–18.
- Pratama, G., Adinugroho, S., & Rahayudi, B. 2019. Penggunaan Fungsi Aktivasi Linier dan Logarithmic Normalization pada Metode Backpropagation untuk Peramalan Luas Kebakaran Hutan. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, **3**(12): 11003–11008.
- Tan, P. N., Steinbach, Michael., & Kumar, Vipin. 2014. *Introduction to Data Mining*. New York:Pearson Education.

- Raup, A., Ridwan, W., Khoeriyah, Y., Supiana, dan Zaqiah, Q. Y. 2022. Deep Learning dan Penerapannya dalam Pembelajaran. *Jurnal Ilmiah Ilmu Pendidikan*, **5**(9): 3258–3267.
- Riski, G., Hartama, D., & Solikhun. 2025. Optimizing Multilayer Perceptron for Car Purchase Prediction with GridSearch and Optuna. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, **9**(2): 266–275.
- Roberts, D. A., Yaida, S., & Hanin, B. 2021. *The Principles of Deep Learning Theory: An Effective Theory Approach to Understanding Neural Networks*. Cambridge University Press.
- Rowan, Muflikhah, L., & Cholissodin, I. 2022. Peramalan Kasus Positif COVID-19 di Jawa Timur menggunakan Metode Hybrid ARIMA-LSTM. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, **6**(9): 4146–4153.
- Russell, R. 2018. *Machine Learning: Step-by-step Guide to Implement Machine Learning Algorithms with Python*. Independently published.
- Sapitri, N. M., Nagari, T. G., dan Apriana. 2024. Pemodelan Time Series Pergerakan Harga Saham dengan Deep Learning. *Jurnal Sains*, **3**(1): 11–23.
- Sarfo, A. P., Mai, Q., Sanfilippo, F. M., Preen, D. B., Stewart, L. M., & Fatovich, D. M. 2015. A comparison of multivariate and univariate time series approaches to modelling and forecasting emergency department demand in Western Australia. *Journal of Biomedical Informatics*, **57**: 62–73.
- Sarker, I. H. 2021. Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, **2**(6): 420–439.
- Saxena, A. 2022. An Introduction to Convolutional Neural Networks. *International Journal for Research in Applied Science and Engineering Technology*, **10**(12): 943–947.
- Tsay, R. S. 2014. *Multivariate Time Series Analysis With R and Financial Application* (1st ed.). Wiley.
- Wan, R., Mei, S., Wang, J., Liu, M., & Yang, F. 2019. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics (Switzerland)*, **8**(8): 1–18.

- Wathani, M. N., Bagya, A., Rodi, M., Amri, Z., & Zulkipli. 2025. Penerapan Temporal Convolution Network (TCN) dalam Memprediksi Harga Saham PT Bank Central Asia Tbk. *Jurnal Pendidikan, Sains, Geologi, Dan Geofisika*, **6**(1): 501–505.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). Pearson Education.
- Wibawa, M. S. 2017. Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem dan Informatika (JSI)*, **11**(2): 167–174.
- Wijoyo, A., Saputra, A. Y., Ristanti, S., Sya'ban, R., Amalia, M., dan Febriansyah, R. 2024. Pembelajaran Machine Learning. *OKTAL: Jurnal Ilmu Komputer Dan Science*, **3**(2): 375–380.
- Yang, L. & Shami, A. 2020. On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice. *Neurocomputing*, **415**: 295–316.
- Yu, T., & Zhu, H. 2020. Hyper-parameter optimization: A review of algorithms and applications. *arXiv preprint*.
- Zhang, G. P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, **50**: 159–175.
- Zheng, Y., Liu, Q., Chen, E., Ge, Y., and Zhao, J. L. 2014. Time Series Classification Using Multi-Channels Deep Convolutional Neural Networks. *Springer International Publishing Switzerland*, **8485**: 298–310.
- Zhou, K., Wang, W., Hu, T., & Deng, K. 2020. Time series forecasting and classification models based on recurrent with attention mechanism and generative adversarial networks. *Sensors (Switzerland)*, **20**(24): 1–20.