

**PREDIKSI HARGA SAHAM BANK SYARIAH INDONESIA
MENGGUNAKAN METODE *INDEPENDENT
RECURRENT NEURAL NETWORK***

SKRIPSI

Oleh :
HUMAM AFIF AL-MAHBUBI
NIM. 220605110019



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI HARGA SAHAM BANK SYARIAH INDONESIA
MENGGUNAKAN METODE *INDEPENDENT
RECURRENT NEURAL NETWORK***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
HUMAM AFIF AL-MAHBUBI
NIM. 220605110019

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

PREDIKSI HARGA SAHAM BANK SYARIAH INDONESIA MENGGUNAKAN METODE *INDEPENDENT RECURRENT NEURAL NETWORK*

SKRIPSI

Oleh :
HUMAM AFIF AL-MAHBUBI
NIM. 220605110019

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 10 Desember 2025

Pembimbing I,



Hani Nurhayati, M.T
NIP. 19780625 200801 2 006

Pembimbing II,



Dr. Yunifa Miftachul Arif, M.T
NIP. 19830616 201101 1 004

Mengetahui,

Ketua Program Studi Teknik Informatika

Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M. Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

PREDIKSI HARGA SAHAM BANK SYARIAH INDONESIA MENGGUNAKAN METODE *INDEPENDENT RECURRENT NEURAL NETWORK*

SKRIPSI

Oleh :
HUMAM AFIF AL-MAHBUBI
NIM. 220605110019

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)

Tanggal: 12 Desember 2025

Susunan Dewan Penguji

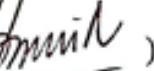
Ketua Penguji : Prof. Dr. Muhammad Faisal M.T
NIP. 19740510 200501 1 007

()

Anggota Penguji I : Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

()

Anggota Penguji II : Hani Nurhayati, M.T
NIP. 19780625 200801 2 006

()

Anggota Penguji III : Dr. Yunifa Miftachul Arif, M. T
NIP. 19830616 201101 1 004

()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



BDIYONO, M. Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Humam Afif Al-Mahbubi
NIM : 220605110019
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Harga Saham Bank Syariah Indonesia
Menggunakan Metode *Independent Recurrent Neural Network*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 22 Desember 2025
Yang membuat pernyataan,



Humam Afif Al-Mahbubi
NIM.220605110019

MOTTO

مَنْ جَدَ وَ جَدَّ

“*Lakonah Lakoneh, Kennengngah Kennengngeh*”

(*KH. Tamhid Turmudzi*)

HALAMAN PERSEMBAHAN

Alhamdulillahi rabbil'alamin

Segala puji syukur saya panjatkan kepada Allah *Subhanu wa Ta'ala*
atas limpahan rahmat, kesehatan, serta hidayah-Nya,
sehingga karya sederhana ini dapat terselesaikan dengan baik.

Dengan penuh rasa syukur, karya ini saya mempersembahkan kepada:

Orang tua saya tercinta,

Mama Fariyati dan Bapak Tosi, yang senantiasa memberikan doa, bimbingan, semangat, serta kasih sayang yang tiada henti. Serta seluruh keluarga, termasuk adik-adik saya, kakek dan nenek yang senantiasa memberikan dukungan dan doa.

Teman-teman seperjuangan,

Khususnya keluarga besar Teknik Informatika. Terima kasih atas ilmu yang terus mengalir, semangat yang selalu menguatkan, serta pengalaman berharga yang mewarnai perjalanan ini. Semoga silaturahmi kita tetap terjaga, dan kita semua dipertemukan dengan kesuksesan yang lebih luas di masa depan.

Aamiin ya rabbal'alamien

KATA PENGANTAR

Assalamu'alaikum wr. wb.

Penulis mengucapkan syukur kehadirat Allah SWT atas segala rahmat dan karunia-Nya sehingga penulisan skripsi yang berjudul “Prediksi Harga Saham Bank Syariah Indonesia Menggunakan Metode *Independent Recurrent Neural Network*” dapat diselesaikan dengan baik. Skripsi ini disusun sebagai salah satu persyaratan untuk memperoleh gelar sarjana pada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Penulis menyadari bahwa keberhasilan dalam menyelesaikan karya ilmiah ini tidak terlepas dari dukungan dan bimbingan berbagai pihak.

Oleh karena itu, penulis menyampaikan ucapan terima kasih yang sebesar besarnya kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si, selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas kebijakan yang inovatif dalam pengembangan sarana dan prasarana pembelajaran, sehingga mendukung tercapainya kualitas pendidikan yang optimal.
2. Dr. Agus Mulyono, M.Kes, selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas kepemimpinannya yang inspiratif dalam memajukan kualitas pendidikan di lingkungan fakultas.
3. Supriyono, M. Kom, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas motivasi dan arahan yang diberikan selama proses perkuliahan.

4. Hani Nurhayati, M.T., selaku dosen pembimbing 1, yang telah memberikan bimbingan, saran, canda tawa, serta kesabaran dan dukungan Ibu sangat berarti bagi penulis selama proses penelitian.
5. Dr. Yunifa Miftachul Arif, M. T., selaku dosen pembimbing 2, atas kesabaran dan arahan yang sangat membantu dalam menyempurnakan karya ini.
6. Dr. Ir. Fachrul Kurniawan, M.MT., IPU., selaku dosen wali, atas perhatian dan bimbingan yang diberikan selama masa studi.
7. Prof. Dr. Muhammad Faisal M.T dan Fajar Rohman Hariri, M.Kom, selaku dosen penguji, kritik dan saran yang sangat membantu dalam memperbaiki kualitas skripsi.
8. Seluruh staf dan dosen Program Studi Teknik Informatika, atas ilmu, dukungan, dan fasilitas yang telah diberikan kepada penulis selama masa studi.
9. Kedua orang tua dan adik-adik tercinta, Fariyati, Tosi, Hanif Adha Ats-Tsaqif, Hurin ‘Ainun Al-Huwaina, Hizam Adnan Athafariz, dan Alm. Ahmad Maulana atas cinta, doa, dan dukungan tiada henti yang menjadi kekuatan terbesar penulis dalam menyelesaikan studi ini.
10. Rekan seperjuangan “Kontrakan Penghuni Surga”, yang beranggotakan Gumiang, Fahry, Adino, Syamsul, Farros, Rama, Rheza, Maulana, Alfred, Fajar, Muzakky, Abyan, Akbar, Nizam dan Hanif. Terima kasih atas kenangan dan suka duka yang diberikan.

11. Kepada rekan-rekan “Sobhat Gedhang” yang beranggotakan Haris, Yusni, Rozaq dan Hilmi yang telah menemani penulis dalam proses pembelajaran dalam bermiaga.
12. Seluruh keluarga besar Teknik Informatika terkhusus Angkatan 2022 “INFINITY”, atas segala ilmu, semangat, dan pengalaman berharga yang telah dibagikan. Semoga silaturahmi kita semakin erat dan kita semua dapat meraih impian kita semua.
13. Teman-teman KKM Desa Ngadireso, atas kenangan selama melakukan Kegiatan Kerja Mahasiswa di Desa Ngadireso, Kabupaten Malang, Jawa Timur.
14. Serta seluruh rekan-rekan penulis baik dari masa kecil hingga sekarang, yang telah *support*, memberikan semangat, pengetahuan, dan pengalaman yang tidak ternilai harganya.

Penulis menyadari bahwa skripsi ini masih perlu disempurnakan. Segala kritik dan saran yang membangun akan sangat berharga bagi penulis untuk memperbaiki karya ini. Semoga penelitian ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan, khususnya berbasis pendidikan Islam.

Wassalamu 'alaikum warahmatullahi wabarakatuh.

Malang, 12 Desember 2025

Penulis

ABSTRAK

Al-Mahbubi, Humam Afif. 2025. **Prediksi Harga Saham Bank Syariah Indonesia Menggunakan Metode *Independent Recurrent Neural Network***. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Hani Nurhayati, M.T. (II) Dr. Yunifa Miftachul Arif, M. T.

Kata kunci: Prediksi Harga Saham, Bank Syariah Indonesia, *Independent Recurrent Neural Network* (IndRNN), *Deep Learning*.

Fluktuasi harga saham yang dinamis menuntut metode prediksi yang andal untuk menangkap pola pergerakan secara akurat. Penelitian ini bertujuan memprediksi harga saham PT Bank Syariah Indonesia Tbk (BRIS) untuk 30 hari ke depan menggunakan *Independent Recurrent Neural Network* (IndRNN) dengan dataset 1.203 data harian. Sebanyak 32 skenario eksperimen diuji dengan memvariasikan *window size*, jumlah *hidden unit*, fungsi aktivasi (ReLU, PReLU, ELU, Tanh), dan rasio pembagian data. Evaluasi dilakukan menggunakan RMSE, MAPE, *Directional Accuracy* (DA), dan durasi pelatihan. Hasil penelitian menunjukkan bahwa rasio pembagian data 80:20 secara konsisten memberikan tingkat kesalahan terendah. Konfigurasi model terbaik untuk akurasi nilai diperoleh pada kombinasi *window size* 30 dan 128 *hidden unit* dengan fungsi aktivasi ReLU, yang menghasilkan RMSE sebesar 286,69 dan MAPE 8,18%. Sebaliknya, akurasi arah tren tertinggi dicapai oleh kombinasi *window size* 20 dan 128 *hidden unit* dengan fungsi aktivasi ELU sebesar 52,29%. Dari sisi efisiensi, fungsi aktivasi Tanh pada arsitektur sederhana terbukti memiliki waktu komputasi tercepat. Penelitian ini menyimpulkan bahwa terdapat perbedaan karakteristik antara akurasi nilai dan akurasi arah, di mana *window size* yang lebih besar unggul dalam menangkap tren jangka panjang, sedangkan *window size* yang lebih pendek lebih responsif terhadap perubahan arah pergerakan harga.

ABSTRACT

Al-Mahbubi, Humam Afif. 2025. **Stock Price Prediction of Bank Syariah Indonesia Using Independent Recurrent Neural Network.** Thesis. Department of Informatics Engineering, Faculty of Science and Technology, State Islamic University Maulana Malik Ibrahim Malang. Advisors: (I) Hani Nurhayati, M.T. (II) Dr. Yunifa Miftachul Arif, M. T.

Dynamic stock price fluctuations demand reliable prediction methods to accurately capture movement patterns. This study aims to predict the stock price of PT Bank Syariah Indonesia Tbk (BRIS) for the next 30 days using Independent Recurrent Neural Network (IndRNN) with a dataset of 1,203 daily records. A total of 32 experimental scenarios were tested by varying window size, number of hidden units, activation functions (ReLU, PReLU, ELU, Tanh), and data split ratios. Evaluation was performed using RMSE, MAPE, Directional Accuracy (DA), and training duration. The results show that the 80:20 data split ratio consistently provided the lowest error rates. The best model configuration for value accuracy was obtained in the combination of window size 30 and 128 hidden units with the ReLU activation function, yielding an RMSE of 286.69 and MAPE of 8.18%. Conversely, the highest trend direction accuracy was achieved by the combination of window size 20 and 128 hidden units with the ELU activation function, at 52.29%. In terms of efficiency, the Tanh activation function on a simple architecture proved to have the fastest computational time. This study concludes that there is a characteristic difference between value accuracy and directional accuracy, where a larger window size excels in capturing long-term trends, while a shorter window size is more responsive to changes in price movement direction.

Keywords: Stock price prediction, Bank Syariah Indonesia, Independent Recurrent Neural Network (IndRNN), Deep Learning.

ملخص البحث

المحبوب، همام عفيف. ٢٠٢٥. التنبؤ بأسعار أسهم بنك الشريعة الإندونيسي باستخدام طريقة الشبكة العصبية المتكررة المستقلة. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرفون: (١) هاني نور حباني، الماجستير؛ (٢) الدكتور يونيفا مفتاح العارف، الماجستير.

الكلمات المفتاحية: التنبؤ بأسعار الأسهم؛ بنك الشريعة الإندونيسي؛ الشبكة العصبية المتكررة المستقلة؛ التعلم العميق.

تطلب التقليبات الديناميكية في أسعار الأسهم طرق تنبؤ موثوقة لالتقاط أنماط الحركة بدقة. تهدف هذه الدراسة إلى التنبؤ بأسعار أسهم شركة بنك الشريعة الإندونيسي للأيام 30 القادمة باستخدام الشبكة العصبية المتكررة المستقلة (IndRNN) بالاعتماد على مجموعة بيانات تضم 1203 سجلًا يوميًّا. تم اختبار ما مجموعه 32 سيناريو تجريبي من خلال تنويع حجم النافذة، وعدد الوحدات المخفية، ودوال التنشيط (Tanh, ELU, PReLU, ReLU)، ونسب تقسيم البيانات. تم إجراء التقييم باستخدام حذر متوسط مربع الخطأ، ومتوسط نسبة الخطأ المطلق، ودقة الاتجاه، ومدة التدريب. أظهرت النتائج أن نسبة تقسيم البيانات 80:20 قدمت بشكل متسق أدنى معدلات للأخطاء. تم الحصول على أفضل تكوين للنموذج لدقة القيمة من خلال الجمع بين حجم نافذة 30 و 128 وحدة مخفية مع دالة التنشيط RELU، مما 286.69% RMSE و 8.18% MAPE. في المقابل، تم تحقيق أعلى دقة لاتجاه المسار من خلال الجمع بين حجم نافذة 20 و 128 وحدة مخفية مع دالة التنشيط ELU بنسبة 52.29%. من حيث الكفاءة، أثبتت دالة التنشيط تانه في البنية البسيطة أنها تمتلك أسرع وقت للمعالجة الحاسية. تخلص هذه الدراسة إلى وجود اختلاف في الخصائص بين دقة القيمة ودقة الاتجاه، حيث يتتفوق حجم النافذة الأكبر في التقاط الاتجاهات طويلة الأجل، بينما يكون حجم النافذة الأصغر أكثر استجابة للتغيرات في اتجاه حركة الأسعار.

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
ABSTRAK	xi
ABSTRACT	xii
ملخص البحث	xiii
DAFTAR ISI	xiv
DAFTAR GAMBAR	xvi
DAFTAR TABEL	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Saham Syariah	11
2.3 <i>Independent Recurrent Neural Network</i>	12
2.4 Fungsi Aktivasi	13
2.4.1 <i>Rectified Linear Unit</i>	13
2.4.2 <i>Parametric Rectified Linear Unit</i>	13
2.4.3 <i>Exponential Linear Unit</i>	14
2.4.4 <i>Hyperbolic Tangent</i>	14
BAB III DESAIN DAN IMPLEMENTASI	16
3.1 Desain Penelitian	16
3.2 Pengumpulan Data	17
3.3 Desain Sistem	18
3.4 <i>Preprocessing</i>	18
3.4.1 <i>Splitting Data</i>	18
3.4.2 Normalisasi Data	19
3.4.3 <i>Sliding Window</i>	19
3.5 Implementasi IndRNN	20
3.6 Skenario Uji Coba	22
3.7 Evaluasi	22
3.7.1 <i>Root Mean Square Error</i>	23
3.7.2 <i>Mean Absolute Percentage Error</i>	23
3.7.3 <i>Directional Accuracy</i>	24
BAB IV UJI COBA DAN PEMBAHASAN	25

4.1 Hasil <i>Preprocessing</i>	25
4.1.1 Hasil <i>Splitting Data</i>	25
4.1.2 Hasil Normalisasi Data.....	26
4.1.3 Hasil <i>Sliding Window</i>	26
4.2 Hasil Uji Coba.....	27
4.2.1 Fungsi Aktivasi ReLU	27
4.2.2 Fungsi Aktivasi PreLU	34
4.2.3 Fungsi Aktivasi ELU	42
4.2.4 Fungsi Aktivasi Tanh.....	49
4.3 Pembahasan.....	56
4.3.1 Evaluasi RMSE	58
4.3.2 Evaluasi MAPE	60
4.3.3 Evaluasi <i>Dirrectional Accuracy</i>	62
4.3.4 Evaluasi <i>Time Training</i>	63
4.3.5 Model Terbaik	65
4.4 Integrasi Islam.....	66
4.4.1 <i>Muamalah Mu'allah</i>	67
4.4.2 <i>Muamalah Ma'annas</i>	68
BAB V KESIMPULAN DAN SARAN	69
5.1 Kesimpulan	69
5.2 Saran.....	70

DAFTAR PUSTAKA
LAMPIRAN

DAFTAR GAMBAR

Gambar 3.1 Desain Penelitian.....	16
Gambar 3.2 Dataset Harga Saham BRIS	17
Gambar 3.3 Desain Sistem.....	18
Gambar 3.4 Ilustrasi <i>Sliding Window</i>	20
Gambar 3.5 Arsitektur IndRNN	21
Gambar 4.1 Grafik Model A pada 30 Hari Terakhir Data <i>Testing</i>	28
Gambar 4.2 Grafik Model B pada 30 Hari Terakhir Data <i>Testing</i>	30
Gambar 4.3 Grafik Model C pada 30 Hari Terakhir Data <i>Testing</i>	31
Gambar 4.4 Garfik Model D pada 30 Hari Terakhir Data <i>Testing</i>	33
Gambar 4.5 GrafikModel A pada 30 Hari Terakhir Data <i>Testing</i>	35
Gambar 4.6 Grafik Model B pada 30 Hari Terakhir Data <i>Testing</i>	37
Gambar 4.7 Grafik Model C pada 30 Hari Terakhir Data <i>Testing</i>	38
Gambar 4.8 Grafik Model D pada 30 Hari Terakhir Data <i>Testing</i>	40
Gambar 4.9 Grafik Model A pada 30 Hari Terakhir Data <i>Testing</i>	43
Gambar 4.10 Grafik Model B pada 30 Hari Terakhir Data <i>Testing</i>	44
Gambar 4.11 Grafik Model C pada 30 Hari Terakhir Data <i>Testing</i>	46
Gambar 4.12 Grafik Model D pada 30 Hari Terakhir Data <i>Testing</i>	48
Gambar 4.13 Grafik Model A pada 30 Hari Terakhir Data <i>Testing</i>	50
Gambar 4.14 Grafik Model B pada 30 Hari Terakhir Data <i>Testing</i>	51
Gambar 4.15 Grafik Model C pada 30 Hari Terakhir Data <i>Testing</i>	53
Gambar 4.16 Grafik Model D pada 30 Hari Terakhir Data <i>Testing</i>	54
Gambar 4.17 <i>Heatmap</i> RMSE dari seluruh model	59
Gambar 4.18 <i>Heatmap</i> MAPE dari seluruh model	61
Gambar 4.19 <i>Heatmap</i> <i>Dirrectional Accuracy</i> dari seluruh model.	62
Gambar 4.20 <i>Heatmap</i> <i>Time Training</i> dari seluruh model.....	64

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait.....	9
Tabel 3.1 Model & Rasio Split data	22
Tabel 4.1 <i>Groundtruth</i> Harga Saham	25
Tabel 4.2 Jumlah data <i>training</i> dan data <i>testing</i> setiap rasio.....	25
Tabel 4.3 Data sebelum dan setelah dinormalisasi.....	26
Tabel 4.4 Hasil Evaluasi pada Model B (ReLU).....	28
Tabel 4.5 Hasil Evaluasi pada Model B (ReLU).....	30
Tabel 4.6 Hasil Evaluasi pada Model C (ReLU).....	32
Tabel 4.7 Hasil Evaluasi pada Model D (ReLU)	34
Tabel 4.8 Hasil Evaluasi pada Model A (PReLU).....	36
Tabel 4.9 Hasil Evaluasi pada Model B (PReLU)	38
Tabel 4.10 Hasil Evaluasi pada Model C (PReLU)	39
Tabel 4.11 Hasil Evaluasi pada Model D (PReLU)	41
Tabel 4.12 Hasil Evaluasi pada Model A (ELU).....	43
Tabel 4.13 Hasil Evaluasi pada Model B (ELU).....	45
Tabel 4.14 Hasil Evaluasi pada Model C (ELU).....	47
Tabel 4.15 Hasil Evaluasi pada Model D (ELU)	48
Tabel 4.16 Hasil Evaluasi pada Model A (Tanh).....	50
Tabel 4.17 Hasil Evaluasi pada Model B (Tanh)	52
Tabel 4.18 Hasil Evaluasi pada Model C (Tanh)	53
Tabel 4.19 Hasil Evaluasi pada Model D (Tanh)	55
Tabel 4.20 Ringkasan Hasil Evaluasi Pada Seluruh Model	56

BAB I

PENDAHULUAN

1.1 Latar Belakang

Investasi merupakan kegiatan mengalokasikan sejumlah dana atau aset dalam bentuk tertentu dan jangka waktu tertentu, dengan harapan memperoleh keuntungan di masa depan (Prayogi et al., 2024). Salah satu bentuk investasi yang banyak diminati adalah saham. Di Indonesia, minat masyarakat terhadap investasi saham terus meningkat, baik dari kalangan pemula maupun profesional (Midesia, 2020). Berdasarkan data Kustodian Sentral Efek Indonesia (KSEI), jumlah investor saham meningkat sekitar 1,6 juta pada tahun 2020 menjadi 7,5 juta pada bulan Agustus 2025 (KSEI, 2025). Peningkatan signifikan ini menunjukkan besarnya ketertarikan masyarakat terhadap saham, sekaligus menuntut adanya pemahaman yang lebih mendalam mengenai dinamika harga saham yang fluktuatif (Warouw et al., 2022).

Fluktuasi harga saham yang tinggi menjadikan investasi saham penuh ketidakpastian. Pergerakan harga saham dipengaruhi oleh berbagai faktor, mulai dari kondisi makroekonomi, ekspektasi pertumbuhan perusahaan, hingga tingkat kepercayaan terhadap manajemen. Seiring dengan kemajuan teknologi, informasi terkait pasar dapat diakses dengan cepat dalam jumlah besar. Namun, kelimpahan data ini justru menambah kompleksitas analisis, karena semakin banyak variabel yang harus dipertimbangkan dalam waktu singkat (Hu et al., 2021). Oleh sebab itu, investor dituntut untuk lebih cermat dalam menentukan keputusan membeli, menjual, atau mempertahankan saham. Salah satu langkah strategis untuk

mengurangi ketidakpastian tersebut adalah dengan melakukan prediksi harga saham secara akurat, sehingga keputusan investasi dapat lebih rasional dan potensi kerugian dapat diminimalkan (Budiprasetyo et al., 2023).

Upaya memenuhi kebutuhan prediksi harga saham tersebut mendorong lahirnya berbagai pendekatan berbasis data. Zhang et al., (2023) menjelaskan bahwa metode statistik konvensional sering kali tidak mampu mengidentifikasi pola tersembunyi serta hubungan yang bersifat *non-linier* dalam data keuangan. Sebaliknya, Hu et al. (2021) menyebutkan bahwa penerapan metode *deep learning* terbukti mampu memberikan akurasi dan hasil yang lebih baik dalam prediksi di bidang keuangan. Kondisi ini membuka peluang bagi penggunaan pendekatan yang lebih mampu memahami pola dan dinamika pasar secara lebih akurat.

Konsep prediksi dan perencanaan menghadapi masa depan sejatinya bukan hanya dikenal dalam ilmu modern, tetapi juga telah diajarkan dalam Al-Qur'an. Sebagaimana firman Allah *Subhanahu wa ta'ala* dalam Q.S. Yusuf ayat 47–49 yang berbunyi:

فَالَّتَّرَّعُونَ سَبْعَ سَيِّنَنَّ دَأْبًا فَمَا حَصَدْتُمْ فَدَرُرُوهُ فِي سُبْنَلَةٍ لَا قَلِيلًا مَّا تَكُونُ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَّكْلُنَ مَا قَدَّمْتُ لَهُنَّ لَا قَلِيلًا مَّا تُحْصِنُونَ ﴿٤٨﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ عَامٌ فِيهِ يُعَاقِثُ اللَّاثُسُ وَفِيهِ يَعْصُرُونَ ﴿٤٩﴾

“(Yusuf) berkata, “Bercocoktanamlah kamu tujuh tahun berturut-turut! Kemudian apa yang kamu tuai, biarkanlah di tangkainya, kecuali sedikit untuk kamu makan. Kemudian, sesudah itu akan datang tujuh (tahun) yang sangat sulit (paceklik) yang menghabiskan apa yang kamu simpan untuk menghadapinya, kecuali sedikit dari apa (bibit gandum) yang kamu simpan. Setelah itu akan datang tahun, ketika manusia diberi hujan (dengan cukup) dan pada masa itu mereka memeras (anggur).” (Q.S. Yusuf: 47-49)

Pada tafsir Ibnu Katsir menjelaskan bahwa Nabi Yusuf memberikan arahan strategis untuk menghadapi siklus tahun subur dan paceklik. Beliau menekankan

agar hasil panen pada masa subur disimpan dengan membiarkannya tetap pada bulirnya agar lebih awet dan tidak cepat rusak, serta mengatur pola konsumsi agar hemat dan tidak berlebihan demi menjamin ketersediaan cadangan (Katsir, 2003). Prinsip ini dapat dipahami sebagai bentuk tabungan darurat (*emergency saving*), yaitu strategi perencanaan untuk mengantisipasi ketidakpastian di masa depan (Hani & Fadliyati, 2020). Konsep ini sangat relevan dengan konteks investasi modern, di mana prediksi harga saham dibutuhkan agar investor mampu mengambil keputusan yang lebih rasional dan meminimalkan risiko kerugian.

Kebutuhan akan metode prediksi yang lebih andal mendorong munculnya *Independent Recurrent Neural Network* (IndRNN) sebagai salah satu pendekatan *deep learning* yang menjanjikan. IndRNN merupakan pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi keterbatasan RNN maupun *Long Short-Term Memory* (LSTM), khususnya masalah *vanishing gradient* dan *exploding gradient* pada pemrosesan urutan data panjang. Berbeda dengan RNN konvensional, IndRNN dirancang agar setiap *neuron* dalam satu lapisan bersifat independen terhadap *neuron* lainnya. IndRNN terbukti mampu memproses urutan data yang sangat panjang hingga 5000 *time-step*, melampaui secara signifikan kemampuan LSTM yang hanya stabil hingga kurang dari 1000 *time-step* (Li et al., 2018).

Pemilihan IndRNN juga didukung oleh hasil empiris yang menunjukkan performa lebih unggul dibandingkan metode lain. Dalam penelitian yang dilakukan oleh Alsharef et al. (2020), IndRNN mencatatkan nilai *Mean Squared Error* (MSE) sebesar 46 pada prediksi harga saham Tata Motors. Nilai ini merepresentasikan rata-

rata kuadrat *error* dalam skala harga saham (*close price*). Setelah dilakukan *fine-tuning* dengan mengganti fungsi aktivasi ReLU menjadi PReLU, nilai MSE dapat ditekan hingga 44,16. Pengujian lanjutan menggunakan data saham Amazon juga menunjukkan hasil serupa, di mana IndRNN yang telah melalui *fine-tuning* memperoleh MSE terendah sebesar 57.

Keunggulan IndRNN kembali ditunjukkan oleh penelitian Alsharef et al. (2022) yang membandingkan berbagai metode prediksi pada data harga Ethereum. IndRNN memperoleh nilai *Mean Squared Error* (MSE) sebesar 239, lebih baik dibandingkan LSTM (MSE = 298), ARIMA (MSE = 314), dan model *linear* lainnya. Setelah dilakukan *fine-tuning*, IndRNN mencatat hasil terbaik dengan MSE hanya 213, menjadikannya model dengan akurasi terbaik dalam menghadapi volatilitas tinggi pada data keuangan digital. Temuan ini menegaskan bahwa IndRNN, khususnya dalam versi *fine-tuned*, memiliki kemampuan tinggi dalam menangkap pola temporal kompleks secara efisien, sekaligus membuka peluang penerapannya pada instrumen keuangan lain, termasuk saham syariah.

Berdasarkan uraian tersebut, pemilihan IndRNN dalam penelitian ini didasarkan pada keunggulannya dalam mengenali pola data *time-series* secara lebih stabil dan akurat. Sejumlah penelitian sebelumnya telah menunjukkan bahwa IndRNN mampu mengatasi permasalahan volatilitas data keuangan sekaligus menghasilkan tingkat kesalahan prediksi yang lebih rendah dibandingkan metode lain. Hal ini membuka peluang besar untuk menerapkan IndRNN dalam memprediksi harga saham syariah di Indonesia. Oleh karena itu, penelitian ini difokuskan pada penggunaan IndRNN untuk memprediksi harga saham PT Bank

Syariah Indonesia Tbk (BRIS) guna memberikan gambaran yang lebih akurat bagi pengambilan keputusan investasi.

1.2 Rumusan Masalah

Bagaimana ukuran performa metode *Independent Recurrent Neural Network* (IndRNN) dalam memprediksi harga saham PT Bank Syariah Indonesia Tbk (BRIS) berdasarkan nilai evaluasi *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Directional Accuracy* (DA)?

1.3 Batasan Masalah

1. Penelitian ini menggunakan dataset berupa data historis harga saham harian PT Bank Syariah Indonesia Tbk (BRIS) yang diperoleh dari Yahoo Finance. Dataset dibatasi pada periode waktu tertentu yang telah ditentukan peneliti.
2. Prediksi harga saham dilakukan dengan fokus pada data *time-series* harga penutupan (*closing price*), tanpa mempertimbangkan faktor eksternal lain seperti kondisi makroekonomi, berita, maupun sentimen pasar.
3. Evaluasi model menggunakan metrik RMSE, MAPE, DA dan waktu pelatihan.

1.4 Tujuan Penelitian

Tujuan dari penelitian berdasarkan masalah yang disebutkan adalah mengetahui performa dengan mengukur tingkat *error* dari implementasi metode IndRNN dalam memprediksi harga saham PT Bank Syariah Indonesia Tbk (BRIS) berdasarkan nilai RMSE, MAPE, DA dan *Time Training*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat di masa yang akan datang, yaitu:

1. Memberikan kontribusi ilmiah dalam pengembangan ilmu pengetahuan, khususnya pada penerapan metode IndRNN untuk permasalahan *time-series* di bidang keuangan, serta menjadi rujukan bagi peneliti maupun praktisi *data science* dalam melakukan penelitian lanjutan atau pengembangan model prediksi harga saham berbasis IndRNN.
2. Memberikan wawasan bagi investor, khususnya pada pasar saham syariah, untuk mendukung pengambilan keputusan investasi yang lebih rasional berdasarkan hasil prediksi yang lebih akurat.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Alsharef et al., (2020) dalam penelitiannya membandingkan beberapa metode untuk memprediksi harga saham, diantaranya *Moving Average* (MA), *Auto-Regressive Integrated Moving Average* (ARIMA), *Long-Short Term Memory* (LSTM), dan IndRNN dengan data historis saham Tata Motors dari Yahoo Finance (1996–2009). Hasil penelitian menunjukkan bahwa IndRNN memberikan *Mean Squared Error* (MSE) terendah, yaitu 46, dibandingkan LSTM (53), ARIMA (55), dan MA (108). Nilai MSE ini merepresentasikan rata-rata kuadrat *error* dalam skala harga saham, sehingga secara langsung mencerminkan tingkat kedekatan hasil prediksi dengan harga aktual. Selanjutnya, IndRNN di-*fine-tune* dengan mengganti fungsi aktivasi ReLU menjadi *Parametric ReLU* (PReLU), yang menurunkan MSE lebih lanjut menjadi 44.16. Verifikasi dengan dataset saham Amazon (1996–2019) menunjukkan pola serupa, di mana IndRNN memperoleh MSE 69 dan versi *fine-tuned* mencapai 57. Temuan ini menegaskan bahwa IndRNN mampu memberikan akurasi prediksi lebih tinggi dibandingkan algoritma lainnya, serta dapat dioptimalkan lebih lanjut dengan pemilihan fungsi aktivasi yang tepat.

Pada tahun selanjutnya, Alsharef et al., (2022) memperluas penelitian dengan menerapkan IndRNN pada data harga Ethereum periode 2015–2020. Penelitian ini membandingkan algoritma *linear* yaitu *Auto-Regressive* (AR), *Moving Average* (MA), *Auto-Regressive Integrated Moving Average* (ARIMA) dengan algoritma *deep learning* yaitu LSTM dan IndRNN. Hasilnya menunjukkan

bahwa AR dan MA tidak mampu menangani volatilitas tinggi pada data Ethereum, sementara ARIMA memberikan hasil moderat dengan nilai MSE 314. LSTM menghasilkan MSE sebesar 298, sedangkan IndRNN lebih unggul dengan MSE 239. Versi *fine-tuned* IndRNN dengan fungsi aktivasi PReLU menunjukkan performa terbaik dengan MSE 213. Hal ini membuktikan bahwa IndRNN, khususnya dengan aktivasi PReLU, menjadikannya model dengan akurasi terbaik dalam menghadapi volatilitas tinggi pada data keuangan digital.

Pada penelitian yang dilakukan oleh Hong et al., (2021) mengenai prediksi perkembangan epidemi COVID-19, digunakan data kumulatif kasus terkonfirmasi dan kematian mingguan dari enam negara (China, Amerika Serikat, India, Brazil, Perancis, dan Rusia) serta data global pada periode Januari 2020 hingga Mei 2021. Model yang diuji meliputi LSTM, Bi-LSTM, GRU, *Stacked Bi-GRU*, CNN-LSTM, Deep-CNN, serta IndRNN baik dalam versi standar maupun dengan strategi *fine-tuning* berbasis transfer bobot. Hasil penelitian menunjukkan bahwa IndRNN standar sudah memberikan performa terbaik dengan nilai *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) lebih rendah dibandingkan model lainnya. Selanjutnya, penerapan *fine-tuning* pada IndRNN mampu menekan *error* hingga 20.94%, dengan MAPE $< 1.2\%$ pada tahap pengujian dan $< 6.2\%$ pada tahap validasi. Capaian terbaik diperoleh pada data kematian di China, yaitu MAPE sebesar 0.05% dan RMSE sebesar 1.17, yang menegaskan bahwa IndRNN versi standar maupun yang sudah di-*fine-tuning* lebih baik dalam menangani data *time-series* yang kompleks.

Venugopal et al., (2023) melakukan penelitian mengenai estimasi *State of Charge* (SOC) pada baterai *lithium-ion* kendaraan listrik menggunakan IndRNN. Data yang digunakan berasal dari sel baterai Panasonic NCR18650PF berbasis *Lithium Nickel Cobalt Aluminium Oxide* (NCA) yang diuji dalam sembilan profil *drive cycle* pada tiga kondisi suhu berbeda (0°C, 10°C, 25°C). Model yang digunakan berupa arsitektur IndRNN murni dengan tiga input (tegangan, arus, suhu), satu lapisan tersembunyi berisi 1000 *neuron* dengan aktivasi ReLU, dan satu *output*. Hasil penelitian menunjukkan bahwa IndRNN memberikan performa terbaik dibandingkan LSTM dan GRU, dengan rata-rata RMSE sebesar 0.7633%, MAE sebesar 0.6389%, serta *maximum error* sebesar 2.2398%. Temuan ini membuktikan bahwa IndRNN mampu menangkap pola *non-linear* dan dependensi jangka panjang pada data *time-series* baterai secara lebih efektif, sekaligus memperlihatkan keunggulannya sebagai model yang akurat dan efisien untuk aplikasi sistem manajemen baterai kendaraan listrik.

Tabel 2.1 Penelitian Terkait

No	Judul	Hasil	Persamaan	Perbedaan
1	<i>Predicting Stock Market Prices using Fine-Tuned IndRNN</i> (Alsharef et al., 2020)	Tata Motors (MSE): - MA 108, - ARIMA 55, - LSTM 53, - IndRNN 46, - <i>Fine-tuned</i> IndRNN 44.16 Amazon (MSE): - MA 137 - ARIMA 79 - LSTM 75 - IndRNN 69 - <i>Fine-tuned</i> IndRNN 57.	Penggunaan data <i>time-series</i> finansial dan metode IndRNN.	Prediksi saham Tata Motors dan Amazon.

No	Judul	Hasil	Persamaan	Perbedaan
2	<i>Predicting Time-Series Data Using Linear and Deep Learning Models-An Experimental Study</i> (Alsharef et al., 2022)	Evaluasi MSE: - AR 78,843 - MA 14,438 - ARIMA 314 - LSTM 298 - IndRNN 239 - <i>Fine-tuned</i> IndRNN 213	Penggunaan data <i>time-series</i> finansial dan metode IndRNN.	Prediksi harga Ethereum.
3	<i>Prediction Of Covid-19 Epidemic Situation Via Fine-Tuned Indrnn</i> (Hong et al., 2021)	IndRNN unggul dengan RMSE dan MAPE terendah dibanding LSTM, GRU, dan CNN. Versi <i>fine-tuned</i> IndRNN menekan <i>error</i> hingga 20.94% dengan hasil terbaik MAPE 0.05% dan RMSE 1.17.	Penggunaan data <i>time-series</i> dan metode IndRNN.	Prediksi perkembangan epidemi COVID-19.
4	<i>State of Charge Estimation of Lithium Batteries in Electric Vehicles Using IndRNN</i> (Venugopal et al., 2023)	IndRNN memperoleh hasil lebih baik dari pada LSTM dan GRU dengan nilai RMSE 0.7633%, MAE 0.6389%, dan MAX 2.2398%.	Penggunaan data <i>time-series</i> dan metode IndRNN.	Prediksi <i>State of Charge</i> (SOC) baterai kendaraan listrik.
5	Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia (Mushliha, 2024)	CNN-BiLSTM memperoleh hasil MAPE: - 2.376% (BRIS) - 2.092% (BTPS) - 0.629% (PNBS)	Prediksi harga saham bank syariah Indonesia.	Menggunakan metode <i>hybrid</i> CNN-BiLSTM.

No	Judul	Hasil	Persamaan	Perbedaan
6	<i>Sharia Bank of Indonesia Stock Price Prediction using Long Short-Term Memory</i> (Poernamawati et al., 2024)	LSTM dengan <i>tuning hyperparameter</i> pada data saham BSI (2021–2024) menghasilkan akurasi tinggi dengan MAPE 2.46%.	Prediksi harga saham bank syariah Indonesia.	Menggunakan metode LSTM.
Usulan Penelitian				
7	Prediksi Harga Saham Bank Syariah Indonesia Menggunakan Metode <i>Independent Recurrent Neural Network</i>	-	Penerapan metode <i>Independent Recurrent Neural Network</i> untuk memprediksi harga saham PT Bank Syariah Indonesia Tbk (BRIS).	

2.2 Saham Syariah

Saham syariah merupakan efek berbentuk saham yang tidak bertentangan dengan prinsip syariah di pasar modal, dan definisinya tetap merujuk pada pengertian saham sebagaimana diatur dalam regulasi Otoritas Jasa Keuangan (OJK) (IDX, 2025). Secara umum, saham adalah bukti penyertaan atau kepemilikan dalam suatu perusahaan yang memberikan hak keuntungan bagi pemilik modal, dengan hasil investasi yang bersifat variabel. Dalam perspektif Islam, konsep saham dipandang sejalan dengan akad *musyarakah* atau *syirkah*, yaitu kerja sama permodalan yang membagi keuntungan secara adil antara pemilik modal (Hartati, 2021).

2.3 Independent Recurrent Neural Network

Independent Recurrent Neural Network (IndRNN) adalah pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Li et al. (2018). IndRNN diusulkan untuk mengatasi keterbatasan RNN yang sering mengalami permasalahan *vanishing* dan *exploding gradient*, sehingga sulit dalam mempelajari ketergantungan jangka panjang. Solusi yang ditawarkan IndRNN adalah membuat setiap *neuron* dalam satu *layer* bersifat independen, sehingga aliran gradien dapat dikendalikan dan memori jangka panjang dapat dipertahankan. Berdasarkan penelitian Li et al. (2018), IndRNN terbukti mampu memproses *sequens* panjang (lebih dari 5000 *step*) serta membangun jaringan yang lebih dalam dibandingkan RNN konvensional.

Struktur dasar IndRNN berbeda dengan RNN konvensional. Jika pada RNN setiap *neuron* dalam satu *layer* saling terhubung melalui matriks bobot rekuren, maka pada IndRNN setiap *neuron* hanya memiliki bobot rekuren skalar yang terhubung dengan dirinya sendiri. Hal ini membuat setiap neuron dalam satu *layer* bersifat independen. Secara matematis, *hidden state* pada *neuron* ke-*n* pada *timestep* ke-*t* dapat dituliskan sebagai berikut:

$$h_t^{(n)} = \sigma(w_n x_t + u_n h_{t-1}^{(n)} + b_n) \quad (2.1)$$

Keterangan:

- $h_t^{(n)}$ = *hidden state neuron* ke-*n* pada waktu ke-*t*
- σ = fungsi aktivasi
- w_n = bobot *input* pada *neuron* ke-*n*
- x_t = *input* pada waktu ke-*t*
- u_n = bobot *recurrent* skalar untuk *neuron* ke-*n*
- b_n = bias pada *neuron* ke-*n*

Persamaan ini menunjukkan bahwa setiap *neuron* dalam IndRNN memproses informasi secara mandiri, hanya bergantung pada *input* saat ini dan

hidden state miliknya sendiri pada *timestep* sebelumnya. Dengan demikian, IndRNN mampu menyederhanakan kompleksitas perhitungan sekaligus menjaga stabilitas gradien.

2.4 Fungsi Aktivasi

Fungsi aktivasi memiliki peran penting dalam proses pelatihan jaringan saraf karena memberikan unsur *non-linear* yang dibutuhkan agar model mampu mempelajari pola dan representasi yang lebih kompleks (Rasamoelina et al., 2020). Pada penelitian ini, beberapa fungsi aktivasi seperti ReLU, PReLU, ELU, dan Tanh diuji untuk melihat bagaimana perbedaannya memengaruhi performa model dalam memprediksi harga saham.

2.4.1 Rectified Linear Unit

Rectified Linear Unit (ReLU) adalah fungsi aktivasi yang sangat populer dan banyak digunakan dibeberapa penelitian (Mercioni & Holban, 2023). Fungsi ini diperkenalkan oleh (Nair & Hinton, 2010). ReLU meneruskan nilai input secara langsung jika bernilai positif dan memberikan nilai nol jika input bernilai negatif. Secara matematis, fungsi ReLU dapat didefinisikan sebagai berikut:

$$f(x) = \max(0, x) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (2.2)$$

Keterangan:
 x = nilai *input* yang diterima oleh *neuron*

2.4.2 Parametric Rectified Linear Unit

Parametric Rectified Linear Unit atau PReLU merupakan fungsi aktivasi yang diperkenalkan oleh He et al., (2015). PReLU memiliki karakteristik adaptif,

di mana kemiringan (*slope*) pada sisi negatif tidak bernali tetap melainkan nilainya diperoleh dari proses *training*. Hal ini memungkinkan model untuk menentukan nilai kemiringan negatif terbaik secara otomatis selama proses *training* (Alsharef et al., 2020). Secara matematis, formula PReLU dapat ditulis sebagai berikut:

$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha x, & \text{if } x \leq 0 \end{cases} \quad (2.3)$$

Keterangan:

- x = nilai input yang diterima oleh *neuron*
 α = parameter kemiringan yang dipelajari oleh model

2.4.3 Exponential Linear Unit

Fungsi aktivasi selanjutnya adalah *Exponential Linear Unit* (ELU) yang diperkenalkan oleh Clevert et al. (2016). Fungsi ini memiliki nilai negatif yang mendorong rata-rata aktivasi neuron mendekati nol, sehingga proses pembelajaran menjadi lebih stabil dan mendekati *natural gradient*. Selain itu, ELU akan mencapai nilai jenuh (*saturation*) pada sisi negatif, yang membuat variasi aktivasi lebih kecil dan informasi yang diteruskan ke lapisan berikutnya menjadi lebih stabil. Secara matematis, fungsi ELU dapat ditulis sebagai berikut:

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha (e^x - 1) & \text{if } x \leq 0 \end{cases} \quad (2.4)$$

Keterangan:

- x = nilai input yang diterima oleh *neuron*
 α = parameter positif yang mengontrol derajat *saturation* pada sisi negatif
 e = bilangan Euler

2.4.4 Hyperbolic Tangent

Hyperbolic Tangent atau yang sering dikenal Tanh, merupakan fungsi aktivasi yang memiliki karakteristik lebih halus (*smoother*), dengan *output* yang terpusat di nol (*zero-centered*) (Nwankpa et al., 2020). Fungsi ini memetakan nilai

input ke dalam rentang nilai antara -1 hingga 1 (Dubey et al., 2022). Secara matematis, formula Tanh dapat ditulis sebagai berikut:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

Keterangan:

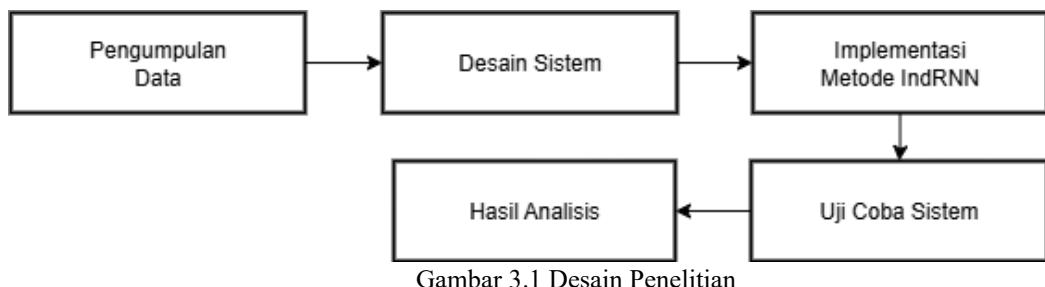
x = nilai input yang diterima oleh *neuron*
 e = bilangan Euler

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Penelitian ini disusun melalui beberapa tahapan yang terstruktur. Tahapan tersebut meliputi pengumpulan data, perancangan sistem, implementasi metode IndRNN, pengujian, serta analisis hasil. Alur penelitian secara umum ditunjukkan pada Gambar 3.1.



Gambar 3.1 Desain Penelitian

Alur penelitian pada Gambar 3.1 dimulai dari tahap pengumpulan data, yaitu memperoleh data harga saham BRIS dari sumber publik seperti Yahoo Finance. Data yang diperoleh kemudian digunakan pada tahap desain sistem, di mana dilakukan perancangan proses pra-pemrosesan, pembentukan dataset, serta perancangan arsitektur model IndRNN. Selanjutnya, tahap implementasi metode IndRNN dilakukan dengan membangun model sesuai rancangan dan menyiapkan proses pelatihan. Model yang telah dibangun kemudian dievaluasi pada tahap uji coba sistem untuk mengukur kinerjanya. Hasil dari pengujian ini dianalisis pada tahap hasil analisis, yaitu dengan menghitung metrik evaluasi RMSE dan MAPE serta membandingkan hasil prediksi dengan data aktual.

3.2 Pengumpulan Data

Pengumpulan data dalam penelitian ini menggunakan data sekunder berupa catatan historis harga saham PT Bank Syariah Indonesia Tbk dengan kode emiten BRIS. Data diperoleh melalui situs Yahoo Finance dengan periode pengambilan mulai dari 1 September 2020 hingga 1 September 2025. Dataset tersebut memuat 1203 baris data perdagangan yang masing-masing merepresentasikan aktivitas pasar pada satu hari bursa.

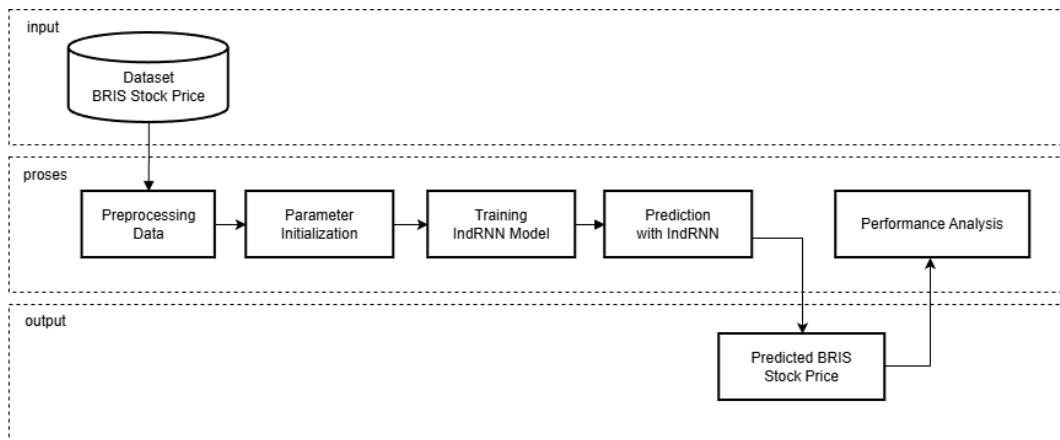
Penelitian ini berfokus pada prediksi harga penutupan (*closing price*), sehingga dari keseluruhan data hanya dua atribut yang dipilih, yakni *Date* dan *Close*. Atribut *date* bertipe *datetime* sebagai penanda urutan waktu, sedangkan *close* bertipe *float* yang menunjukkan harga penutupan harian saham. Data disimpan dalam format .csv agar mudah diproses pada tahap berikutnya. Adapun visualisasi data harga penutupan saham BRIS ditunjukkan pada plot berikut.



Gambar 3.2 Dataset Harga Saham BRIS

3.3 Desain Sistem

Desain sistem yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.2. Diagram tersebut memperlihatkan alur proses sistem yang diawali dari tahap *preprocessing*, dilanjutkan dengan proses pelatihan menggunakan model IndRNN, hingga menghasilkan *output* berupa prediksi harga penutupan saham BRIS. Pada implementasinya, sistem ini dibangun dengan menggunakan bahasa pemrograman Python. Dengan rancangan tersebut, penelitian dapat dilaksanakan secara terstruktur mulai dari pengolahan data hingga analisis hasil prediksi.



Gambar 3.3 Desain Sistem

3.4 *Preprocessing*

Tahap *preprocessing* bertujuan untuk menyiapkan data agar dapat diproses oleh model IndRNN. Proses ini dilakukan secara bertahap mulai dari pembagian data, normalisasi, hingga pembentukan *sliding window*.

3.4.1 *Splitting Data*

Langkah pertama yang dilakukan adalah membagi dataset menjadi dua bagian, yaitu data *training* dan data *testing*. Proses pembagian tidak dapat dilakukan secara acak, karena jenis data pada penelitian ini bersifat *time-series*. Oleh karena

itu, pembagian data dilakukan berdasarkan urutan waktu agar model dapat belajar dari data sebelumnya dan kemudian diuji pada data masa depan yang belum pernah dilihat. Tahap ini ditempatkan di awal proses *preprocessing* untuk menghindari terjadinya *information leakage*, yaitu kondisi ketika model secara tidak langsung memperoleh informasi dari data uji selama proses pelatihan (Apicella et al., 2025). Pada penelitian ini, rasio pembagian yang digunakan adalah 80:20 dan 70:30.

3.4.2 Normalisasi Data

Hasil dari *splitting* data, *subset* data *training* selanjutnya dinormalisasikan dengan menggunakan metode *Min-Max Scaling* ke dalam rentang [0,1]. Normalisasi merupakan langkah penting dalam pemrosesan data *time-series* karena dapat menghilangkan distorsi amplitudo dan *offset* tanpa mengubah pola utama dari data. Dengan demikian, pola yang sama dapat dikenali meskipun dengan rentang nilai yang berbeda (Lima & Souza, 2023). Secara matematis, formula untuk metode *Min-Max Scaling* dituliskan sebagai berikut:

$$\hat{x} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

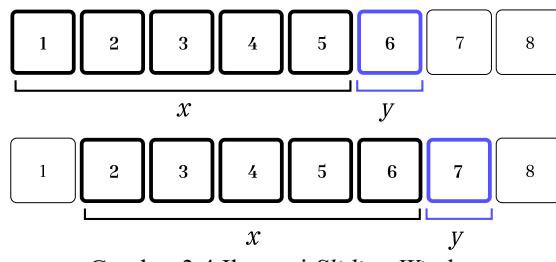
Keterangan:

- \hat{x} = data setelah dinormalisasi
- x_i = data sebelum dinormalisasi
- x_{min} = nilai minimum dari dataset
- x_{max} = nilai maksimum dari dataset

3.4.3 Sliding Window

Sliding Window merupakan teknik yang digunakan untuk mengubah data *time-series* menjadi format *supervised learning*, dengan cara memanfaatkan sejumlah data historis sebagai input untuk memprediksi nilai pada periode

berikutnya (Norwawi, 2021). Pada data *time-series*, setiap nilai memiliki hubungan dengan nilai pada periode sebelumnya. Oleh karena itu, informasi historis perlu diperhitungkan agar pola pergerakan dapat dikenali dengan baik. *Sliding window* membantu model memanfaatkan serangkaian data masa lalu, bukan hanya satu titik terakhir, sehingga pola temporal lebih kompleks bisa ditangkap. Ilustrasi mekanisme *sliding window* ditunjukkan pada Gambar 3.4. Misalkan panjang jendela (*window size*) ditentukan sebesar lima, maka lima data historis pertama digunakan untuk memprediksi nilai pada periode selanjutnya. Selanjutnya, jendela bergeser satu langkah ke kanan dan kembali membentuk pasangan *input–output* baru, dan proses ini terus berulang hingga seluruh data habis diproses.



Gambar 3.4 Ilustrasi *Sliding Window*

Secara matematis, pembentukan *sliding window* dapat dituliskan sebagai berikut:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-k}) \quad (3.2)$$

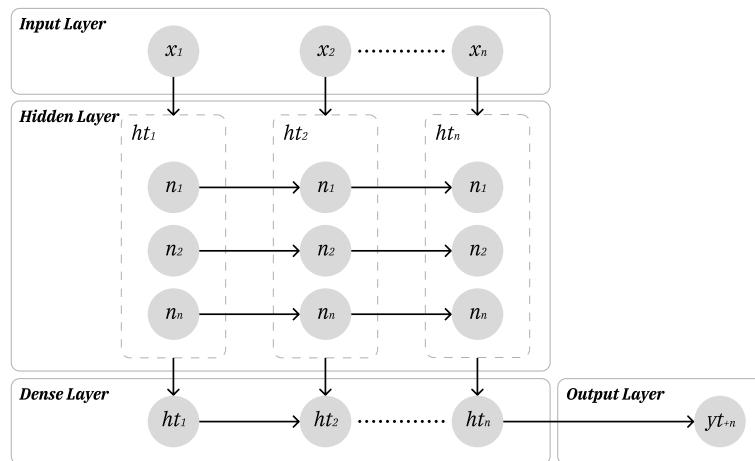
Keterangan:

- y_t = nilai aktual pada waktu ke- t
- y_{t-1} = data historis pada k periode sebelumnya
- k = ukuran jendela (*window size*)

3.5 Implementasi IndRNN

Implementasi model dilakukan dengan memanfaatkan arsitektur *Independent Recurrent Neural Network* (IndRNN). Model ini dirancang untuk

memproses data hasil dari tahap *preprocessing*, di mana setiap input (x_1, x_2, \dots, x_n) merepresentasikan urutan data historis yang akan digunakan untuk memprediksi harga pada 30 hari berikutnya. Ilustrasi arsitektur IndRNN ditunjukkan pada Gambar 3.5.



Gambar 3.5 Arsitektur IndRNN

Pada arsitektur tersebut, lapisan pertama adalah *Input Layer* yang menerima data hasil *preprocessing*. Data kemudian diproses oleh *IndRNN Layer*, di mana setiap *neuron* memiliki koneksi rekuren independen terhadap dirinya sendiri. Keluaran dari seluruh *hidden state* kemudian diproyeksikan melalui *Dense Layer*, yang melakukan penggabungan linear dengan bobot dan bias, sesuai dengan persamaan:

$$y_{t+n} = Wh_T + b \quad (3.3)$$

Keterangan:

- y_{t+n} = nilai prediksi harga saham pada periode berikutnya
- h_T = vektor *hidden state* ke- T hasil dari *hidden layer*
- W = matriks bobot pada *dense layer*
- b = nilai bias

Tahap terakhir adalah *Output Layer*, yang menghasilkan prediksi harga saham periode berikutnya.

3.6 Skenario Uji Coba

Pada tahap ini dilakukan serangkaian uji coba untuk menentukan kombinasi parameter terbaik dalam implementasi IndRNN. Skenario uji coba dirancang dengan memvariasikan beberapa parameter penting, yaitu *window size*, jumlah unit IndRNN, rasio pembagian data latih dan uji, serta fungsi aktivasi yang digunakan. Pemilihan parameter ini didasarkan pada pengaruhnya terhadap kemampuan model dalam mengenali pola historis harga saham BRIS. Adapun skenario uji coba yang digunakan dapat dilihat pada Tabel 3.1 berikut:

Tabel 3.1 Model & Rasio Split data

Model	Window Size	Hidden Unit	Split Ratio	Activation Function
Model A	20	64	70:30	ReLU, PreLU, ELU, Tanh
Model B	20	128		
Model C	30	64		
Model D	30	128		

Secara umum, variasi skenario pada Tabel 3.1 disusun agar model dapat dilatih dengan cara pandang yang berbeda-beda terhadap data historis. Ada skenario yang lebih menekankan pada pengenalan pola jangka pendek maupun jangka panjang melalui pengaturan *window size*, ada pula yang menguji kapasitas memori dari tingkat sederhana hingga yang lebih kompleks melalui perbedaan jumlah unit. Variasi ini, ditambah dengan beragam fungsi aktivasi dan rasio pembagian data, setiap konfigurasi memberikan kesempatan bagi model untuk mengenali karakteristik dan fluktuasi harga saham dari sisi yang berbeda-beda.

3.7 Evaluasi

Tahap evaluasi bertujuan untuk menilai kinerja model IndRNN dalam melakukan prediksi harga saham BRIS. Evaluasi dilakukan dengan menggunakan

beberapa metrik yang dapat menggambarkan tingkat akurasi model dari berbagai sudut pandang. Metrik yang digunakan meliputi *Root Mean Square Error* (RMSE) untuk mengukur kesalahan absolut dalam skala harga, *Mean Absolute Percentage Error* (MAPE) untuk menilai tingkat kesalahan relatif dalam bentuk persentase, serta *Directional Accuracy* (DA) untuk mengevaluasi kemampuan model dalam memprediksi arah pergerakan harga saham.

3.7.1 Root Mean Square Error

Root Mean Square Error (RMSE) merupakan akar kuadrat dari kesalahan kuadrat rata-rata yang dihitung berdasarkan selisih antara nilai aktual dengan nilai prediksi. RMSE dapat dirumuskan sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (3.4)$$

Keterangan:

- Y_i = nilai aktual pada data ke-*i*
- \hat{Y}_i = nilai prediksi pada data ke-*i*
- n = jumlah data pengamatan

RMSE banyak digunakan sebagai metrik standar dalam evaluasi model, karena hasil perhitungan berada pada satuan yang sama dengan data asli sehingga dapat merepresentasikan kesalahan tipikal pada distribusi *error* normal (Hodson, 2022).

3.7.2 Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) merupakan metrik evaluasi yang menyatakan tingkat kesalahan prediksi dalam bentuk persentase. Perhitungannya

dilakukan dengan menghitung rata-rata selisih relatif antara nilai aktual dan hasil prediksi (Oak et al., 2024). Persamaan MAPE ditunjukkan sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (3.5)$$

Keterangan:

- Y_i = nilai aktual pada data ke- i
- \hat{Y}_i = nilai prediksi pada data ke- i
- n = jumlah data pengamatan

3.7.3 *Directional Accuracy*

Directional Accuracy (DA) merupakan metrik evaluasi yang digunakan untuk menilai kemampuan model dalam memprediksi arah pergerakan harga saham, apakah arah pergerakan naik atau turun sesuai dengan data aktual (Chang et al., 2024). Secara matematis, *Directional Accuracy* didefinisikan sebagai berikut:

$$DA = \frac{1}{N} \sum_{t=2}^N I [sign(\hat{y}_t - y_{t-1}) = sign(y_t - y_{t-1})] \times 100\% \quad (3.6)$$

Keterangan:

- N = jumlah total observasi
- y_t = nilai aktual pada waktu ke- t
- \hat{y}_t = nilai hasil prediksi pada waktu ke- t
- I = fungsi indikator, bernilai 1 jika kondisi benar dan 0 jika salah
- $sign$ = fungsi tanda, bernilai +1 untuk kenaikan dan -1 untuk penurunan

BAB IV

UJI COBA DAN PEMBAHASAN

4.1 Hasil *Preprocessing*

Tahap ini menampilkan hasil dari proses pra-pemrosesan data yang telah dilakukan sebelum tahap pelatihan model. Tahapan ini meliputi proses *splitting data*, normalisasi data, dan pembentukan *sliding window*. Pada penelitian ini data yang digunakan sebagai *groundtruth* berupa harga *close* harian saham PT Bank Syariah Indonesia Tbk (BRIS) yang diperoleh melalui situs Yahoo Finance sesuai periode penelitian. Sampel data harga saham yang digunakan dapat dilihat pada Tabel 4.1.

Tabel 4.1 *Groundtruth* Harga Saham

Tanggal	Harga Penutupan
2020-09-01	950.9260864257812
2020-09-02	946.049560546875
2020-09-03	931.419921875
...	...
2025-09-01	2690.0

4.1.1 Hasil *Splitting Data*

Pada penelitian ini digunakan dua skenario pembagian data, yaitu 80% data *training* dan 20% data *testing*, serta 70% data *training* dan 30% data *testing*. Hasil pembagian data dengan rasio 80:20 menghasilkan 952 data *training* dan 231 data *testing*, sedangkan pada rasio 70:30 diperoleh 842 data *training* dan 361 data *testing* sebagaimana ditunjukkan pada Tabel 4.2.

Tabel 4.2 Jumlah data *training* dan data *testing* setiap rasio

Rasio	\sum Data Training	\sum Data Testing
80:20	962	241
70:30	842	361

4.1.2 Hasil Normalisasi Data

Proses normalisasi dilakukan untuk menyamakan skala nilai pada setiap fitur agar model dapat mempelajari pola data dengan lebih stabil. Data harga saham yang digunakan memiliki rentang nilai yang cukup besar antar periode, sehingga perlu disesuaikan ke dalam skala yang lebih kecil. Metode yang digunakan dalam penelitian ini adalah *Min-Max Scaling*, yang mengubah setiap nilai menjadi berada pada rentang 0 hingga 1. Contoh data harga penutupan saham sebelum dan setelah dilakukan normalisasi dapat dilihat pada Tabel 4.3.

Tabel 4.3 Data sebelum dan setelah dinormalisasi

Tanggal	Sebelum Normalisasi	Setelah Normalisasi
2020-09-01	950.9260864257812	0.08210181
2020-09-02	946.049560546875	0.08045978
2020-09-03	931.419921875	0.07553367
2020-09-04	960.67919921875	0.08538589
...
2025-09-01	2690.0	0.66768497

4.1.3 Hasil *Sliding Window*

Setelah proses normalisasi dilakukan, tahap selanjutnya adalah pembentukan *sliding window*. Tahapan ini bertujuan untuk mengubah data deret waktu menjadi pasangan *input-target* yang dapat dipelajari oleh model IndRNN. Melalui metode ini, sejumlah data harga penutupan sebelumnya dijadikan sebagai *input sequence* untuk memprediksi nilai harga penutupan pada periode berikutnya.

Pada penelitian ini digunakan dua skenario ukuran *window*, yaitu 20 hari dan 30 hari. Artinya, pada skenario pertama (*window size* = 20), 20 hari data harga penutupan sebelumnya digunakan untuk memprediksi harga pada 30 hari selanjutnya, sedangkan pada skenario kedua (*window size* = 30), 30 hari data harga

penetupan sebelumnya digunakan untuk memprediksi harga pada 30 hari selanjutnya. Proses ini dilakukan secara bergeser satu langkah setiap kali, sehingga seluruh data terbentuk menjadi pasangan *input–output* berurutan seperti yang ditunjukkan pada Lampiran 1, Lampiran 2, Lampiran 3, dan Lampiran 4.

4.2 Hasil Uji Coba

Pengujian model pada penelitian ini dilakukan sebanyak 36 kali berdasarkan skenario yang telah ditentukan, dengan kombinasi parameter, rasio pembagian data, serta fungsi aktivasi yang berbeda. Hasil dari setiap pengujian menghasilkan nilai prediksi harga saham yang kemudian dievaluasi menggunakan metrik RMSE, MAPE, *Directional Accuracy* (DA) dan juga waktu *training*. Hasil dari evaluasi tersebut digunakan untuk menilai performa model dan membandingkan akurasi antar skenario yang diuji.

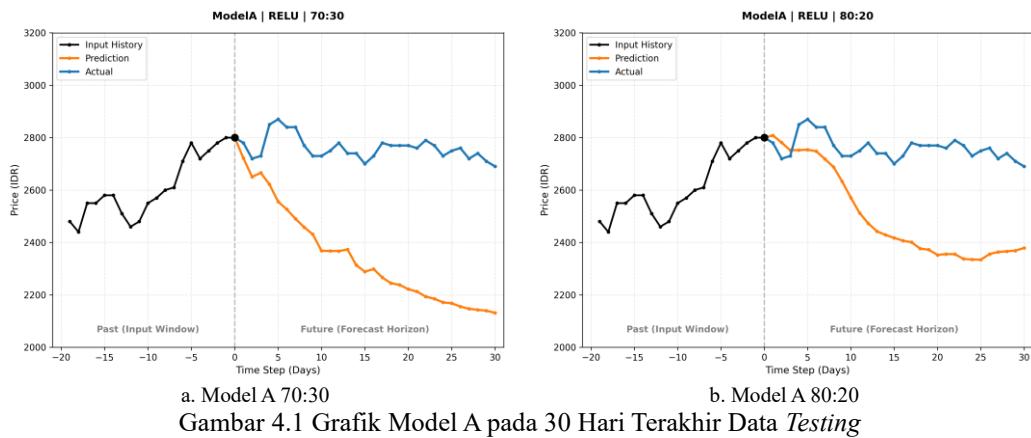
4.2.1 Fungsi Aktivasi ReLU

Bagian ini menyajikan hasil eksperimen model IndRNN yang dilatih menggunakan fungsi aktivasi ReLU. Penerapan fungsi ini pada keempat skenario model (Model A, B, C, dan D) dilakukan untuk menguji konsistensi performanya dalam menangkap tren data historis, baik pada konfigurasi memori jangka pendek maupun panjang. Adapun rincian hasil analisis dari masing-masing eksperimen tersebut disajikan sebagai berikut.

4.2.1.1 Model A

Model A menggunakan kombinasi parameter dengan *window size* sebanyak 20, jumlah unit IndRNN sebanyak 64, dan jumlah *epoch* sebanyak 1000. Model ini

diuji menggunakan dua rasio pembagian data, yaitu 70:30 dan 80:20. Hasil visualisasi perbandingan antara tren data input, nilai prediksi, dan nilai aktual harga saham pada Model A dapat dilihat pada Gambar 4.1.



Visualisasi Gambar 4.1 menunjukkan rasio 80:20 lebih stabil dalam merespons momentum dibanding rasio 70:30. Saat data input (garis hitam) mengalami *uptrend* kuat, garis prediksi (oranye) pada rasio 70:30 justru turun menjauhi data aktual (garis biru). Sebaliknya, pada rasio 80:20, garis prediksi terlihat lebih landai dan mampu menahan penurunan drastis. Hal ini menunjukkan bahwa tambahan data latih membantu model mengenali tren dengan lebih baik dan tidak terlalu reaktif terhadap koreksi harga. Adapun rekapitulasi nilai evaluasi *error*, akurasi arah, serta durasi waktu *training* disajikan dalam Tabel 4.4 untuk memberikan gambaran performa dari Model A.

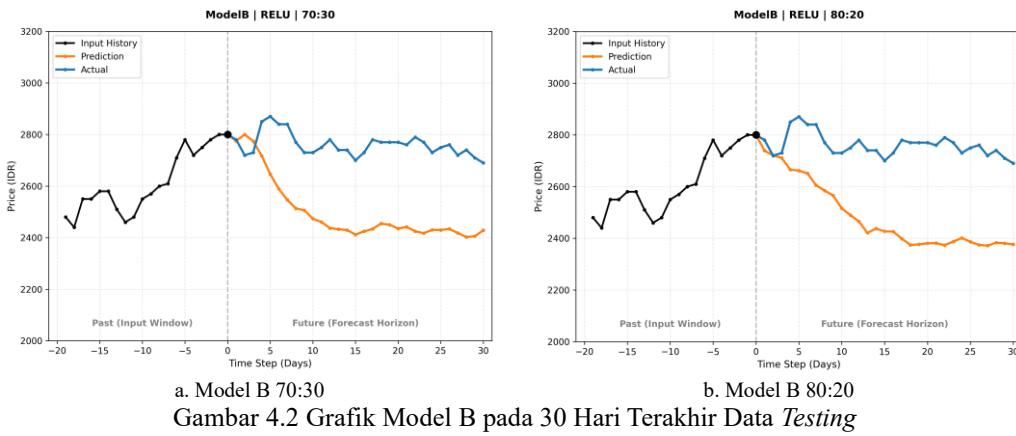
Tabel 4.4 Hasil Evaluasi pada Model B (ReLU)

Model A (ReLU)	RMSE	MAPE	DA	Time Training
70:30	452.77	13.55%	51.15%	4 menit 12 detik
80:20	324.43	9.25%	50.20%	4 menit 40 detik

Berdasarkan hasil evaluasi yang ditunjukkan oleh Tabel 4.4, terlihat adanya peningkatan performa yang signifikan seiring dengan bertambahnya jumlah data latih. Pada rasio pembagian data 80:20, memperoleh nilai RMSE sebesar 324.43 dan MAPE 9.25%. Capaian ini jauh lebih baik dibandingkan skenario 70:30 yang memiliki RMSE sebesar 452.77 dan MAPE 13.55%. Namun, peningkatan akurasi pada rasio 80:20 membutuhkan biaya komputasi yang lebih tinggi, di mana proses pelatihan memakan waktu sekitar 4 menit 40 detik, sedikit lebih lama dibandingkan rasio 70:30 yang selesai dalam 4 menit 12 detik. Sedangkan, pada *Directional Accuracy* (DA), rasio 70:30 justru mencatatkan nilai yang sedikit lebih tinggi, yaitu 51.15%, dibandingkan rasio 80:20 yang sebesar 50.20%. Fenomena ini menunjukkan bahwa meskipun rasio 80:20 memiliki evaluasi numerik yang lebih baik, rasio 70:30 sedikit lebih baik dalam menebak arah pergerakan tren.

4.2.1.2 Model B

Model B dirancang untuk menguji pengaruh peningkatan jumlah *hidden unit* terhadap akurasi prediksi. Berbeda dengan model sebelumnya, konfigurasi ini menggandakan jumlah *hidden unit* IndRNN menjadi 128 neuron, namun tetap mempertahankan *window size* yang sama yaitu 20 hari. Hasil visualisasi perbandingan antara tren data *input* dan hasil prediksi pada Model B dapat dilihat pada Gambar 4.2.



Secara visual pada Gambar 4.2, terlihat bahwa peningkatan kompleksitas model menjadi 128 *neuron* menghasilkan kurva prediksi yang lebih halus dibandingkan Model A, namun secara umum model masih menunjukkan perilaku konservatif terhadap momentum *input*. Meskipun data *input* (garis hitam) memperlihatkan tren kenaikan yang kuat menuju titik prediksi, kedua skenario pembagian data pada Model B tetap memprediksi terjadinya penurunan harga. Pada rasio 70:30 dan 80:20, garis prediksi (oranye) langsung bergerak turun menjauhi level harga terakhir data *input*, melebar dari data aktual (biru) yang cenderung bertahan di area atas. Hal ini mengindikasikan bahwa penambahan jumlah *hidden unit* saja belum cukup untuk menghasilkan prediksi yang lebih akurat. Rincian nilai evaluasi performa Model B untuk kedua rasio pembagian data disajikan dalam Tabel 4.5.

Tabel 4.5 Hasil Evaluasi pada Model B (ReLU)

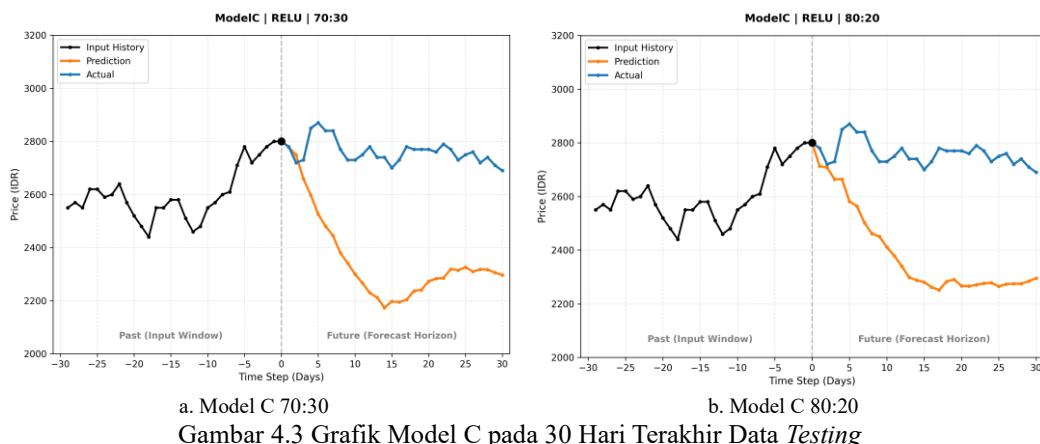
Model B (ReLU)	RMSE	MAPE	DA	Time Training
70:30	312.85	9.10%	49.74%	4 menit 42 detik
80:20	317.02	9.39%	51.02%	5 menit 2 detik

Berdasarkan evaluasi pada Tabel 4.5, selisih performa antara kedua rasio terbilang sangat tipis. Skenario 70:30 mencatatkan RMSE sebesar 312.85 dan

MAPE 9.10%, hanya unggul sedikit dibandingkan skenario 80:20 yang memiliki RMSE 317.02 dan MAPE 9.39%. Namun, pada evaluasi *Directional Accuracy*, rasio 80:20 sedikit lebih unggul dengan nilai 51.31%, dibandingkan rasio 70:30 yang sebesar 49.74%. Sedangkan dari sisi komputasi, peningkatan kompleksitas model berdampak pada durasi pelatihan. Waktu *training* pada rasio 80:20 berdurasi 5 menit 2 detik, sedikit lebih lama dibandingkan rasio 70:30 yang memakan waktu 4 menit 42 detik.

4.2.1.3 Model C

Pada Model C parameter *window size* ditingkatkan menjadi 30 hari, sedangkan untuk *hidden unit* sebanyak 64 neuron. Model C dilatih selama 1000 *epoch* untuk melihat apakah penambahan input dapat membantu model mengenali pola harga dengan lebih baik. Hasil visualisasi perbandingan antara tren data *input* dan hasil prediksi pada Model C dapat dilihat pada Gambar 4.3.



Secara visual pada Gambar 4.3, terlihat bahwa peningkatan *window size* menjadi 30 hari justru berdampak negatif terhadap akurasi prediksi arah tren. Meskipun data *input* (garis hitam) menunjukkan pola kenaikan harga (*uptrend*)

yang solid selama 30 hari ke belakang, respons model pada kedua skenario pembagian data menunjukkan divergensi yang ekstrem. Tepat setelah titik prediksi dimulai ($t=0$), garis prediksi (orange) mengalami penurunan yang curam, bergerak berlawanan arah dengan momentum *input*-nya. Sedangkan untuk hasil evaluasi *error*, akurasi arah, serta waktu *training* pada Model C disajikan dalam Tabel 4.6.

Tabel 4.6 Hasil Evaluasi pada Model C (ReLU)

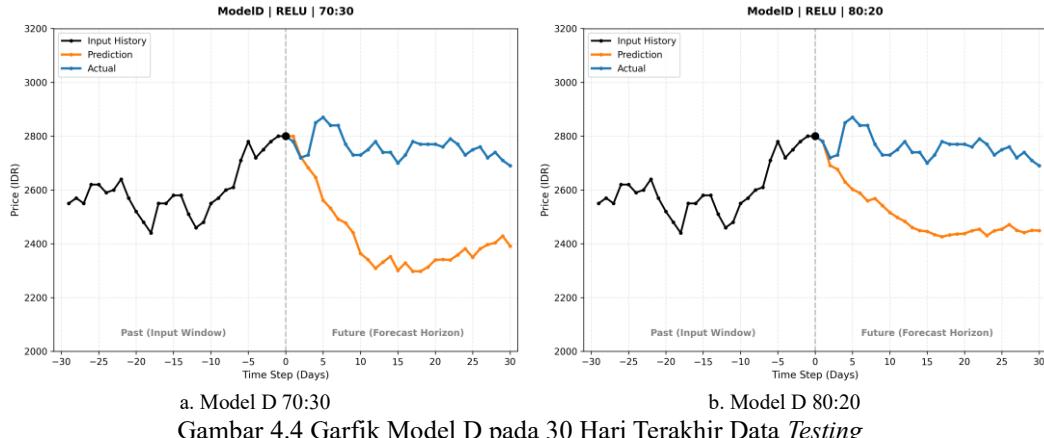
Model C (ReLU)	RMSE	MAPE	DA	Time Training
70:30	388.3	11.6%	50.65%	6 menit 10 detik
80:20	400.95	12.2%	50.1%	6 menit 40 detik

Hasil evaluasi pada Tabel 4.6 mengonfirmasi penurunan performa tersebut. Berbeda dengan Model A dan Model B, Model C mencatatkan nilai *error* yang jauh lebih tinggi. Pada skenario 70:30, diperoleh RMSE sebesar 388.30 dengan MAPE 11.6%. Penambahan data latih pada skenario 80:20 justru memperburuk akurasi, dengan RMSE meningkat menjadi 400.95 dan MAPE naik ke angka 12.2%. Dari sisi *Directional Accuracy*, kedua rasio menunjukkan hasil yang stagnan di angka 50.66% dan 50.10%. Selain penurunan akurasi, penambahan *window size* juga berdampak signifikan pada biaya komputasi. Waktu pelatihan meningkat drastis menjadi kisaran 6 menit, lebih lama dibandingkan Model A dan B yang rata-rata selesai di bawah 5 menit.

4.2.1.4 Model D

Pada Model D, jumlah *hidden unit* ditingkatkan menjadi 128 *neuron*, dengan tetap mempertahankan *window size* sebanyak 30 hari. Konfigurasi ini bertujuan untuk melihat apakah peningkatan kapasitas komputasi (*hidden unit*) mampu mengompensasi kesulitan yang dialami model sebelumnya dalam mengolah

window data yang panjang. Hasil visualisasi perbandingan antara tren data *input* dan hasil prediksi pada Model D dapat dilihat pada Gambar 4.4.



a. Model D 70:30
b. Model D 80:20

Gambar 4.4 Garfik Model D pada 30 Hari Terakhir Data *Testing*

Secara visual pada Gambar 4.4, terlihat perbedaan perilaku yang cukup kontras antara kedua skenario pembagian data dalam merespons momentum *input*. Pada rasio 70:30, peningkatan jumlah *hidden unit* tampaknya belum cukup untuk mengatasi bias negatif dari *window size* 30 hari. Meskipun data *input* (garis hitam) menunjukkan tren kenaikan yang jelas, garis prediksi (oranye) masih menunjukkan pola penurunan yang tajam, serupa dengan kegagalan yang terjadi pada Model C.

Namun, perbaikan performa mulai terlihat pada rasio 80:20. Dengan jumlah data latih yang lebih banyak, garis prediksi terlihat mulai mencoba mendekati data aktual (biru). Meskipun arah umumnya masih menurun dan belum mampu menyamai level harga aktual, kurva penurunannya terlihat jauh lebih landai dan terkendali dibandingkan rasio 70:30. Hal ini mengindikasikan bahwa kombinasi arsitektur yang lebih kompleks (128 *unit*) dan data latih yang lebih kaya (80%) mulai membantu model untuk meredam kesalahan prediksi ekstrem, meskipun

belum sepenuhnya mampu menangkap momentum kenaikan harga yang sebenarnya.

Rincian nilai evaluasi *error*, akurasi arah, serta durasi waktu *training* disajikan dalam Tabel 4.7.

Tabel 4.7 Hasil Evaluasi pada Model D (ReLU)

Model D (ReLU)	RMSE	MAPE	DA	Time Training
70:30	338.06	9.64%	49.98%	6 menit 37 detik
80:20	286.69	8.18%	49%	7 menit 10 detik

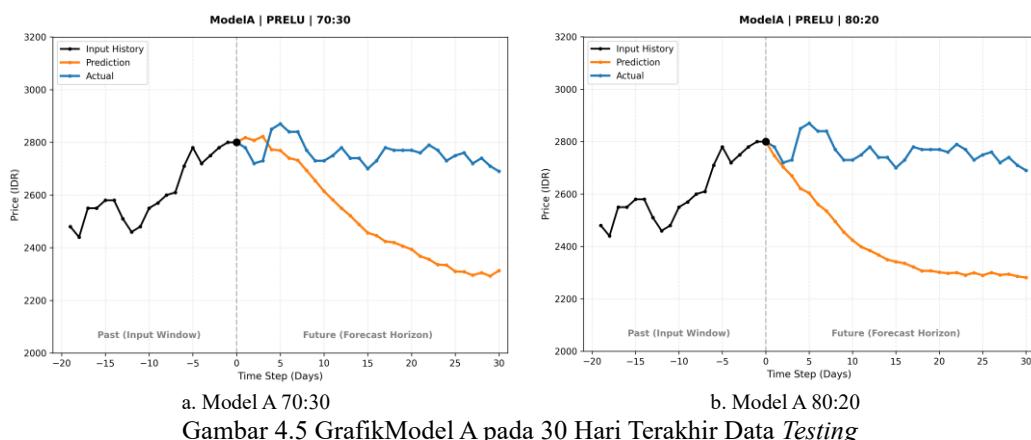
Berdasarkan hasil yang dipaparkan pada Tabel 4.7, pada rasio 80:20, Model D berhasil mencatatkan nilai RMSE terendah di antara seluruh eksperimen ReLU, yaitu sebesar 286.69, dengan nilai MAPE di angka 8.18%. Capaian ini jauh lebih baik dibandingkan rasio 70:30 yang masih tertahan di RMSE 338.06. Artinya, penambahan data latih sebesar 10% pada model kompleks ini memberikan dampak terhadap akurasi numerik. Namun, kemampuan Model D 80:20 dalam menebak arah tren justru hanya memperoleh DA 49%. Konsekuensi dari kompleksitas tinggi pada Model D adalah beban komputasi yang besar. Proses pelatihan pada rasio 80:20 memakan waktu hingga 7 menit 10 detik.

4.2.2 Fungsi Aktivasi PreLU

Selanjutnya, pengujian beralih pada penerapan fungsi aktivasi *Parametric Rectified Linear Unit* (PReLU). Pengujian dilakukan terhadap keempat skenario arsitektur (Model A, B, C, dan D) untuk melihat seberapa konsisten performa prediksi yang dihasilkan dalam mengenali tren data, baik pada pengaturan memori jangka pendek maupun panjang. Rincian analisis performa dari masing-masing eksperimen tersebut dipaparkan sebagai berikut.

4.2.2.1 Model A

Model A menggunakan kombinasi parameter dengan *window size* sebanyak 20, jumlah unit IndRNN sebanyak 64, dan jumlah *epoch* sebanyak 1000. Model ini diuji menggunakan dua rasio pembagian data, yaitu 70:30 dan 80:20. Hasil visualisasi perbandingan antara tren data *input* dan hasil prediksi pada Model A dengan aktivasi PReLU dapat dilihat pada Gambar 4.5.



Secara visual pada Gambar 4.5, terlihat bahwa penggunaan fungsi aktivasi PReLU pada Model A menghasilkan pola prediksi yang memiliki karakteristik serupa dengan fungsi aktivasi sebelumnya. Model masih menunjukkan bias negatif yang kuat dalam merespons momentum harga. Meskipun data *input* (garis hitam) menunjukkan pergerakan harga yang sedang naik, garis prediksi (oranye) pada kedua rasio pembagian data justru bergerak berlawanan arah. Baik pada rasio 70:30 maupun 80:20, model memproyeksikan terjadinya penurunan setelah periode prediksi dimulai, sehingga menciptakan *gap* yang semakin melebar terhadap data aktual (biru).

Adapun rekapitulasi nilai evaluasi *error*, akurasi arah, serta durasi waktu pelatihan disajikan dalam Tabel 4.8 untuk memberikan gambaran performa dari Model A.

Tabel 4.8 Hasil Evaluasi pada Model A (PReLU)

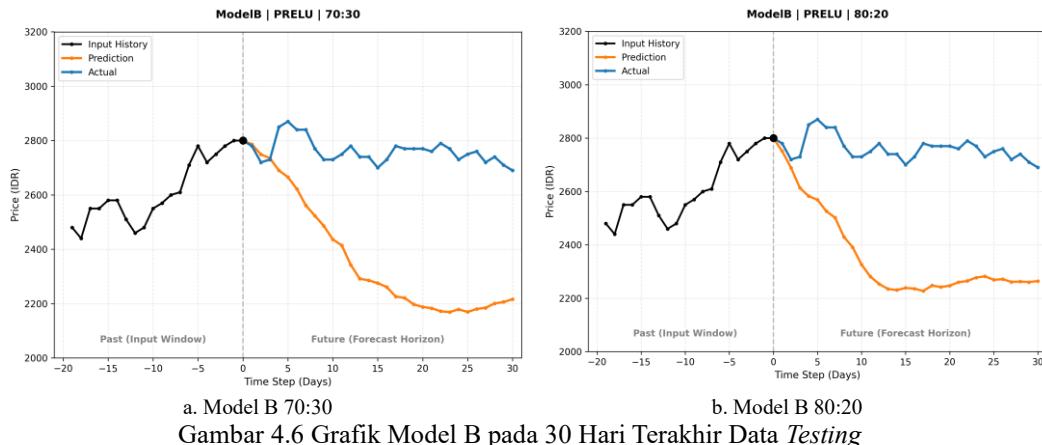
Model A (PReLU)	RMSE	MAPE	DA	Time Training
70:30	388.01	11.24%	51.55%	6 menit 22 detik
80:20	416.77	12.8%	51.19%	6 menit 58 detik

Data pada Tabel 4.8 mengonfirmasi grafik yang ditampilkan pada Gambar 4.5. Rasio 70:30 dan 80:20 mencatatkan nilai evaluasi numerik yang lumayan tinggi, pada rasio 70:30 memperoleh 388.01 dengan MAPE 11.24%. Sementara itu, pada rasio 80:20, RMSE naik menjadi 416.77 dengan MAPE 12.8%. Namun pada evaluasi *Directional Accuracy*. Rasio 70:30 memperoleh nilai DA sebesar 51.56%, yang merupakan angka yang cukup baik dalam memprediksi arah tren. Dari sisi komputasi, penggunaan PReLU terbukti memakan biaya waktu yang lebih mahal dibanding dengan ReLU. Waktu pelatihan rasio 70:30 berdurasi 6 menit 22 detik dan rasio 80:20 berdurasi 6 menit 58 detik, jauh lebih lama dibandingkan ReLU yang hanya membutuhkan waktu sekitar 4 menit. Hal ini disebabkan oleh komputasi tambahan untuk memperbarui parameter α pada setiap *neuron* selama proses *training*.

4.2.2.2 Model B

Pada Model B, jumlah *hidden unit* ditingkatkan menjadi 128 neuron dengan tetap mempertahankan *window size* 20 hari. Fokus utama pengujian ini adalah melihat apakah fungsi aktivasi PReLU dapat belajar dengan kapasitas unit yang lebih besar untuk menangkap pola data yang lebih kompleks. Visualisasi

perbandingan antara tren data *input* dan hasil prediksi pada Model B ditunjukkan pada Gambar 4.6.



Secara visual pada Gambar 4.6, terlihat bahwa penambahan jumlah *hidden unit* belum memberikan dampak signifikan dalam memperbaiki arah prediksi. Karakteristik grafik yang dihasilkan masih sangat serupa dengan Model A, di mana model tetap menunjukkan sentimen negatif yang kuat. Peningkatan *hidden unit* menjadi 128 *neuron* tampaknya hanya membuat kurva penurunan menjadi sedikit lebih halus, namun tidak mengubah pola prediksi (garis oranye) yang mendekati data aktual (garis biru). Hal ini mengindikasikan bahwa kombinasi *window size* 20 hari dengan aktivasi PReLU memiliki kecenderungan bias yang persisten terhadap pola penurunan historis, dan sekadar menambah jumlah *neuron* tidak cukup untuk membuat model lebih sensitif terhadap tren yang sedang terjadi pada data aktual.

Adapun rekapitulasi nilai evaluasi *error*, akurasi arah, serta durasi waktu pelatihan disajikan dalam Tabel 4.9 untuk memberikan gambaran performa dari Model B.

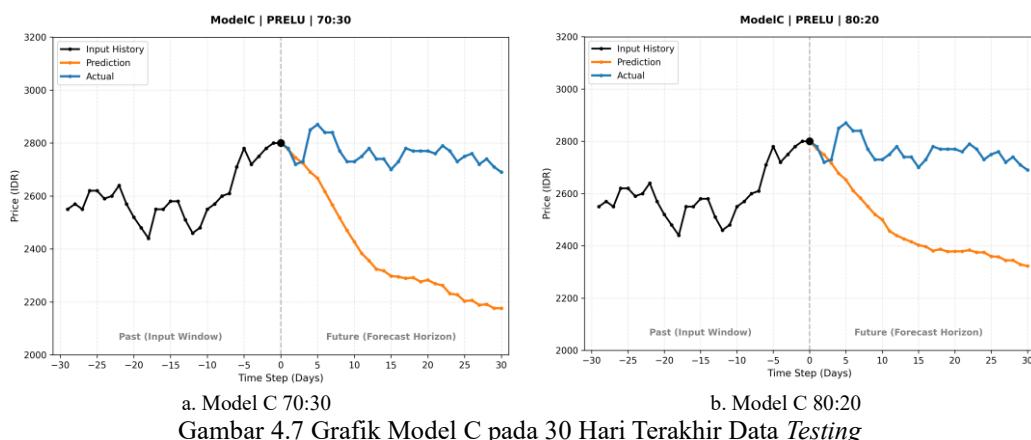
Tabel 4.9 Hasil Evaluasi pada Model B (PReLU)

Model B (PReLU)	RMSE	MAPE	DA	Time Training
70:30	438.39	13.23%	51.13%	6 menit 51 detik
80:20	426.17	13.21%	49.25%	7 menit 26 detik

Berdasarkan hasil evaluasi dari Tabel 4.9, hasilnya lebih tergambarkan bahwasannya Model B masih belum mengalami peningkatan. Hal ini ditunjukkan oleh RMSE sebesar 426.17 dan MAPE 13.21% untuk rasio 80:20 serta rasio 70:30 mencatat RMSE 438.39 dan MAPE 13.23%. Namun pada evaluasi *Directional Accuracy* pada rasio 70:30 masih mampu menjaga DA di angka 51.14%, sedangkan 80:20 turun menjadi 49.25%. Penambahan *hidden unit* juga membebani proses pelatihan secara signifikan. Waktu *training* yang dibutuhkan pada rasio 80:20 menembus angka 7 menit 26 detik.

4.2.2.3 Model C

Model C merupakan konfigurasi yang memperluas rentang input historis dengan menetapkan *window size* sebesar 30 hari, sementara *hidden unit* memiliki jumlah 64 *neuron*. Hasil visualisasi perbandingan antara tren data *input* dan hasil prediksi pada Model C dapat dilihat pada Gambar 4.7.



Secara visual pada Gambar 4.7, terlihat keduanya masih menunjukkan kecenderungan bias negatif terhadap tren *input* (garis hitam). Pada rasio 70:30, model tampak kesulitan mengelola memori jangka panjang. Meskipun data *input* menunjukkan tren kenaikan, garis prediksi (oranye) justru mengalami penurunan dan menjauhi data aktual (garis biru). Sebaliknya, perbaikan performa terlihat pada rasio 80:20. Garis prediksi pada rasio ini terlihat jauh lebih terkendali dan tidak mengalami penurunan sedrastis rasio 70:30. Jarak (*gap*) antara prediksi dan data aktual menjadi lebih rapat, yang mengindikasikan bahwa penambahan data latih membantu parameter PReLU untuk meredam kesalahan prediksi, sehingga menghasilkan kurva yang lebih landai.

Namun, terlepas dari perbaikan pada rasio 80:20, secara umum kedua grafik menunjukkan bahwa Model C masih belum mampu sepenuhnya mengikuti pola tren fluktuatif pada data aktual. Model C masih cenderung memprediksi penurunan (*downtrend*) meskipun dihadapkan pada momentum *input* yang sedang naik.

Adapun rekapitulasi nilai evaluasi *error*, akurasi arah, serta durasi waktu pelatihan disajikan dalam Tabel 4.10 untuk memberikan gambaran performa dari Model C.

Tabel 4.10 Hasil Evaluasi pada Model C (PReLU)

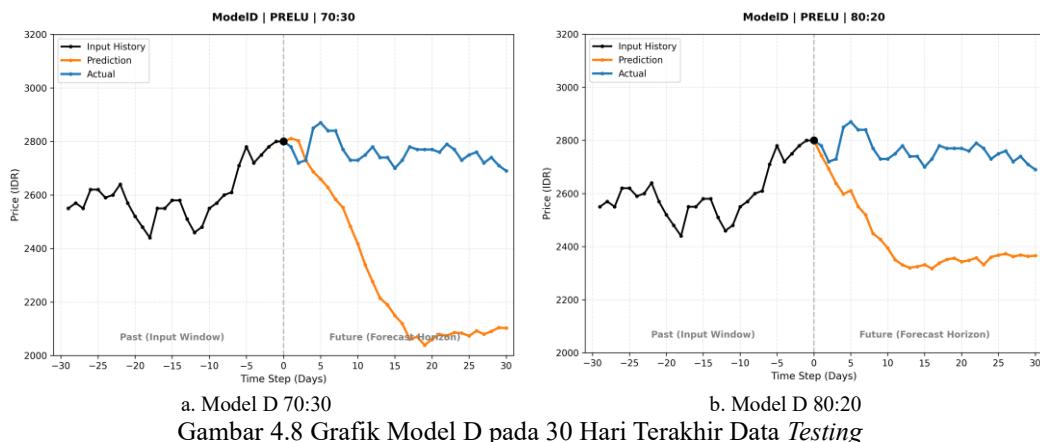
Model C (PReLU)	RMSE	MAPE	DA	Time Training
70:30	433.37	12.92%	52.14%	9 menit 8 detik
80:20	361.24	10.86%	50.74%	10 menit 3 detik

Berdasarkan hasil evaluasi yang ditunjukkan oleh Tabel 4.10, terlihat bahwa perbedaan rasio menunjukkan perbedaan. Pada rasio 80:20, model menunjukkan kemampuan yang relatif lebih baik dalam meminimalisir kesalahan prediksi,

dengan memperoleh nilai RMSE sebesar 361.24 dan MAPE 12.97%. Sebaliknya, pada rasio 70:30, terjadi penurunan, nilai RMSE berada di angka 433.37 dengan MAPE 10.86%. Pada evaluasi *Directional Accuracy*, rasio 70:30 memperoleh nilai DA terbaik yakni 52.14% sedangkan pada rasio 80:20 hanya memperoleh 50.74%. Sedangkan dari prespektif komputasional, durasi *training* Model C tercatat lebih lama dibandingkan Model A dan B, hal ini diakibatkan oleh dimensi input yang lebih besar. Waktu yang dibutuhkan mencapai 9 menit 8 detik untuk rasio 70:30 dan 10 menit 3 detik untuk rasio 80:20.

4.2.2.4 Model D

Model D mengkombinasikan dimensi *input* historis yang panjang (*window size* 30 hari) dengan jumlah *hidden unit* 128. Eksperimen ini ditujukan untuk mengobservasi apakah fungsi aktivasi PReLU mampu memproses *input* yang panjang dan jumlah *hidden unit* yang besar untuk menghasilkan prediksi yang lebih akurat. Komparasi visual antara tren data *input* dan hasil prediksi pada Model D dapat diamati pada Gambar 4.8.



Secara visual pada Gambar 4.8, terlihat perbedaan stabilitas prediksi yang sangat signifikan antara kedua rasio pembagian data, meskipun keduanya masih belum mampu mengikuti level harga aktual. Pada rasio 70:30, model menunjukkan kegagalan dalam menangkap momentum positif dari data *input*. Meskipun garis *input* (hitam) naik, garis prediksi (oranye) justru mengalami penurunan, menciptakan divergensi yang sangat lebar terhadap data aktual (biru). Sebaliknya, pada rasio 80:20, terlihat adanya perbaikan yang nyata dalam hal stabilitas. Meskipun pada awal prediksi model sempat melakukan koreksi turun, garis prediksi kemudian mampu menahan penurunan dan bergerak mendekati data aktual mulai hari ke-10 hingga akhir. Hal ini berbeda jauh dengan rasio 70:30 yang terus menurun. Adapun rekapitulasi nilai evaluasi *error*, akurasi arah, serta durasi waktu pelatihan disajikan dalam Tabel 4.11 untuk memberikan gambaran performa dari Model D.

Tabel 4.11 Hasil Evaluasi pada Model D (PReLU)

Model D (PReLU)	RMSE	MAPE	DA	Time Training
70:30	428.31	12.67%	51.8%	9 menit 49 detik
80:20	375.06	11.54%	48.7%	10 menit 42 detik

Berdasarkan hasil yang diperoleh dari Tabel 4.11, proporsi pembagian data sangat berdampak terhadap akurasi yang diperoleh, pada rasio 70:30, model mencatatkan nilai RMSE sebesar 428.31 dan MAPE 12.67%. Namun, ketika data latih diperbesar menjadi rasio 80:20, tingkat akurasi meningkat, di mana nilai RMSE menurun menjadi 375.06 dan MAPE 11.54%. Meskipun baik didalam evaluasi numerik, rasio 80:20 mengalami penurunan pada evaluasi *Directional*

Accuracy (DA). Rasio 80:20 memperoleh nilai DA 48.7%, sedangkan rasio 70:30 justru lebih baik yakni memperoleh 51.8%.

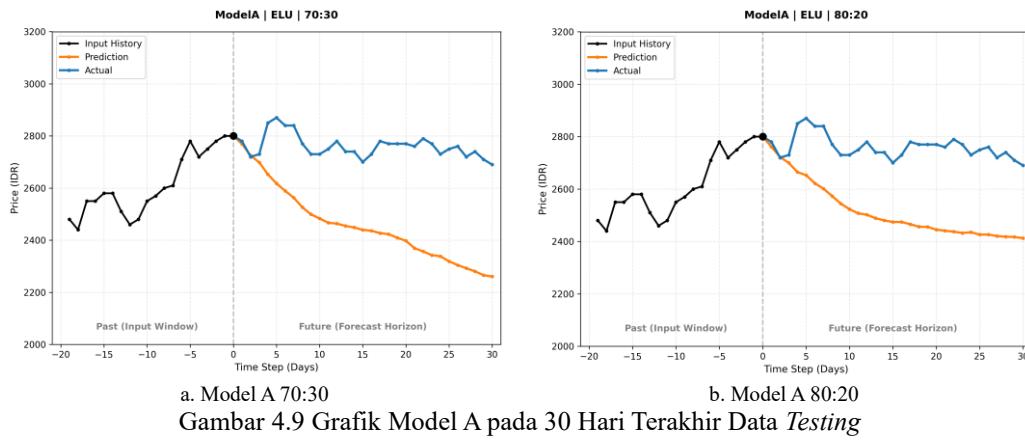
Konsekuensi dari tingginya kompleksitas arsitektur pada Model D mencatatkan durasi pelatihan terlama di antara seluruh skenario eksperimen. Waktu yang dibutuhkan mencapai 9 menit 49 detik untuk rasio 70:30 dan 10 menit 42 detik untuk rasio 80:20.

4.2.3 Fungsi Aktivasi ELU

Tahapan eksperimen selanjutnya difokuskan pada evaluasi kinerja fungsi aktivasi *Exponential Linear Unit* (ELU). Pengujian ini diterapkan secara menyeluruh pada keempat skenario arsitektur (Model A, B, C, dan D) untuk menguji fungsi aktivasi ELU dalam menangkap dinamika tren data historis, baik dari rasio pembagian data, ukuran *window*, dan kompleksitas neuron (*hidden unit*). Adapun hasil analisis performa dan perbandingan tingkat *error* dari masing-masing konfigurasi model diuraikan sebagai berikut.

4.2.3.1 Model A

Model A menggunakan kombinasi parameter dengan *window size* sebanyak 20, jumlah unit IndRNN sebanyak 64, dan jumlah *epoch* sebanyak 1000. Model ini diuji menggunakan dua rasio pembagian data, yaitu 70:30 dan 80:20. Hasil dari pengujian di tunjukkan pada Gambar 4.9.



Secara visual pada Gambar 4.9, meskipun kedua grafik masih memperlihatkan kecenderungan prediksi yang bergerak turun dan tidak berhasil menangkap kenaikan harga yang terjadi di data input (garis hitam), grafik rasio 80:20 memperlihatkan garis prediksi (garis kuning) yang lebih mendekati data aktual (garis biru) dan berusaha mempertahankan posisinya mendekati harga aktual. Sebaliknya, pada grafik rasio 70:30, garis prediksi terlihat mengalami penurunan yang lebih signifikan dan menjauhi data aktual.

Sebagai transparansi data hasil eksperimen, Tabel 4.12 berikut merangkum metrik evaluasi yang meliputi kesalahan numerik, akurasi arah tren, serta durasi komputasi yang dibutuhkan.

Tabel 4.12 Hasil Evaluasi pada Model A (ELU)

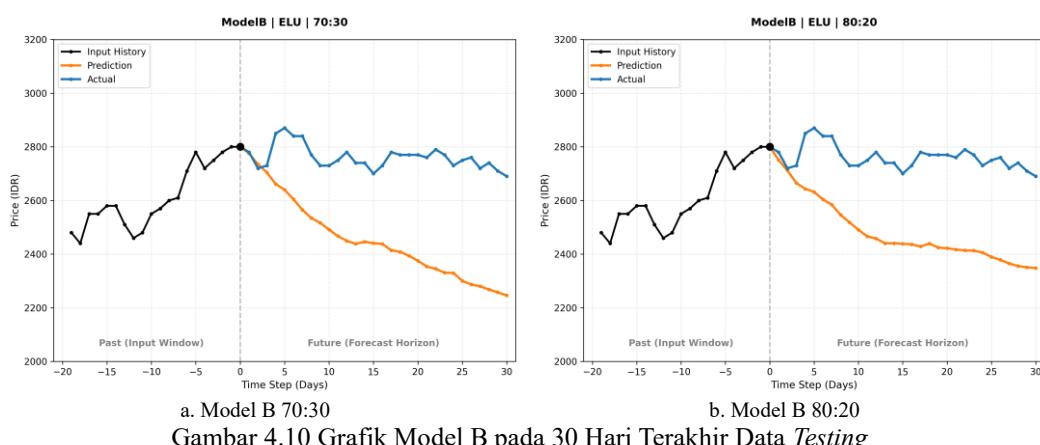
Model A (ELU)	RMSE	MAPE	DA	Time Training
70:30	376.96	11.18%	52.07%	6 menit 38 detik
80:20	351.26	10.37%	52.01%	7 menit 14 detik

Berdasarkan Tabel 4.12, terlihat adanya perbedaan kualitas prediksi yang tidak terlalu jauh yang dipengaruhi oleh rasio pembagian data. Pada rasio 80:20, Model A dengan aktivasi ELU menunjukkan kinerja yang cukup impresif dengan

menekan nilai RMSE ke angka 351.26 dan MAPE 10.37%. Pada rasio 70:30, mengalami penurunan akurasi RMSE sebesar 445.45 dan MAPE 13.43%. Pada aspek *Directional Accuracy* (DA). Rasio 80:20 memiliki nilai DA yang lebih rendah yakni 52.01%, sedangkan pada rasio 70:30 evaluasi DA nya sedikit meningkat menjadi 52.07%. Peningkatan jumlah rasio dan penerapan fungsi eksponensial pada ELU menyebabkan durasi pelatihan yang lebih lama dibandingkan fungsi aktivasi sebelumnya. Pada Model A waktu pelatihan yang dibutuhkan yakni mencapai 6 menit 38 detik untuk rasio 70:30 dan 7 menit 14 detik untuk rasio 80:20.

4.2.3.2 Model B

Model B konfigurasi untuk jumlah unit IndRNN ditingkatkan menjadi 128 neuron, dengan tetap mempertahankan *window size* 20 hari. Pengujian ini difokuskan untuk melihat apakah penambahan jumlah neuron dengan fungsi aktivasi ELU dapat menghasilkan akurasi yang lebih baik atau malah mengalami penurunan. Hasil visualisasi perbandingan antara nilai prediksi dengan nilai aktual harga saham pada Model B berbasis ELU dapat dilihat pada Gambar 4.10.



Hasil yang ditunjukkan pada Gambar 4.10, masih memiliki karakteristik yang sama seperti pada Model A sebelumnya, pada Model B juga masih gagal dalam menangkap pola pada data aktual (garis biru) dan juga masih belum bisa menangkap tren yang terjadi pada data input (garis hitam). Garis prediksi (oranye) pada kedua grafik tersebut cenderung bergerak turun secara perlahan dan gagal menangkap pola fluktuasi dari data harga aktual. Namun, pada rasio 80:20 *gap* antara garis prediksi dan data aktual tidak selebar rasio 70:30. Hal ini mengindikasikan peningkatan jumlah *hidden unit* pada fungsi aktivasi ELU masih belum mampu menangkap pola yang terjadi pada data aktual.

Sebagai transparansi data hasil eksperimen, Tabel 4.13 menyajikan rekapitulasi nilai *error* prediksi, akurasi arah tren, serta durasi waktu pelatihan yang dibutuhkan oleh masing-masing konfigurasi rasio data.

Tabel 4.13 Hasil Evaluasi pada Model B (ELU)

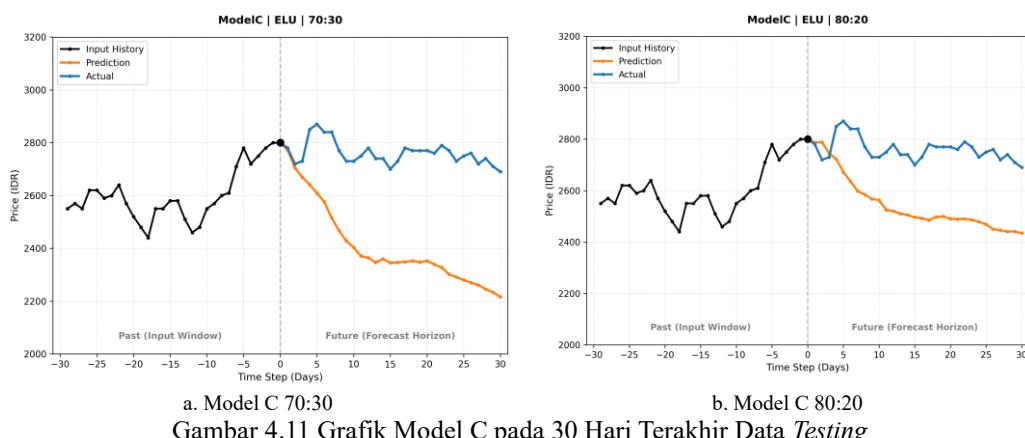
Model B (ELU)	RMSE	MAPE	DA	Time Training
70:30	379.31	11.18%	52.29%	7 menit 15 detik
80:20	398.81	12%	51.43%	7 menit 53 detik

Berdasarkan Tabel 4.13 Model B menghasilkan performa yang relatif setara antar kedua rasio pembagian data, namun dengan tingkat *error* yang cukup tinggi. Pada rasio 70:30, model mencatatkan RMSE sebesar 379.31 dengan MAPE 11.18%. Sementara itu, pada rasio 80:20, performanya sedikit menurun dengan nilai RMSE sebesar 398.81 dan MAPE 12%. Pada aspek *Directional Accuracy* (DA), terdapat sedikit peningkatan. Rasio 70:30 mencatatkan kemampuan prediksi arah tren yang sedikit lebih baik, yakni 52.29%, dibandingkan rasio 80:20 yang berada di angka 51.43%.

Namun, untuk waktu *training* yang dibutuhkan, Model B membutuhkan waktu sebesar 7 menit 15 detik untuk rasio 70:30 dan 7 menit 53 detik untuk rasio 80:20. Peningkatan waktu training yang dibutuhkan ini menegaskan bahwa penggunaan ELU pada penambahan jumlah *hidden unit* menuntut sumber daya waktu yang lebih lama.

4.2.3.3 Model C

Model C merepresentasikan skenario pengujian dengan rentang memori historis yang diperpanjang (*window size* 30 hari) namun dengan jumlah *hidden unit* 64. Hasil perbandingan visual antara nilai prediksi dengan pergerakan harga aktual pada Model C ditunjukkan pada Gambar 4.11.



Pada Gambar 4.11, memperlihatkan kedua rasio masih belum mampu menangkap pola yang diberikan oleh data input (garis hitam) yang mengalami kenaikan, kedua grafik menunjukkan hasil prediksi (garis oranye) yang cenderung menurun. Namun, grafik rasio 80:20 memperlihatkan garis prediksi yang sangat dekat dengan harga aktual. Sementara itu, pada grafik rasio 70:30, garis prediksi

bergerak turun menjauhi data aktual dan kurang menangkap pola pada data aktual. Hal ini mengindikasikan peningkatan jumlah *input* dengan jumlah data *training* yang lebih banyak dapat menghindari kesalahan prediksi yang lebih mminimal.

Selanjutnya, Tabel 4.14 merangkum indikator kinerja utama yang mencakup evaluasi *error* secara numerik, arah pergerakan, serta total durasi waktu yang dibutuhkan untuk proses *training* pada Model C.

Tabel 4.14 Hasil Evaluasi pada Model C (ELU)

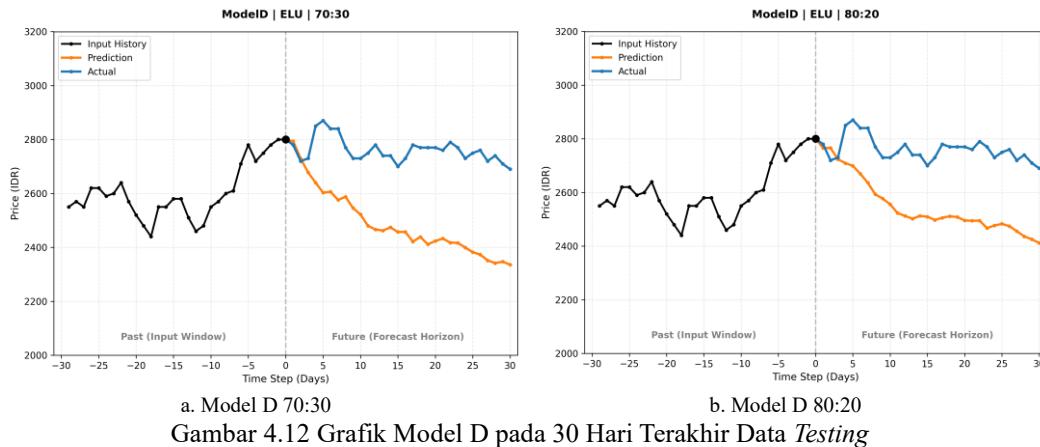
Model C (ELU)	RMSE	MAPE	DA	Time Training
70:30	432.82	13.05%	51.49%	9 menit 31 detik
80:20	356.23	10.37%	51.61%	10 menit 29 detik

Berdasarkan hasil dari Tabel 4.14, terlihat jelas bahwa penerapan ELU pada *window size* 30 hari menuntut sumber daya komputasi yang sangat masif. Model C memerlukan waktu *training* mencapai 9 menit 31 detik untuk rasio 70:30 dan 10 menit 29 detik untuk rasio 80:20. Sedangkan secara evaluasi numerik, Model C dengan rasio 80:20 memperoleh nilai RMSE 356.23 dengan MAPE 10.37%. Kinerja ini lebih unggul dibandingkan rasio 70:30 yang menghasilkan RMSE sebesar 432.82 dan MAPE 13.05%. Namun, pada metrik *Directional Accuracy* (DA) hasil dari kedua rasio tidak jauh berbeda, rasio 70:30 memperoleh 51.49% dan rasio 80:20 memperoleh 51.61%.

4.2.3.4 Model D

Pada Model D, konfigurasinya memiliki jumlah *window* sebesar 30 hari dan jumlah *hidden unit* sebanyak 128 neuron. Eksperimen ini bertujuan untuk menguji apakah fungsi aktivasi ELU dapat memproses data input yang lebih panjang dan

juganya yang lebih kompleks. Gambaran visual mengenai hasil yang diperoleh dari Model D dapat dicermati pada Gambar 4.12.



Grafik yang dihasilkan pada Gambar 4.12 menunjukkan Model D juga masih belum mampu melihat tren yang terjadi pada data input (garis hitam) yang menunjukkan kenaikan. Kedua rasio masih menunjukkan hasil prediksi (garis oranye) yang cenderung menurun dan bergerak menjauhi data aktual (garis biru), meskipun dengan rasio 70:30 nilai prediksi berusaha untuk mengikuti fluktuatifnya data aktual namun garisnya terus menurun yang menyebabkan semakin jauh dengan data aktual. Sedangkan pada rasio 80:20 grafik prediksinya cenderung lebih landai namun masih belum terlalu mengikuti fluktuatifnya data aktual.

Selanjutnya, untuk hasil evaluasi ditunjukkan pada Tabel 4.15 yang menyajikan hasil evaluasi *error* secara numerik, arah pergerakan, serta durasi *training* yang dibutuhkan Model D.

Tabel 4.15 Hasil Evaluasi pada Model D (ELU)

Model D (ELU)	RMSE	MAPE	DA	Time Training
70:30	355.7	10.48%	51.49%	10 menit 34 detik
80:20	346.47	10.03%	51.1%	11 menit 23 detik

Berdasarkan Tabel 4.15, menunjukan bahwasannya pada rasio 80:20, memiliki nilai akurasi numerik yang sedikit lebih baik dibanding dengan rasio 70:30, yakni memperoleh RMSE 346.47 dan MAPE 10.03. Namun pada evaluasi *Directional Accuracy*, rasio 70:30 memperoleh nilai DA sedikit lebih tinggi dibanding rasio 80:20. Dari keseluruhan skenario pada fungsi aktivasi ELU, Model D merupakan skenario dengan nilai akurasi yang paling baik dari pada model-model sebelumnya, hal ini mengindikasikan bahwasannya fungsi aktivasi ELU dapat memproses dengan input yang lebih panjang dan *hidden unit* yang lebih kompleks. Namun, akibat kompleksitas pada Model D menyebabkan beban komputasi yang lebih berat, yang mana durasi pelatihannya mencapai hingga 11 menit 23 detik pada rasio 80:20 dan 10 menit 34 detik pada rasio 70:30.

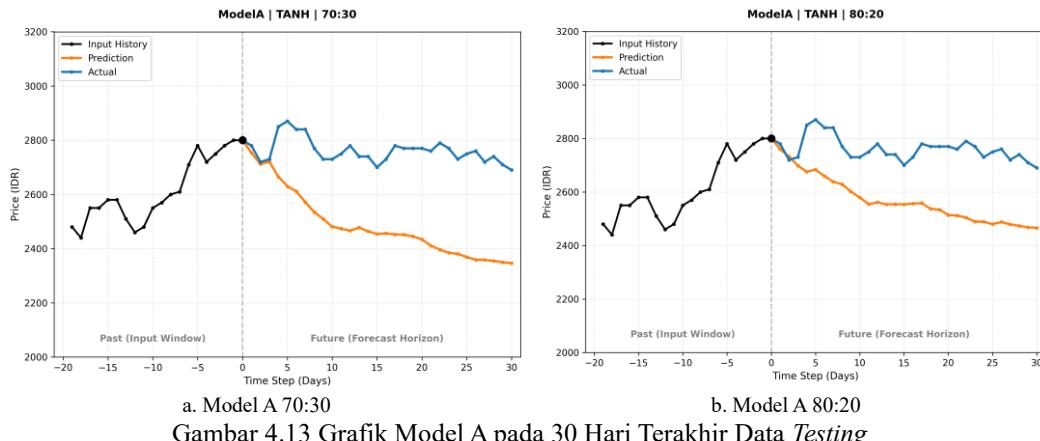
4.2.4 Fungsi Aktivasi Tanh

Rangkaian eksperimen pada parameter fungsi aktivasi selanjutnya yaitu menggunakan *Hyperbolic Tangent* (Tanh). Karakteristik Tanh yang memetakan nilai input ke dalam rentang -1 hingga 1 memberikan perspektif berbeda dibandingkan fungsi sebelum-sebelumnya. Pengujian ini diterapkan secara pada keempat skenario model (Model A, B, C, dan D). Adapun uraian lengkap mengenai kinerja prediksi dan stabilitas model dari setiap konfigurasi dipaparkan sebagai berikut.

4.2.4.1 Model A

Model A memiliki konfigurasi parameter *window size* 20 hari dan jumlah *hidden unit* sebanyak 64 neuron. Gambaran visual mengenai kualitas hasil prediksi

dibandingkan dengan data aktual pada Model A berbasis Tanh dapat dilihat pada Gambar 4.13 berikut.



Gambar 4.13 Grafik Model A pada 30 Hari Terakhir Data *Testing*

Berdasarkan Gambar 4.13 hasil prediksi (garis oranye) juga memperlihatkan bahwasannya pada kedua rasio masih belum mampu mengikuti tren yang terjadi pada data input (garis hitam) yang mengalami peningkatan. Pada rasio 70:30 hasil prediksi mengalami penurunan secara perlahan menjauhi tren harga aktual (garis biru). Sebaliknya, pada grafik rasio 80:20, hasil prediksi cenderung lebih landai dan tidak terlalu jauh dengan data aktual. Namun, dari kedua rasio tersebut masih belum menangkap pola data aktual yang fluktuatif.

Hasil perhitungan nilai evaluasi baik secara numerik, arah pergerakan dan waktu yang diperlukan pada saat proses *training* terhadap model A disajikan pada Tabel 4.16.

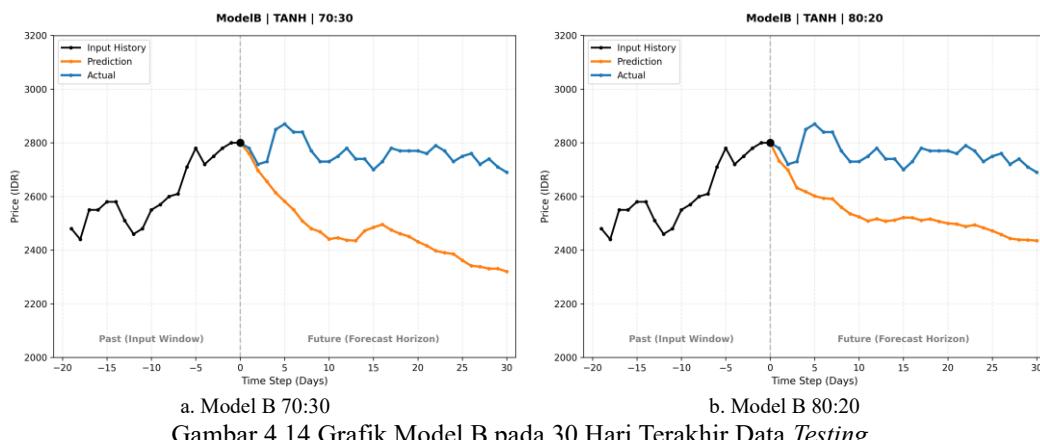
Tabel 4.16 Hasil Evaluasi pada Model A (Tanh)

Model A (Tanh)	RMSE	MAPE	DA	Time Training
70:30	364.62	10.69%	50.99%	4 menit 1 detik
80:20	304.78	8.79%	51.69%	4 menit 22 detik

Berdasarkan Tabel 14.6, rasio 80:20 berhasil mencatatkan nilai RMSE sebesar 304.78 dengan MAPE hanya 8.79%. Capaian ini jauh mengungguli rasio 70:30, yang masih memiliki tingkat kesalahan cukup tinggi dengan RMSE 364.62 dan MAPE 10.69%. Konsistensi positif juga terlihat pada indikator *Directional Accuracy* (DA). Rasio 80:20 mampu memprediksi arah tren dengan akurasi 51.69%, lebih tinggi dibandingkan rasio 70:30 yang sebesar 50.99%. Selain keunggulan akurasi, Tanh juga menawarkan efisiensi komputasi yang sangat baik. Durasi pelatihan yang dibutuhkan tergolong singkat, yakni 4 menit 1 detik untuk rasio 70:30 dan 4 menit 22 detik untuk rasio 80:20.

4.2.4.2 Model B

Pada Model B jumlah *hidden unit* ditingkatkan menjadi 128 neuron, sementara parameter *window size* tetap dipertahankan pada 20 hari. Hasil prediksi dan harga aktual pada Model B divisualisasikan melalui Gambar 4.14.



Secara visual, nilai prediksi (garis oranye) terhadap data aktual (garis biru) dari kedua rasio menunjukkan adanya perbedaan yang cukup signifikan. Pada rasio 70:30, garis prediksi berusaha mengikuti pola fluktuatif data aktual, namun

pergerakannya menurun dan menjauhi data aktual. Sebaliknya, pada grafik rasio 80:20, garis prediksi cenderung menurun secara perlahan dan masih belum menangkap pola fluktuatif harga saham. Meskipun begitu, pada kedua rasio ini juga masih belum mampu menangkap tren yang terjadi pada data input (garis hitam) yang sedang mengalami kenaikan secara perlahan.

Hasil perhitungan nilai evaluasi baik secara numerik, arah pergerakan, dan waktu *training* pada Model B disajikan pada Tabel 4.17.

Tabel 4.17 Hasil Evaluasi pada Model B (Tanh)

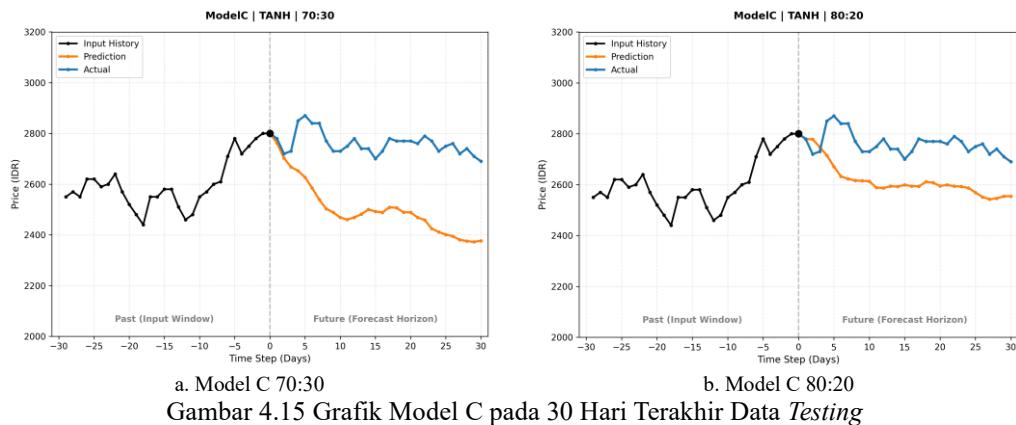
Model B (Tanh)	RMSE	MAPE	DA	Time Training
70:30	372.23	11.09%	51.67%	4 menit 34 detik
80:20	328.85	9.73%	50.72%	5 menit

Berdasarkan tabel 4.17 terlihat bahwa rasio 80:20 berhasil mencatatkan nilai RMSE sebesar 328.85 dengan MAPE 9.73%. Angka ini sedikit lebih baik dibandingkan rasio 70:30 yang mengalami peningkatan dengan RMSE mencapai 372.23 dan MAPE 11.09%. Sedangkan pada evaluasi *Directional Accuracy* (DA) rasio 70:30 justru menunjukkan hasil yang lebih baik dengan memperoleh nilai DA sebesar 51.67%, mengungguli rasio 80:20 yang berada di angka 50.72%. Peningkatan jumlah *hidden unit* mempengaruhi durasi pelatihan, pada Model B waktu pelatihan yang dibutuhkan meningkat menjadi 4 menit 34 detik pada rasio 70:30 dan mencapai 5 menit pada rasio 80:20.

4.2.4.3 Model C

Model C merepresentasikan konfigurasi dengan rentang input historis yang lebih panjang, menggunakan parameter *window size* sebesar 30 hari sedangkan untuk *hidden unit* sejumlah 64. Pada skenario ini, fungsi aktivasi Tanh diuji

kemampuannya dalam mengelola pada dimensi input yang lebih besar. Gambaran visual mengenai perbandingan antara nilai prediksi dengan pergerakan harga aktual pada Model C berbasis Tanh dapat dilihat pada Gambar 4.15.



a. Model C 70:30
b. Model C 80:20

Gambar 4.15 Grafik Model C pada 30 Hari Terakhir Data *Testing*

Grafik yang ditunjukkan pada Gambar 4.15, memberikan perbedaan yang cukup signifikan, pada rasio 80:20 memperlihatkan kemampuan memahami pola yang terjadi pada data input (garis hitam) dimana hasil prediksi (garis oranye) berbeda dengan model-model sebelumnya yang cenderung bergerak menurun, pada Model C rasio 80:20 hasil prediksinya cenderung lebih landai dan mendekati data aktual. Sedangkan pada grafik rasio 70:30, hasil prediksinya cenderung menurun dan menjauhi data aktual. Hal ini mengindikasikan peningkatan jumlah input dan dengan proporsi data *training* yang lebih banyak dapat meminimalisir kesalahan prediksi. Hasil perhitungan nilai evaluasi baik secara numerik, arah pergerakan, dan waktu yang diperlukan pada saat proses training terhadap Model C disajikan pada tabel 4.18.

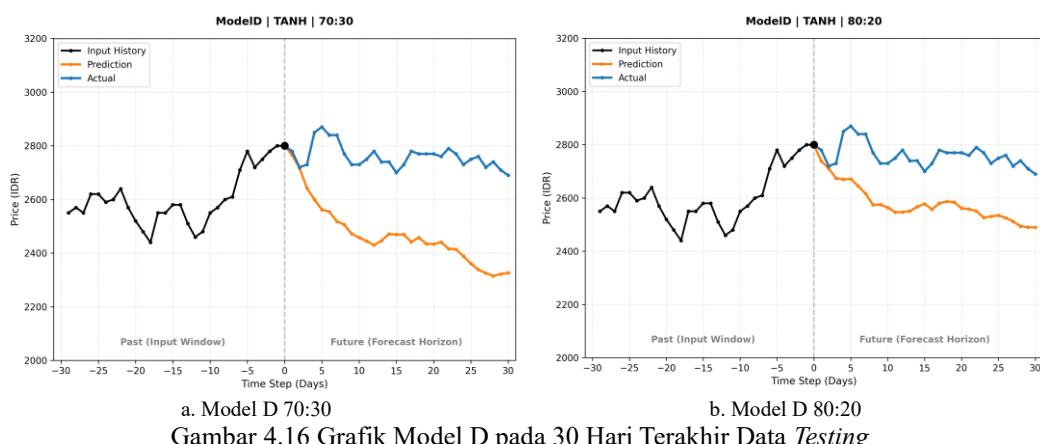
Tabel 4.18 Hasil Evaluasi pada Model C (Tanh)

Model C (Tanh)	RMSE	MAPE	DA	Time Training
70:30	368.72	10.97%	51.48%	5 menit 40 detik
80:20	291.03	8.44%	51.23%	6 menit 13 detik

Berdasarkan Tabel 4.18, rasio 80:20 berhasil menekan tingkat kesalahan dengan mencatatkan RMSE mencapai 291.03 dan MAPE 8.44%. Capaian ini jauh lebih unggul dibandingkan rasio 70:30, yang menghasilkan nilai *error* lebih tinggi dengan RMSE 368.72 dan MAPE 10.97%. Namun, pada hasil *Directional Accuracy* (DA), meskipun rasio 70:30 memiliki *error* numerik yang lebih besar, rasio ini memperoleh nilai DA sedikit lebih tinggi yakni 51.48%, dibandingkan rasio 80:20 yang berada di angka 51.23%. Penambahan jumlah input mempengaruhi durasi pelatihan pada Model C, durasinya mencapai 5 menit 40 detik pada rasio 70:30 dan 6 menit 13 detik pada rasio 80:20.

4.2.4.4 Model D

Pada Model D, konfigurasinya memiliki jumlah *window* sebesar 30 hari dan jumlah *hidden unit* sebanyak 128 neuron. Eksperimen ini bertujuan untuk menguji apakah fungsi aktivasi Tanh dapat memproses data input yang lebih panjang dan juga neuron yang lebih kompleks. Gambaran visual mengenai perbandingan antara nilai prediksi dengan pergerakan harga aktual pada Model D ditunjukkan pada Gambar 4.16.



Kedua grafik pada Gambar 4.16, memperlihatkan bahwasannya pada kedua rasio pembagian data, masih belum mampu mengikuti tren pada data input (garis hitam) yang mengalami kenaikan, namun dari kedua rasio tersebut memperlihatkan garis prediksi (oranye) berusaha untuk mengikuti pola fluktuatif pada data aktual (garis biru). Namun pada rasio 70:30 cenderung bergerak menurun menjauhi data aktual, sedangkan rasio 80:20 lebih stabil dan tidak terlalu menjauhi data aktual. Hal ini mengindikasikan bahwasannya proporsi data *training* yang lebih banyak pada Model D dapat memberikan hasil prediksi yang lebih baik.

Hasil perhitungan nilai evaluasi baik secara numerik, arah pergerakan dan waktu yang diperlukan pada saat proses training terhadap Model D disajikan pada Tabel 4.19.

Tabel 4.19 Hasil Evaluasi pada Model D (Tanh)

Model D (Tanh)	RMSE	MAPE	DA	Time Training
70:30	358.92	10.53%	50.88%	6 menit 27 detik
80:20	322.23	9.43%	51.27%	7 menit 5 detik

Berdasarkan Tabel 4.19, rasio 80:20 mencatatkan kinerja yang lebih baik dengan nilai RMSE sebesar 322.23 dan MAPE 9.43%. Capaian ini lebih unggul dibandingkan rasio 70:30, yang memperoleh nilai RMSE 358.92 dan MAPE 10.53%. Konsistensi yang dihasilkan oleh rasio 80:20 juga di tunjukkan pada evaluasi *Directional Accuracy* (DA) yang memperoleh 51.27% sedikit lebih unggul dibanding rasio 70:30 yang hanya memperoleh nilai DA sebesar 50.88%. Kompleksitas pada Model D juga menyebabkan waktu *training* terlama pada fungsi aktivasi Tanh, pada rasio 70:30 waktu yang dibutuhkan adalah 6 menit 27 detik dan 7 menit 5 detik untuk rasio 80:20.

4.3 Pembahasan

Setelah melalui serangkaian tahapan pengujian terhadap empat variasi arsitektur model (Model A, B, C, dan D) yang dikombinasikan dengan empat jenis fungsi aktivasi (ReLU, PReLU, ELU, dan Tanh), tahap selanjutnya adalah melakukan komparasi menyeluruh untuk menentukan konfigurasi yang paling optimal. Pembahasan pada subbab ini difokuskan pada analisis komparatif terhadap tiga aspek utama kinerja model, yaitu akurasi prediksi berdasarkan evaluasi nilai numerik (*RMSE & MAPE*), kemampuan model dalam membaca arah pergerakan harga (*Directional Accuracy*), serta efisiensi komputasi yang diukur dari durasi pelatihan. Sebagai landasan analisis, rekapitulasi hasil evaluasi dari seluruh skenario eksperimen disajikan secara lengkap pada Tabel 4.20.

Tabel 4.20 Ringkasan Hasil Evaluasi Pada Seluruh Model

Fungsi Aktivasi	Rasio	Model	RMSE	MAPE	DA	Time Training
ReLU	70:30	Model A	452.77	13.55%	51.15%	4m 12s
		Model B	312.85	9.1%	49.74%	4m 42s
		Model C	388.3	11.6%	50.65%	6m 10s
		Model D	338.07	9.64%	49.98%	6m 37s
	80:20	Model A	324.43	9.25%	50.2%	4m 40s
		Model B	317.02	9.39%	51.31%	5m 2s
		Model C	400.95	12.2%	50.1%	6m 40s
		Model D	286.69	8.18%	49%	7m 10s
PReLU	70:30	Model A	388.01	11.24%	51.55%	6m 22s
		Model B	438.39	13.23%	51.13%	6m 51s
		Model C	433.37	12.92%	52.14%	9m 8s
		Model D	428.31	12.67%	51.8%	9m 49s
	80:20	Model A	416.77	12.8%	51.19%	6m 58s
		Model B	426.17	13.21%	49.25%	7m 26s
		Model C	361.24	10.86%	50.74%	10m 3s
		Model D	375.06	11.54%	48.7%	10m 42s
ELU	70:30	Model A	376.96	11.18%	52.07%	6m 38s
		Model B	379.31	11.18%	52.29%	7m 15s
		Model C	432.82	13.05%	51.49%	9m 31s
		Model D	355.7	10.48%	51.49%	10m 34s

Fungsi Aktivasi	Rasio	Model	RMSE	MAPE	DA	Time Training
ELU	80:20	Model A	351.26	10.37%	52.01%	7m 14s
		Model B	398.81	12%	51.43%	7m 53s
		Model C	356.23	10.37%	51.61%	10m 29s
		Model D	346.47	10.03%	51.1%	11m 23s
Tanh	70:30	Model A	364.62	10.69%	50.99%	4m 1s
		Model B	372.23	11.09%	51.67%	4m 34s
		Model C	368.72	10.97%	51.48%	5m 40s
		Model D	358.92	10.53%	50.88%	6m 27s
	80:20	Model A	304.78	8.79%	51.69%	4m 22s
		Model B	328.85	9.73%	50.72%	5m
		Model C	291.03	8.44%	51.23%	6m 13s
		Model D	322.23	9.43%	51.27%	7m 5s

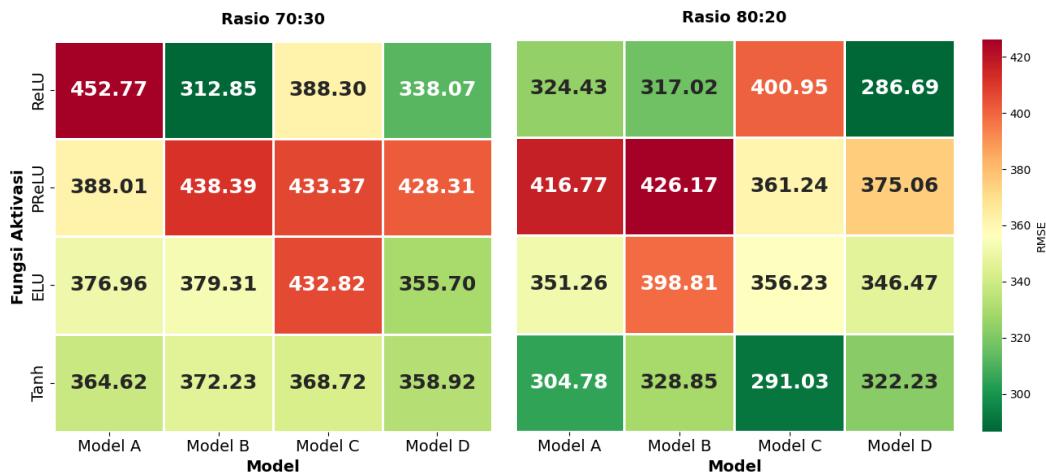
Berdasarkan rekapitulasi data pada Tabel 4.20, hasilnya menunjukkan pola performa yang bervariasi. Fungsi aktivasi ReLU secara konsisten mengungguli fungsi aktivasi lainnya dalam hal efisiensi waktu dan akurasi nilai prediksi. Dominasi ini terlihat jelas pada skenario Model D (Rasio 80:20), di mana ReLU mencatatkan nilai *error* terendah di antara seluruh eksperimen dengan MAPE sebesar 8.18% dan RMSE 286.69, didukung oleh durasi pelatihan yang relatif singkat di kisaran 7 menit. Performa yang sangat kompetitif juga ditunjukkan oleh fungsi aktivasi Tanh, yang mampu mendekati capaian tersebut dengan MAPE terendah 8.44% pada Model C (80:20).

Sebaliknya, penggunaan fungsi aktivasi yang lebih kompleks seperti PReLU dan ELU menunjukkan adanya *trade-off* yang signifikan antara biaya komputasi dan karakteristik prediksi. Kedua fungsi ini mencatatkan inefisiensi waktu yang mencolok, terlihat paling ekstrem pada Model D dengan aktivasi ELU (80:20) yang memakan waktu pelatihan hingga 11 menit 23 detik serta menghasilkan rata-rata *error* numerik yang lebih tinggi (MAPE di atas 10%).

Namun, di balik inefisiensi tersebut, ELU justru menunjukkan keunggulan unik dalam sensitivitas membaca tren, di mana ELU berhasil mencatatkan nilai *Directional Accuracy* (DA) tertinggi dari seluruh skenario eksperimen, yakni sebesar 52.29% pada Model B (70:30). Hal ini mengindikasikan bahwa meskipun lambat dan kurang presisi dalam menebak harga secara *numeric*, fitur *negative saturation* pada ELU sedikit lebih baik dalam menangkap sinyal arah pergerakan. Namun, secara umum kemampuan seluruh model dalam memprediksi arah pergerakan harga masih cenderung terbatas, dengan nilai DA yang sebagian besar stagnan pada rentang 49%–52%. Analisis selanjutnya akan dibagi secara spesifik berdasarkan masing-masing metrik evaluasi.

4.3.1 Evaluasi RMSE

Evaluasi kinerja prediksi berbasis *Root Mean Square Error* (RMSE) yang divisualisasikan melalui *heatmap* pada Gambar 4.17 memperlihatkan pola distribusi tingkat kesalahan yang cukup dinamis antar skenario pengujian. Secara visual, panel rasio pembagian data 80:20 menunjukkan dominasi warna hijau yang lebih luas dibandingkan panel rasio 70:30, yang mengindikasikan bahwa penambahan proporsi data latih secara umum efektif dalam menurunkan deviasi kesalahan prediksi. Namun, efektivitas ini sangat bergantung pada jenis fungsi aktivasi yang digunakan, di mana tidak semua model merespons penambahan data dengan tingkat perbaikan yang sama.



Gambar 4.17 *Heatmap* RMSE dari seluruh model

Berdasarkan visualisasi *heatmap* pada Gambar 4.17, hasil pengujian model IndRNN menunjukkan bahwa proporsi data latih memiliki dampak yang signifikan terhadap akurasi prediksi 30 hari kedepan. Secara umum, skenario pembagian data rasio 80:20 menghasilkan nilai RMSE yang lebih rendah secara konsisten dibandingkan rasio 70:30. Hal ini mengindikasikan bahwa untuk memprediksi 30 hari ke depan, model membutuhkan volume data latih yang lebih besar agar mampu menangkap pola temporal yang kompleks. Ketidakstabilan pada rasio 70:30 terlihat jelas pada peningkatan *error* yang cukup signifikan, khususnya pada Model A dengan fungsi aktivasi ReLU yang mencatatkan RMSE tertinggi hingga 452.77.

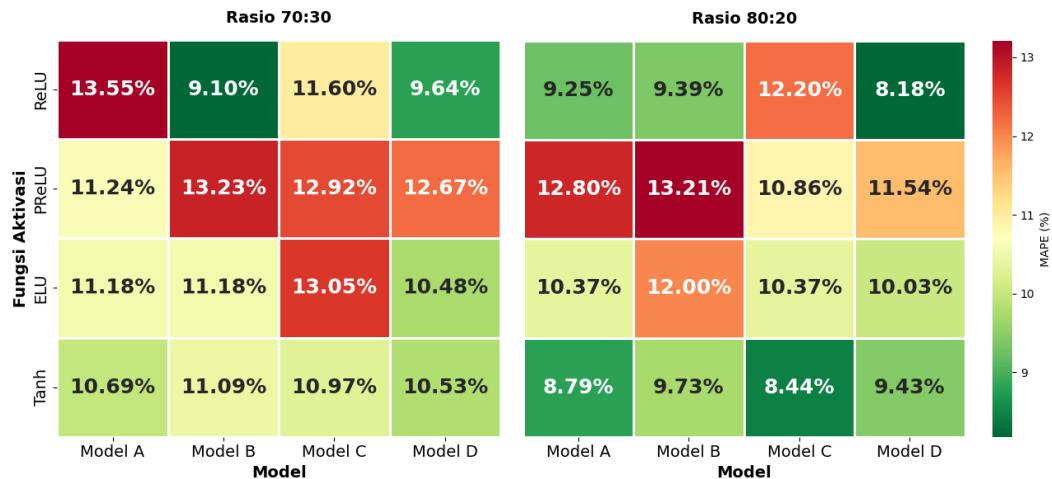
Konfigurasi arsitektur model memperlihatkan peran yang penting dalam hasil RMSE. Model D (*window size* 30, *hidden unit* 128) dengan fungsi aktivasi ReLU pada rasio 80:20 tercatat sebagai konfigurasi terbaik dengan capaian RMSE terendah sebesar 286.69. Keunggulan ini didorong oleh penggunaan *window size* 30 yang setara dengan durasi prediksi (30 hari), sehingga memberikan konteks historis yang memadai bagi model untuk memproyeksikan tren masa depan.

Sebaliknya, Model A dan Model B yang menggunakan *window size* 20 cenderung menghasilkan tingkat *error* yang lebih tinggi. Keterbatasan informasi historis (20 hari) untuk memprediksi rentang waktu yang lebih panjang (30 hari) menyebabkan model kesulitan melakukan generalisasi dengan akurat.

Selanjutnya, evaluasi terhadap fungsi aktivasi menunjukkan karakteristik stabilitas yang berbeda. Fungsi aktivasi Tanh terbukti memiliki performa yang paling stabil (*robust*) di seluruh variasi model dan pembagian data. Bahkan pada arsitektur dengan kapasitas unit yang lebih rendah, seperti Model C (*window size* 30, *hidden unit* 64), penggunaan Tanh mampu menghasilkan RMSE sebesar 291.03, yang sangat kompetitif mendekati performa terbaik Model D ReLU.

4.3.2 Evaluasi MAPE

Selain meninjau nilai rata-rata selisih kesalahan, evaluasi juga dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE) untuk melihat seberapa besar penyimpangan prediksi dalam satuan persentase. Distribusi nilai MAPE dari seluruh skenario pengujian ditunjukkan dalam visualisasi *heatmap* pada Gambar 4.18. Gradasi warna hijau merepresentasikan persentase *error* yang rendah (akurasi tinggi), sedangkan warna merah menunjukkan persentase *error* yang tinggi.



Gambar 4.18 *Heatmap* MAPE dari seluruh model

Berdasarkan visualisasi *heatmap* pada Gambar 4.18, evaluasi kinerja model menggunakan metrik MAPE mempertegas temuan bahwa proporsi data latih mempengaruhi dalam akurasi prediksi rentang waktu 30 hari. Gambar 4.18 menunjukkan pola yang konsisten di mana skenario pembagian data rasio 80:20 mendominasi performa dengan nilai *error* yang lebih rendah (area hijau) dibandingkan rasio 70:30.

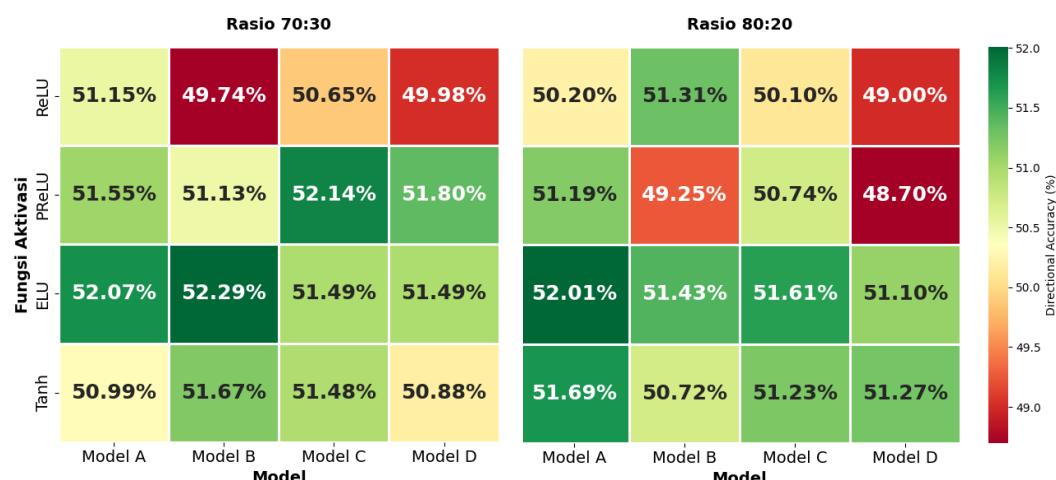
Dari sisi spesifikasi model, konfigurasi arsitektur Model D (*window size* 30, *hidden unit* 128) yang dikombinasikan dengan fungsi aktivasi ReLU pada rasio 80:20 kembali teridentifikasi sebagai varian terbaik dengan capaian MAPE terendah sebesar 8.18%. Keunggulan ini berkorelasi kuat dengan penggunaan *window size* 30 yang selaras dengan durasi prediksi (30 hari). Ketersediaan *sequence* input sepanjang 30 hari memberikan informasi yang cukup bagi model untuk memetakan pola ke masa depan. Sebaliknya, keterbatasan *window size* 20 pada Model A menyebabkan ketidakstabilan yang signifikan, terlihat pada tingginya nilai MAPE yang mencapai 13.55% saat menggunakan aktivasi ReLU

pada rasio 70:30, akibat ketidakmampuan model menangkap dependensi jangka panjang dengan input yang terbatas.

Selain itu, analisis terhadap fungsi aktivasi menunjukkan bahwa Tanh menawarkan stabilitas performa (*robustness*) yang paling konsisten di berbagai kondisi arsitektur. Hal ini terlihat pada Model C (*window size* 30, *hidden unit* 64) dengan aktivasi Tanh yang mampu menjaga nilai MAPE di angka 8.44% pada rasio 80:20, selisih yang sangat tipis dengan performa terbaik Model D.

4.3.3 Evaluasi *Directional Accuracy*

Evaluasi selanjutnya berfokus pada *Directional Accuracy* (DA) untuk mengukur kemampuan model dalam memprediksi apakah harga saham akan naik atau turun pada hari berikutnya. Distribusi akurasi arah ini dipetakan dalam visualisasi *heatmap* pada Gambar 4.19. Pada visualisasi ini, gradasi warna hijau merepresentasikan akurasi yang lebih tinggi, sedangkan warna merah merepresentasikan akurasi yang lebih rendah.



Gambar 4.19 *Heatmap Directional Accuracy* dari seluruh model.

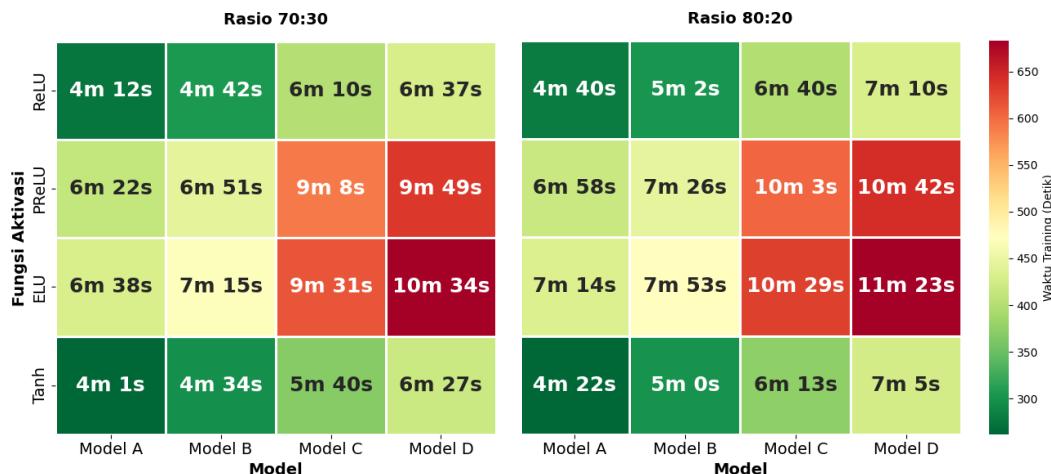
Berbeda dengan metrik evaluasi numerik sebelumnya, visualisasi *heatmap* pada Gambar 4.19 mengukur kinerja model menggunakan metrik *Directional Accuracy* (DA), di mana nilai yang lebih tinggi (warna hijau) merepresentasikan kemampuan model yang lebih baik dalam memprediksi arah pergerakan tren data. Hasil pengujian menunjukkan fenomena menarik di mana dominasi rasio pembagian data tidak seperti pada metrik RMSE atau MAPE. Meskipun rasio 80:20 secara umum menampilkan distribusi warna hijau yang stabil, nilai DA tertinggi justru tercatat pada skenario rasio 70:30. Hal ini mengindikasikan bahwa untuk memprediksi arah tren, penambahan data latih tidak selalu menjamin peningkatan akurasi arah secara linear, melainkan sangat bergantung pada sensitivitas fungsi aktivasi terhadap perubahan pola jangka pendek.

Analisis mendalam terhadap fungsi aktivasi menempatkan ELU (*Exponential Linear Unit*) sebagai komponen paling baik dalam memprediksi arah tren. Fungsi ELU secara konsisten mendominasi area hijau di hampir seluruh variasi model, dengan performa tertinggi dicapai oleh Model B (*window size* 20, *hidden unit* 128) pada rasio 70:30 yang mencatatkan akurasi arah tertinggi sebesar 52.29%. Di sisi lain, fungsi Tanh kembali menunjukkan kestabilan diberbagai konfigurasi, Tanh menjaga akurasi DA di kisaran 50-51%.

4.3.4 Evaluasi *Time Training*

Evaluasi terakhir berfokus pada durasi waktu pelatihan (*time training*). Pengujian ini dilakukan untuk melihat seberapa efisien komputasi yang dibutuhkan oleh setiap model. Distribusi durasi waktu tersebut dipetakan ke dalam visualisasi

heatmap pada Gambar 4.20. Warna hijau menunjukkan waktu yang lebih singkat, sedangkan warna merah menunjukkan waktu yang lebih lama.



Gambar 4.20 *Heatmap Time Training* dari seluruh model.

Secara umum pada Gambar 4.20, terlihat adanya korelasi linear antara volume data latih dan durasi pelatihan, skenario rasio 80:20 membutuhkan waktu *training* yang lebih lama dibandingkan rasio 70:30 di seluruh variasi model. Hal ini juga ditunjukkan oleh kompleksitas model berbanding lurus dengan durasi pelatihan. Model A (*window size* 20, *hidden unit* 64) tercatat sebagai arsitektur yang paling efisien secara waktu, sementara Model D (*window size* 30, *hidden unit* 128) membutuhkan waktu yang paling lama. Peningkatan durasi pada Model D disebabkan oleh kombinasi jumlah unit IndRNN yang lebih besar dan *window size* yang lebih panjang, yang secara signifikan meningkatkan jumlah parameter yang harus diperbarui serta kompleksitas operasi perkalian matriks selama proses *backpropagation*.

Faktor paling signifikan yang membedakan durasi pelatihan terlihat pada pemilihan fungsi aktivasi. Fungsi Tanh dan ReLU terbukti sangat efisien, ditandai

dengan dominasi warna hijau tua. Model A dengan aktivasi Tanh pada rasio 70:30 mencatatkan waktu pelatihan tercepat, yaitu 4 menit 1 detik. Efisiensi ReLU dan Tanh menunjukkan kesederhanaan operasi matematisnya yang teroptimasi dengan baik pada level *hardware*. Sebaliknya, fungsi ELU dan PReLU menunjukkan peningkatan komputasi yang signifikan (warna merah), dengan durasi terlama mencapai 11 menit 23 detik pada Model D dengan ELU (rasio 80:20). Lambatnya proses pada ELU dapat dikaitkan dengan operasi eksponensial yang lebih berat secara komputasi, sedangkan PReLU memerlukan pembaruan parameter tambahan (α) pada setiap neuron, yang membutuhkan komputasi tambahan.

4.3.5 Model Terbaik

Berdasarkan hasil pengujian yang ditampilkan pada Tabel 4.20, pemilihan model terbaik dilakukan melalui tiga sudut pandang, yaitu berdasarkan tingkat kesalahan numerik (RMSE dan MAPE), akurasi arah pergerakan harga saham (*Directional Accuracy/DA*), serta efisiensi durasi pelatihan (*time training*).

Berdasarkan evaluasi numerik, konfigurasi model yang paling baik adalah Model D (*window size* 30, *hidden unit* 128) dengan fungsi aktivasi ReLU pada rasio 80:20. Kombinasi ini berhasil mencatatkan nilai *error* terendah secara keseluruhan, dengan RMSE sebesar 286.69 dan MAPE sebesar 8.18%. Sebaliknya, pada evaluasi *Directional Accuracy*, performa terbaik justru dihasilkan oleh skenario yang berbeda. Model B (*window* 20, *hidden unit* 128) dengan fungsi aktivasi ELU pada rasio 70:30 tercatat sebagai model dengan kemampuan paling baik dalam memprediksi arah tren yakni memperoleh skor DA sebesar 52.29%. Hal ini mengindikasikan adanya perbedaan antara evaluasi numerik dan akurasi arah, di

mana *window size* yang lebih pendek (20) pada Model B tampaknya lebih responsif terhadap fluktuasi jangka pendek yang menentukan perubahan momentum arah.

Selanjutnya, dari segi efisiensi waktu, Model A (*window size* 20, *hidden unit* 64) dengan fungsi aktivasi Tanh pada rasio 70:30 merupakan konfigurasi yang paling efisien secara komputasional, dengan durasi pelatihan tercepat selama 4 menit 1 detik. Efisiensi ini berbanding terbalik dengan Model D (ELU, 80:20) yang membutuhkan waktu hingga 11 menit 23 detik. Penggunaan fungsi aktivasi standar seperti Tanh pada arsitektur yang lebih sederhana (Model A) mampu memangkas beban komputasi secara signifikan. Namun, jika mempertimbangkan keseimbangan antara performa *error* dan waktu, Model C dengan Tanh (ratio 80:20) dapat menjadi alternatif yang moderat dengan durasi 6 menit 13 detik namun tetap menghasilkan *error* yang kompetitif (MAPE 8.44%).

4.4 Integrasi Islam

Setelah diperoleh model terbaik yang mampu memberikan hasil prediksi paling optimal, penelitian ini tidak hanya dilihat dari sisi teknis dan matematis semata. Pelaksanaan penelitian ini berlandaskan pada nilai-nilai Islam yang bersumber dari Al-Qur'an, sehingga diharapkan penelitian ini dapat memberikan pemahaman tentang pentingnya penerapan etika berinvestasi sesuai dengan prinsip syariah, serta menumbuhkan kesadaran akan tanggung jawab manusia dalam mengelola harta secara halal sebagai bentuk amanah yang diberikan oleh Allah *Subhanahu wa Ta'ala.*

4.4.1 *Muamalah Mu'allah*

Sebagai wujud penerapan nilai *muamalah mu'allah*, manusia diarahkan untuk senantiasa bertakwa kepada Allah *Subhanahu wa Ta'ala*, disertai dengan kesadaran untuk mengevaluasi setiap perbuatan serta merencanakan langkah yang bijaksana bagi masa depan. Salah satu ayat yang mencerminkan hal ini adalah firman Allah dalam Q.S. Al-Hasyr ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا إِذْ قَدَّمْتُمْ لِعَدًّا وَأَتَقْتُلُوا اللَّهَ لَنَّ اللَّهَ خَيْرٌ بِمَا تَعْمَلُونَ ﴿١٨﴾

“Wahai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat). Bertakwalah kepada Allah. Sesungguhnya Allah Mahateliti terhadap apa yang kamu kerjakan.” (Q.S. Al-Hasyr: 18)

Ayat ini mengandung prinsip dasar *muhasabah* (introspeksi diri) dan perencanaan masa depan. Dalam Tafsir Ibnu Katsir, dijelaskan bahwa perintah “hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok” dimaknai sebagai seruan untuk menghisab diri sendiri sebelum dihisab oleh Allah. Manusia diminta untuk melihat kembali amal shalih apa saja yang telah ia tabung sebagai bekal saat bertemu dengan Tuhannya kelak. Selain itu, penekanan pada ketakwaan dalam ayat ini merupakan pengingat bahwa Allah Maha Mengetahui segala perbuatan manusia, baik perkara besar maupun kecil, sehingga tidak ada satu pun yang tersembunyi dari-Nya.

Nilai *muhasabah* ini semakin kuat bila dikaitkan dengan sabda Rasulullah *Shallallahu 'Alaihi Wasallam*:

كُلُّكُمْ رَاعٍ وَكُلُّكُمْ مَسْئُولٌ عَنْ رَعِيَّتِهِ

“Setiap orang dari kalian adalah pemimpin, dan setiap kalian akan dimintai pertanggungjawaban terhadap yang dipimpinnya” (HR. Bukhari no. 4801 dan Muslim no. 3408)

Hadis tersebut menegaskan bahwa setiap individu memegang tanggung jawab atas apa yang dilakukan. Pesan ini mengingatkan bahwa *muhasabah* bukan sekadar menilai diri, tetapi juga menyadari bahwa setiap amal kelak akan dipertanggungjawabkan di hadapan Allah *Subhanahu wa Ta'ala*. Dalam konteks penelitian, nilai ini tercermin pada upaya peneliti menyajikan proses dan hasil secara transparan, sehingga apa yang dilakukan dapat dinilai dengan jelas dan memberikan manfaat bagi pembaca.

4.4.2 *Muamalah Ma'annas*

Sebagai bentuk pengamalan dari *muamalah ma'annas*, manusia diajarkan untuk senantiasa menumbuhkan sikap tolong-menolong dan berupaya menghadirkan kemaslahatan bagi sesamanya. Melalui penelitian ini, nilai tersebut diwujudkan dalam bentuk kontribusi ilmiah yang bertujuan membantu pelaku ekonomi, investor, dan lembaga keuangan dalam mengambil keputusan yang tepat dan efisien. Upaya ini menjadi wujud nyata dari penerapan ilmu pengetahuan untuk kemaslahatan umat, sekaligus perwujudan nilai tolong-menolong dalam kebaikan.

Semangat untuk berbuat baik ini selaras dengan firman Allah *Subhanahu wa Ta'ala*. dalam Q.S. Al-Baqarah ayat 195 yang berbunyi:

وَأَنْفَقُوا فِي سَبِيلِ اللَّهِ وَلَا تُلْقُوا بِأَيْدِيكُمْ إِلَى التَّهْلُكَهِ وَأَخْسِنُوا إِنَّ اللَّهَ يُحِبُّ الْمُحْسِنِينَ (١٩٥)

“Berinfaklah di jalan Allah, janganlah jerumuskan dirimu ke dalam kebinasaan, dan berbuatbaiklah. Sesungguhnya Allah menyukai orang-orang yang berbuat baik.” (Q.S. Al-Baqarah: 195)

Sebagaimana dijelaskan dalam Tafsir Ibnu Katsir, perintah berbuat baik dalam ayat ini merupakan amal ketaatan yang paling tinggi. Dalam konteks muamalah, ketaatan ini tidak hanya terbatas pada harta, tetapi juga pada segala bentuk kontribusi yang mencegah kebinasaan umat (Katsir, 2001). Salah satu bentuk perbuatannya adalah menyebarkan ilmu yang bermanfaat, sebagaimana sabda Rasulullah *Shallallahu 'Alaihi Wasallam*:

إِذَا مَاتَ الْإِنْسَانُ انْقَطَعَ عَنْهُ عَمَلُهُ إِلَّا مِنْ ثَلَاثَةِ إِلَّا مِنْ صَدَقَةٍ جَارِيَةٍ أَوْ عِلْمٍ يُنْتَفَعُ بِهِ أَوْ وَلَدٍ صَالِحٍ يَدْعُو لَهُ

“Apabila salah seorang manusia meninggal dunia, maka terputuslah segala amalannya kecuali tiga perkara: sedekah jariyah, ilmu yang bermanfaat baginya dan anak shalih yang selalu mendoakannya.” (HR. Muslim no. 3084)

Berdasarkan hal tersebut, penelitian ini diharapkan menjadi bagian dari amal ilmu yang bermanfaat, sekaligus implementasi nilai *ihsān* dan prinsip tolongan menolong melalui kontribusi ilmiah yang dapat digunakan oleh berbagai pihak.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini bertujuan untuk membangun model prediksi harga saham PT Bank Syariah Indonesia Tbk (BRIS) menggunakan metode *Independent Recurrent Neural Network* (IndRNN) serta memperoleh konfigurasi model terbaik berdasarkan metrik evaluasi RMSE, MAPE, *Directional Accuracy* (DA), dan efisiensi waktu pelatihan. Pengujian dilakukan secara komprehensif untuk menemukan kombinasi parameter paling optimal melalui 32 skenario percobaan yang memvariasikan *window size* (20 dan 30 hari), jumlah *hidden unit* (64 dan 128 neuron), fungsi aktivasi (ReLU, PReLU, ELU, dan Tanh), serta rasio pembagian data (70:30 dan 80:20).

Berdasarkan serangkaian pengujian yang telah dilakukan, konfigurasi model yang paling optimal dalam meminimalisir kesalahan prediksi secara numerik diperoleh pada Model D dengan fungsi aktivasi ReLU dan rasio pembagian data 80:20. Model ini menghasilkan nilai *error* terendah dengan RMSE sebesar 286.69 dan MAPE sebesar 8.18%. Hasil ini menunjukkan bahwa kombinasi *window size* 30 dan *hidden unit* 128 mampu memberikan representasi harga yang paling presisi untuk prediksi jangka panjang (30 hari), karena didukung oleh kapasitas memori historis yang cukup dan kompleksitas unit yang memadai.

Sementara itu, dari sisi kemampuan mengenali tren naik atau turunnya harga, Model B dengan fungsi aktivasi ELU pada rasio 70:30 mencatatkan kinerja terbaik dengan nilai DA sebesar 52.29%. Hal ini mengindikasikan bahwa untuk

mendeteksi perubahan arah tren, arsitektur dengan *window size* yang lebih pendek (20 hari) namun responsif berkat fungsi aktivasi ELU, lebih efektif dibandingkan model yang lebih kompleks.

Sementara dari efisiensi komputasi, fungsi aktivasi Tanh dan ReLU terbukti menjadi pilihan yang paling efisien secara waktu. Model A dengan fungsi aktivasi Tanh pada rasio 70:30 mampu menyelesaikan pelatihan dalam waktu tercepat, yaitu 4 menit 1 detik. Sebaliknya, penggunaan fungsi aktivasi ELU dan PReLU cenderung membebani komputasi, dengan waktu pelatihan terlama mencapai lebih dari 11 menit pada arsitektur yang kompleks.

5.2 Saran

Berdasarkan kesimpulan yang telah dijabarkan sebelumnya, penulis menyadari bahwa penelitian ini masih memiliki beberapa keterbatasan yang dapat dikembangkan lebih lanjut. Untuk mengoptimalkan hasil dan meningkatkan performa model pada penelitian berikutnya, beberapa saran yang dapat dipertimbangkan adalah sebagai berikut:

1. Menambahkan variabel eksternal non-teknikal, seperti sentimen pasar dari berita keuangan, agar model memperoleh konteks informasi yang lebih komprehensif di luar data harga historis.
2. Mengombinasikan IndRNN dengan algoritma klasifikasi seperti *Support Vector Machine* (SVM) atau *Random Forest* untuk meningkatkan akurasi prediksi arah pergerakan harga saham.

DAFTAR PUSTAKA

- Alsharef, A., Bhuyan, P., & Ray, A. (2020). Predicting Stock Market Prices using Fine-Tuned IndRNN. *International Journal of Innovative Technology and Exploring Engineering*, 9(7), 309–315. <https://doi.org/10.35940/ijitee.G5237.059720>
- Alsharef, A., Sonia, Arora, M., & Aggarwal, K. (2022). Predicting Time-Series Data Using Linear and Deep Learning Models—An Experimental Study. *Lecture Notes in Electrical Engineering*, 907, 505–516. https://doi.org/10.1007/978-981-19-4687-5_39
- Apicella, A., Isgrò, F., & Prevete, R. (2025). Don't Push the Button! Exploring Data Leakage Risks in Machine Learning and Transfer Learning. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-025-11326-3>
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2023). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(3), 164–172. <https://doi.org/10.25077/teknosi.v8i3.2022.164-172>
- Chang, V., Xu, Q. A., Chidozie, A., & Wang, H. (2024). Predicting Economic Trends and Stock Market Prices with Deep Learning and Advanced Machine Learning Techniques. *Electronics (Switzerland)*, 13(17). <https://doi.org/10.3390/electronics13173396>
- Clevert, D.-A., Unterthiner, T., & Hochreiter, S. (2016). *Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)*. <http://arxiv.org/abs/1511.07289>
- Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark. *Neurocomputing*, 503. <https://doi.org/https://doi.org/10.1016/j.neucom.2022.06.111>
- Hani, J., & Fadliyati, N. (2020). Menabung Dalam Al-Qur'an: Tafsir Analisis Terhadap Qs. Yusuf Ayat 47-49. *At-Tibyan Journal of Qur'an and Hadis Studies*, 3, 49. <https://doi.org/https://doi.org/10.30631/a8xj6804>
- Hartati, N. (2021). Investasi Saham Syariah di Bursa Efek Indonesia dalam Perspektif Hukum Ekonomi Syariah. *Jurnal Hukum Ekonomi Syariah*, 05. <https://doi.org/https://doi.org/10.26618/j-hes.v5i01.4819>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *International Conference on Computer Vision*, 1026–1034. <https://doi.org/https://doi.org/10.48550/arXiv.1502.01852>

- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Hong, Z., Fan, Z., Tong, X., Zhou, R., Pan, H., Zhang, Y., Han, Y., Wang, J., Yang, S., Wu, H., & Li, J. (2021). Prediction Of Covid-19 Epidemic Situation Via Fine-Tuned Indrnn. *PeerJ Computer Science*, 7, 1–30. <https://doi.org/10.7717/peerj-cs.770>
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. In *Applied System Innovation* (Vol. 4, Issue 1, pp. 1–30). MDPI AG. <https://doi.org/10.3390/ASI4010009>
- Katsir, I. (2003). *Tafsir Ibnu Katsir Jilid 4* (M. A. Ghoffar E.M, Trans.). Pustaka Imam asy-Syafi'i.
- Li, S., Li, W., Cook, C., Zhu, C., & Gao, Y. (2018). *Independently Recurrent Neural Network (IndRNN): Building A Longer and Deeper RNN*. <http://arxiv.org/abs/1803.04831>
- Lima, F. T., & Souza, V. M. A. (2023). A Large Comparison of Normalization Methods on Time Series. *Big Data Research*, 34. <https://doi.org/10.1016/j.bdr.2023.100407>
- Mercioni, M. A., & Holban, S. (2023). A Brief Review of the Most Recent Activation Functions for Neural Networks. *2023 17th International Conference on Engineering of Modern Electric Systems (EMES)*. <https://doi.org/10.48550/arXiv.1804.02763>
- Midesia, S. (2020). DAMPAK COVID-19 PADA PASAR SAHAM SYARIAH DI INDONESIA. *Jurnal Penelitian Ekonomi Akuntansi (JENSI)*, 4(1), 68–79. <https://doi.org/https://doi.org/10.33059/jensi.v4i1.2663>
- Mushliha, M. (2024). Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia. *Jambura Journal of Mathematics*, 6(2), 195–203. <https://doi.org/10.37905/jjom.v6i2.26509>
- Nair, V., & Hinton, G. E. (2010). *Rectified Linear Units Improve Restricted Boltzmann Machines*. <https://doi.org/https://dl.acm.org/doi/10.5555/3104322.3104425>
- Norwawi, N. M. (2021). Sliding window time series forecasting with multilayer perceptron and multiregression of COVID-19 outbreak in Malaysia. *Data Science for COVID-19 Volume 1: Computational Perspectives*, 547–564. <https://doi.org/10.1016/B978-0-12-824536-1.00025-3>
- Nwankpa, C. E., Marshall, S., Ijomah, W. I., & Gachagan, A. (2020). Activation Functions: Comparison of Trends in Practice and Research for Deep Learning.

- 2nd International Conference on Computational Sciences and Technologies (INCCST 20), 125–133. <https://doi.org/10.48550/arXiv.1811.03378>
- IDX. (2025). *Produk Syariah*. Retrieved September 9, 2025, from Produk Syariah - Bursa Efek Indonesia: <https://www.idx.co.id/id/idx-syariah/produk-syariah/>
- KSEI. (2025, 10). *Data Statistik KSEI*. Retrieved 10 2025, from PT. Kustodian Sentral Efek Indonesia: https://web.ksei.co.id/publications/Data_Statistik_KSEI
- Oak, O., Nazre, R., Budke, R., & Mahatekar, Y. (2024). A Novel Multivariate Bi-LSTM model for Short-Term Equity Price Forecasting. *2024 5th IEEE Global Conference for Advancement in Technology (GCAT)*. <https://doi.org/10.1109/GCAT62922.2024.10923989>
- Poernamawatie, F., Nyoman Susipta, I., & Winarno, D. (2024). *Sharia Bank of Indonesia Stock Price Prediction using Long Short-Term Memory*. 07, 4777–4782. <https://doi.org/10.47191/jefms/v7>
- Prayogi, K., Gata, W., & Kussanti, D. P. (2024). Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU. *Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13. <https://doi.org/10.35889/jutisi.v13i1.1910>
- Rasamoelina, A. D., Adjailia, F., & Sincak, P. (2020). A Review of Activation Function for Artificial Neural Network. *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*. <https://doi.org/10.1109/SAMI48414.2020.9108717>
- Shihab, M. Q. (2016). *Tafsir Al Mishbah : pesan, kesan dan keserasian Al-Qur'an Jilid 1*. Lentera Hati.
- Shihab, M. Quraish. (2002a). *Tafsir Al Mishbah Jilid 14: pesan, kesan dan keserasian Al-Qur'an*. Lentera Hati.
- Shihab, M. Quraish. (2002b). *Tafsir Al-Mishbah Jilid 6: pesan, kesan dan keserasian Al-Qur'an*. Lentera Hati.
- Venugopal, P., T, V., & Reka S, S. (2023). State of Charge Estimation of Lithium Batteries in Electric Vehicles Using IndRNN. *IETE Journal of Research*, 69(5), 2886–2896. <https://doi.org/10.1080/03772063.2021.1906770>
- Warouw, V. G., Pangkey, R. I. J., & Fajar, N. (2022). Pengaruh Kebijakan Dividen Dan Keputusan Investasi Terhadap Harga Saham Pada Perusahaan Yang Tergabung Dalam Indeks Lq45 Di Bei Periode 2016-2018. *Jurnal Akuntasi Manado*, 3, 137–148. <https://doi.org/https://doi.org/10.53682/jaim.v3i1.2426>

Zhang, C., Sjarif, N. N. A., & Ibrahim, R. (2023). Deep learning models for price forecasting of financial time series: A review of recent advancements: 2020–2022. In *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* (Vol. 14, Issue 1). John Wiley and Sons Inc. <https://doi.org/10.1002/widm.1519>

LAMPIRAN

Lampiran 1 Hasil Input Sliding Window = 20

Lampiran 2 Hasil Target Sliding Window = 20

window	Target Hari ke-																			
	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	...	50
1	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	...	0.1806
2	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	...	0.1888
3	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	...	0.1872
4	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	...	0.1905
5	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	...	0.2053
6	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	...	0.2069
7	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	...	0.2003
8	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	...	0.2036
9	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	...	0.2053
10	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	...	0.2135
11	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	...	0.2135
12	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	...	0.2447
13	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	...	0.2315
14	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	...	0.2397
15	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	...	0.2397
16	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	...	0.2496
17	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	...	0.243
18	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	...	0.2463
19	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	...	0.2414
20	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	...	0.2512
21	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	...	0.3481
22	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	...	0.4713
23	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	...	0.4516
24	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	...	0.4581
25	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	...	0.4614
26	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	...	0.514
27	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	...	0.5534
28	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	...	0.5238
29	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	...	0.5074
30	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	...	0.5074
31	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	...	0.514
32	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	...	0.5008
33	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	...	0.5369
34	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	...	0.5337
35	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	...	0.5862
36	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	...	0.6519
37	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	...	0.7011
38	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	...	0.7603
39	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	...	0.9967
40	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	...	1
...
793	0.3478	0.3478	0.368	0.4	0.4017	0.4101	0.4219	0.4135	0.4252	0.4286	0.4168	0.4118	0.4185	0.4387	0.4387	0.4657	0.4892	0.4589	0.5532	...

Lampiran 3 Hasil Input Sliding Window = 30

window	Input Hari ke-																												
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	...	30									
1	0.0821	0.0805	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	...	0.0575									
2	0.0805	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	...	0.1314									
3	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	...	0.2233									
4	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	...	0.1921									
5	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	...	0.22									
6	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	...	0.2217									
7	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	...	0.2545									
8	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	...	0.22									
9	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	...	0.1888									
10	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	...	0.1593									
11	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	...	0.1724									
12	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	...	0.1675									
13	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	...	0.1593									
14	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	...	0.1494									
15	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	...	0.1461									
16	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	...	0.1773									
17	0.0082	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	...	0.1658									
18	0	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	...	0.1626									
19	0.0148	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	...	0.1658									
20	0.0099	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	...	0.1806									
21	0.0049	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	...	0.1806									
22	0.0082	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	...	0.1888									
23	0.023	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	...	0.1872									
24	0.0164	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	...	0.1905									
25	0.0378	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	...	0.2053									
26	0.0394	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	...	0.2069									
27	0.0411	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	...	0.2003									
28	0.0443	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	...	0.2036									
29	0.0427	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	...	0.2053									
30	0.0575	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	...	0.2135									
31	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	...	0.2135									
32	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	...	0.2447									
33	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	...	0.2315									
34	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	...	0.2397									
35	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	...	0.2397									
36	0.0821	0.0805	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	...	0.2496								
37	0.0805	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	...	0.243									
38	0.0755	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	...	0.2463									
39	0.0854	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	...	0.2414									
40	0.0805	0.0772	0.0608	0.0411	0.0443	0.064	0.0575	0.0493	0.0427	0.0476	0.0328	0.0148	0.0082	0	0.0148	0.0099	0.0049	0.0082	...	0.2512									
...								
793	0.3158	0.3192	0.3259	0.3343	0.3394	0.3478	0.3293	0.3293	0.3242	0.3141	0.3158	0.336	0.3343	0.3326	0.336	0.3529	0.331	0.3326	0.4286	...									

Lampiran 4 Hasil Target *Sliding Window = 30*

window	Target Hari ke-																			
	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	...	60
1	0.1314	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	...	0.2135
2	0.2233	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	...	0.2447
3	0.1921	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	...	0.2315
4	0.22	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	...	0.2397
5	0.2217	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	...	0.2397
6	0.2545	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	...	0.2496
7	0.22	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	...	0.243
8	0.1888	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	...	0.2463
9	0.1593	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	...	0.2414
10	0.1724	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	...	0.2512
11	0.1675	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	...	0.3481
12	0.1593	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	...	0.4713
13	0.1494	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	...	0.4516
14	0.1461	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	...	0.4581
15	0.1773	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	...	0.4614
16	0.1658	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	...	0.514
17	0.1626	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	...	0.5534
18	0.1658	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	...	0.5238
19	0.1806	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	...	0.5074
20	0.1806	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	...	0.5074
21	0.1888	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	...	0.514
22	0.1872	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	...	0.5008
23	0.1905	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	...	0.5369
24	0.2053	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	...	0.5337
25	0.2069	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	...	0.5862
26	0.2003	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	...	0.6519
27	0.2036	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	...	0.7011
28	0.2053	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	...	0.7603
29	0.2135	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	...	0.9967
30	0.2135	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	1	...
31	0.2447	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	...	0.9967
32	0.2315	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	...	0.9672
33	0.2397	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	...	0.8851
34	0.2397	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	0.5008	...	0.8095
35	0.2496	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	0.5008	0.5369	...	0.9606
36	0.243	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	0.5008	0.5369	0.5337	...	0.9048
37	0.2463	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	0.5008	0.5369	0.5337	0.5862	...	0.8259
38	0.2414	0.2512	0.3481	0.4713	0.4516	0.4581	0.4614	0.514	0.5534	0.5238	0.5074	0.5074	0.514	0.5008	0.5369	0.5337	0.5862	0.6519	...	0.8259
...
793	0.3478	0.3478	0.368	0.4	0.4017	0.4101	0.4219	0.4135	0.4252	0.4286	0.4168	0.4118	0.4185	0.4387	0.4657	0.4892	0.4589	0.5532