


Pemodelan Deret Waktu Menggunakan *Non-linear Autoregressive Neural Network*: Studi Kasus Prediksi Harga Saham Mandiri

Mohamad Khoirun Najib dan Sri Nurdianti




Volume 7, Issue 2, Pages 213–220, August 2025

Diterima 11 Juli 2025, Direvisi 28 Agustus 2025, Disetujui 30 Agustus 2025, Diterbitkan 31 Agustus 2025

To Cite this Article : M. K. Najib dan S. Nurdianti, "Pemodelan Deret Waktu Menggunakan *Non-linear Autoregressive Neural Network*: Studi Kasus Prediksi Harga Saham Mandiri", *Jambura J. Math*, vol. 7, no. 2, pp. 213–220, 2025, <https://doi.org/10.37905/jjom.v7i2.33397>

© 2025 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF MATHEMATICS




	Homepage	:	http://ejurnal.ung.ac.id/index.php/jjom/index
	Journal Abbreviation	:	Jambura J. Math.
	Frequency	:	Biannual (February and August)
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/jjom
	Online ISSN	:	2656-1344
	Editor-in-Chief	:	Hasan S. Panigoro
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/jjom/oai
	Google Scholar ID	:	iWLjgaUAAAAJ
	Email	:	info.jjom@ung.ac.id


JAMBURA JOURNAL • FIND OUR OTHER JOURNALS




Jambura Journal of Biomathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi

Pemodelan Deret Waktu Menggunakan *Non-linear Autoregressive Neural Network*: Studi Kasus Prediksi Harga Saham Mandiri

Mohamad Khoirun Najib^{1,*}, Sri Nurdianti¹

¹*Sekolah Sains Data, Matematika, dan Informatika, IPB University, Bogor 16680, Indonesia*

ARTICLE HISTORY

Diterima 11 Juli 2025
Direvisi 28 Agustus 2025
Disetujui 30 Agustus 2025
Diterbitkan 31 Agustus 2025

KATA KUNCI

Harga Saham
Jaringan Saraf Tiruan
NARNN
Peramalan Deret Waktu
Prediksi

KEYWORDS

Artificial Neural Network
NARNN
Prediction
Stock Price
Time Series Forecasting

ABSTRAK. Peramalan harga saham yang akurat sangat penting dalam pengambilan keputusan investasi, namun karakteristik deret waktunya yang tak-linear dan kompleks sering kali menjadi tantangan. Penelitian ini mengkaji penerapan *Nonlinear Autoregressive Neural Network* (NARNN) dalam pemodelan deret waktu harga saham bulanan PT Bank Mandiri (Persero) Tbk (BMRI) periode Januari 2011 hingga Desember 2023. Model dibangun dengan mengeksplorasi kombinasi jumlah *feedback delay* dan neuron pada *hidden layer* untuk menemukan konfigurasi optimal berdasarkan nilai *root mean squared error*. Data dibagi menjadi tiga subset: pelatihan, validasi, dan pengujian. Evaluasi menunjukkan bahwa model dengan konfigurasi 8–12 dan 8–13 memberikan hasil prediksi terbaik dengan MAPE pengujian sebesar 4,71%. Strategi *ensemble mean* juga diterapkan dan menghasilkan kinerja yang kompetitif dan stabil. Hasil ini menunjukkan bahwa pendekatan NARNN efektif dalam menangkap pola tak-linear pada data saham dan potensial untuk digunakan dalam peramalan finansial.

ABSTRACT. Accurate stock price forecasting is critical for investment decision-making, yet the nonlinear and complex nature of time series data poses significant challenges. This study investigates the application of the *Nonlinear Autoregressive Neural Network* (NARNN) for modeling the monthly stock price time series of PT Bank Mandiri (Persero) Tbk (BMRI) from January 2011 to December 2023. The model is constructed by exploring combinations of *feedback delays* and *hidden neurons* to identify the optimal configuration based on the *root mean squared error*. The dataset is divided into training, validation, and testing. Evaluation results show that the configurations 8–12 and 8–13 yield the best testing accuracy with a MAPE of 4.71%. An *ensemble mean* strategy is also employed, producing competitive and stable performance. These findings demonstrate that the NARNN approach effectively captures nonlinear patterns in stock data and holds promise for financial forecasting applications.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. Editorial of JJoM: Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Permasalahan peramalan (*forecasting*) deret waktu (*time series*) telah menjadi perhatian utama dalam berbagai bidang ilmu, terutama yang berkaitan dengan pengambilan keputusan berbasis data historis [1–3]. Peramalan memainkan peran penting dalam merumuskan strategi, mengelola risiko, serta mengoptimalkan sumber daya dalam berbagai sektor, mulai dari ekonomi [4], keuangan [5, 6], energi [7], hingga lingkungan [8]. Kebutuhan untuk memprediksi nilai masa depan dari suatu variabel berdasarkan nilai-nilai sebelumnya muncul seiring dengan meningkatnya ketidakpastian dalam sistem global, seperti fluktuasi ekonomi [9], perubahan iklim [10], volatilitas harga komoditas [11], dan dinamika pasar keuangan [12]. Data historis dianggap sebagai sumber informasi berharga karena mengandung pola, tren, musiman, dan anomali yang dapat dimanfaatkan untuk memproyeksikan kondisi masa depan [13].

Namun, tantangan utama dalam peramalan deret waktu terletak pada kemampuannya dalam menangkap pola dan dinamika kompleks yang terkandung dalam data tersebut. Banyak fenome-

na nyata menunjukkan karakteristik nonlinear [14, 15], heteroskedastis [16, 17], dan bersifat dinamis [18, 19], yang menyulitkan model konvensional untuk memberikan hasil prediksi yang konsisten dan akurat. Selain itu, deret waktu sering kali dipengaruhi oleh faktor eksternal yang tidak teramati secara langsung [20–22], serta memiliki ketergantungan jangka pendek maupun jangka panjang yang rumit [23, 24]. Oleh karena itu, pemilihan metode yang tepat serta pemahaman mendalam terhadap sifat data menjadi aspek yang krusial dalam proses peramalan. Tantangan-tantangan ini mendorong berkembangnya berbagai pendekatan baru yang bertujuan untuk meningkatkan performa peramalan deret waktu secara lebih adaptif dan cerdas.

Dalam beberapa tahun terakhir, peramalan deret waktu semakin mendapatkan perhatian luas, didorong oleh kemajuan teknologi komputasi, peningkatan kapasitas penyimpanan data, serta semakin canggihnya algoritma analisis data [25, 26]. Digitalisasi di berbagai sektor menghasilkan volume data historis yang sangat besar dan beragam, sehingga membuka peluang untuk mengeksplorasi teknik peramalan yang lebih kompleks dan akurat. Perkembangan dalam bidang *machine learning*, *big data ana-*

*Penulis Korespondensi.

lytics, dan *cloud computing* turut mempercepat adopsi metode peramalan modern yang mampu mengolah dan menganalisis data dalam skala besar dengan efisiensi tinggi.

Di sektor keuangan, peramalan harga saham merupakan salah satu penerapan paling menonjol dan menantang dari teknik peramalan deret waktu [27, 28]. Hal ini disebabkan oleh tingginya volatilitas pasar dan kompleksitas faktor-faktor yang memengaruhi harga saham, mulai dari indikator ekonomi makro [29], kondisi geopolitik [30], hingga sentimen pasar [31]. Kemampuan untuk memprediksi arah pergerakan harga saham secara tepat memberikan keuntungan strategis yang signifikan, baik dalam konteks pengambilan keputusan investasi, pengelolaan portofolio, manajemen risiko, maupun penyusunan kebijakan moneter dan fiskal.

Seiring dengan meningkatnya kebutuhan akan model prediksi yang lebih akurat dan adaptif terhadap dinamika data yang kompleks, berbagai metode peramalan deret waktu terus dikembangkan dan disempurnakan. Pendekatan klasik seperti *Autoregressive Integrated Moving Average* (ARIMA) [32, 33], *Seasonal ARIMA* (SARIMA) [34, 35], dan *Exponential Smoothing* [36, 37] telah menjadi dasar dalam analisis deret waktu selama beberapa dekade terakhir. Model-model ini bekerja efektif untuk data yang bersifat linear, stasioner, dan memiliki pola musiman yang teratur. Namun, dalam banyak kasus nyata, data deret waktu sering kali menunjukkan karakteristik nonlinear, volatilitas tinggi, serta adanya interaksi yang kompleks antar variabel, yang tidak dapat ditangani secara optimal oleh model linear tradisional.

Untuk mengatasi keterbatasan tersebut, pendekatan berbasis pembelajaran mesin (*machine learning*) mulai banyak diadopsi, karena kemampuannya dalam menangkap pola-pola yang kompleks dan tidak eksplisit dalam data. Salah satu metode yang menonjol adalah *artificial neural networks* (ANN), yang terinspirasi dari cara kerja jaringan saraf biologis [38–40]. ANN memiliki kemampuan untuk mempelajari hubungan nonlinear antar variabel input dan output melalui proses pelatihan data, tanpa perlu asumsi eksplisit tentang bentuk hubungan tersebut. Keunggulan ini menjadikan ANN sebagai alat yang sangat fleksibel dan adaptif dalam berbagai konteks peramalan deret waktu, termasuk dalam sektor keuangan, energi, hingga kesehatan.

Berbagai arsitektur ANN telah dikembangkan dan diaplikasikan untuk peramalan deret waktu, seperti *Multilayer Perceptron* (MLP) [41], *Radial Basis Function Networks* (RBFN) [42], serta jaringan saraf dengan memori jangka pendek seperti *Recurrent Neural Networks* (RNN) [43] dan *Long Short-Term Memory* (LSTM) [44]. Di antara pendekatan tersebut, terdapat satu model yang secara khusus dirancang untuk memanfaatkan nilai-nilai masa lalu dari satu variabel untuk memprediksi nilai berikutnya, yaitu *Nonlinear Autoregressive Neural Network* (NARNN) [45–47]. Model ini menawarkan keseimbangan antara kesederhanaan struktur dan kekuatan dalam menangkap pola nonlinear pada data deret waktu tunggal.

Nonlinear Autoregressive Neural Network (NARNN) merupakan varian dari jaringan saraf yang dirancang khusus untuk menangani peramalan deret waktu univariat, yaitu prediksi nilai masa depan sepenuhnya didasarkan pada nilai-nilai masa lalu dari variabel yang sama. Dalam arsitekturnya, NARNN menggunakan *feedback connection* dari *output* ke *input*, yang memungkinkan model untuk belajar dari ketergantungan jangka pendek maupun jangka pan-

jang secara lebih fleksibel [47–49]. Berbeda dengan model linear seperti ARIMA yang mengandalkan asumsi hubungan linear antar lag, NARNN mampu memetakan hubungan nonlinear secara eksplisit tanpa memerlukan transformasi data atau pemodelan fungsi tertentu secara manual. Selain itu, model ini relatif sederhana dalam implementasinya dibandingkan dengan arsitektur jaringan saraf yang lebih kompleks seperti LSTM, namun tetap dapat memberikan hasil prediksi yang kompetitif.

Melihat potensi dan keunggulan NARNN dalam menangani peramalan deret waktu yang bersifat nonlinear, penelitian ini bertujuan untuk mengeksplorasi model NARNN dalam memprediksi harga saham dari Bank Mandiri (BMRI). Saham bank tersebut merupakan bagian dari indeks LQ45 dan IDX30, serta memiliki kapitalisasi pasar dan volume perdagangan yang tinggi, sehingga pergerakannya sangat berpengaruh terhadap dinamika pasar modal Indonesia secara keseluruhan.

Penelitian ini difokuskan pada analisis data historis harga saham dari masing-masing emiten, dengan tujuan untuk membangun model NARNN yang mampu menghasilkan prediksi harga saham pada horizon waktu jangka pendek. Evaluasi kinerja model akan dilakukan dengan membandingkan nilai prediksi terhadap data aktual menggunakan metrik evaluasi seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil dari penelitian ini diharapkan dapat memberikan gambaran empiris mengenai efektivitas NARNN dalam memodelkan data saham di pasar Indonesia, serta memberikan kontribusi terhadap pengembangan metode prediktif yang lebih akurat dan kontekstual di sektor keuangan nasional.

2. Metode


2.1. Model Autoregressive (AR) dalam Deret Waktu

Peramalan deret waktu adalah proses untuk memprediksi nilai masa depan berdasarkan nilai-nilai masa lalu dalam suatu urutan data yang terorganisir dalam waktu tertentu. Model-model *autoregressive* (AR) adalah salah satu teknik yang paling banyak digunakan dalam peramalan deret waktu, terutama untuk data yang menunjukkan ketergantungan jangka pendek [8, 50]. Dalam model AR, nilai masa depan diprediksi berdasarkan kombinasi linear dari nilai masa lalu. Namun, dalam banyak kasus, hubungan yang ada dalam data deret waktu lebih kompleks dan tidak dapat dijelaskan secara memadai dengan model linear.

2.2. Jaringan Saraf Tiruan dan Perkembangannya dalam Peramalan Deret Waktu

Jaringan saraf tiruan (*artificial neural networks*, ANN) telah menjadi alternatif yang kuat untuk model-model linear dalam peramalan deret waktu [51, 52]. ANN memiliki kemampuan untuk memodelkan hubungan nonlinear yang lebih kompleks dan dapat belajar dari data secara otomatis. Pada dasarnya, ANN terdiri dari lapisan input, lapisan tersembunyi (*hidden*), dan lapisan output, dengan setiap unit dalam lapisan tersembunyi berfungsi untuk mengolah dan menyesuaikan bobot berdasarkan data yang diberikan. Pendekatan ini memungkinkan ANN untuk menangkap pola-pola yang tidak mudah ditangkap oleh model tradisional seperti ARIMA atau regresi linear.

Beberapa varian ANN yang digunakan dalam peramalan deret waktu meliputi *Multilayer Perceptron* (MLP) [53], *Radial Basis Function* (RBF) [54], dan *Recurrent Neural Networks* (RNN) [55]. RNN,



Gambar 1. Diagram NARNN dengan 2-delay dan 30 neuron

misalnya, dapat menangani ketergantungan jangka panjang dalam data deret waktu dengan memanfaatkan loop di dalam jaringan untuk memelihara informasi historis. Namun, RNN memiliki keterbatasan dalam menangani masalah *vanishing gradient* dan kesulitan dalam menangkap pola yang sangat kompleks pada data nonlinear.

2.3. Nonlinear Autoregressive Neural Network (NARNN)

NARNN adalah salah satu pendekatan yang dirancang untuk mengatasi keterbatasan model AR dan RNN dalam menangani data deret waktu nonlinear. NARNN menggabungkan elemen *autoregressive* dengan kemampuan jaringan saraf untuk menangkap pola nonlinear dalam data. Dalam model NARNN, data masa lalu dari variabel yang akan diprediksi digunakan sebagai input untuk jaringan saraf, yang kemudian belajar untuk memprediksi nilai masa depan. Model NARNN berbeda dengan model *autoregressive* linear karena menggunakan transformasi nonlinear dalam memodelkan ketergantungan data. Dengan kemampuan ini, NARNN lebih fleksibel dalam menangani data yang tidak stasioner dan memiliki hubungan kompleks antar variabel. Penelitian sebelumnya menunjukkan bahwa NARNN dapat menghasilkan prediksi yang lebih akurat daripada ARIMA dalam berbagai aplikasi peramalan, termasuk peramalan harga saham [56, 57].

2.3.1. Struktur NARNN

Pendekatan NARNN mengasumsikan bahwa nilai Y pada waktu t , Y_t , merupakan fungsi dari d nilai yang lampau, seperti pada pers. (1):

$$Y_t = f(Y_{t-1}, \dots, Y_{t-d}). \quad (1)$$

Fungsi f yang tidak diketahui dimodelkan menggunakan jaringan saraf tiruan [58]. Gambar 1 menunjukkan model NARNN 2-delay yang terdiri dari 30 neuron. Jaringan saraf ini memperkirakan nilai masa depan dengan melihat dua data historis. Dalam menentukan kinerja model, nilai yang diperkirakan oleh NARNN dibandingkan dengan hasil yang diketahui sebelumnya dan perbedaannya dilihat menggunakan beberapa ukuran kinerja. Untuk kinerja tinggi, nilai perbedaan diharapkan mendekati 0.

Pada jaringan di atas, input yang digunakan berasal dari nilai-nilai masa lalu dari variabel target itu sendiri, yaitu y_{t-1} , y_{t-2} , dan seterusnya, sesuai dengan jumlah delay yang ditentukan. Dalam diagram di atas, jaringan menggunakan dua nilai lag sebagai input (ditunjukkan dengan label "1:2"), yang kemudian diproses oleh lapisan tersembunyi (*hidden layer*) yang terdiri dari

30 neuron. Setiap neuron dalam lapisan tersembunyi melakukan operasi penjumlahan bobot dan bias terhadap input, lalu menerapkan fungsi aktivasi nonlinear untuk menangkap pola kompleks dalam data. Hasil dari lapisan tersembunyi diteruskan ke lapisan output yang biasanya menggunakan fungsi aktivasi linear untuk menghasilkan prediksi nilai y_t . Diagram ini menggambarkan model dalam konfigurasi *open-loop* yang digunakan saat pelatihan, yaitu output aktual digunakan sebagai umpan balik. Setelah pelatihan selesai, jaringan akan dikonversi menjadi *closed-loop* untuk melakukan prediksi beberapa langkah ke depan secara berurutan.

2.3.2. Langkah-langkah NARNN

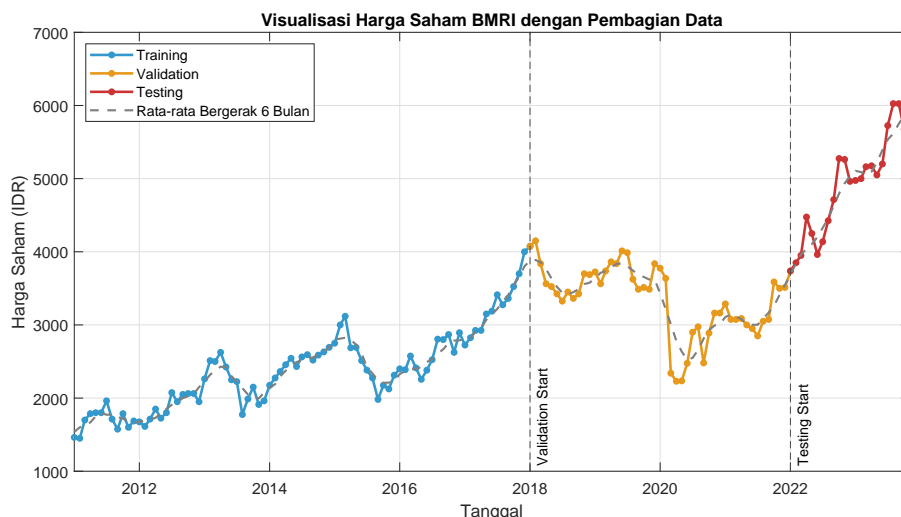
Implementasi model NARNN dalam penelitian ini dilakukan melalui beberapa tahapan sistematis. Pertama, data deret waktu berupa harga penutupan saham dimasukkan sebagai input tunggal ke dalam model. Selanjutnya, data dibagi menjadi tiga bagian, yakni data pelatihan, validasi, dan pengujian. Setelah pembagian data, dilakukan pencarian parameter model terbaik dengan menguji berbagai kombinasi *feedback delays* (yaitu antara 2 hingga 9) serta jumlah neuron tersembunyi (antara 5 hingga 25).

Tahap selanjutnya adalah proses pelatihan dan prediksi. Model dilatih dalam konfigurasi *open loop*, di mana nilai aktual digunakan sebagai umpan balik. Setelah pelatihan selesai, model dikonversi ke konfigurasi *closed loop* untuk memungkinkan prediksi multi-langkah ke depan secara berurutan. Terakhir, dilakukan evaluasi kinerja model menggunakan *Mean Absolute Percentage Error* (MAPE). Selain itu, performa prediksi juga dianalisis secara visual melalui perbandingan antara nilai hasil prediksi dengan data aktual.

2.4. Metrik Evaluasi

Evaluasi performa model prediksi dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE), yang merupakan salah satu metrik yang paling umum digunakan dalam analisis deret waktu, terutama dalam konteks keuangan. MAPE mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual dalam bentuk persentase, sehingga memudahkan interpretasi terhadap besarnya deviasi relatif yang terjadi. Secara matematis, MAPE didefinisikan sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (2)$$



Gambar 2. Visualisasi harga saham BMRI Januari 2011–Desember 2023 dengan pembagian data training, validasi, dan testing, serta rata-rata bergerak 6 bulan

Tabel 1. Informasi hyperparameter dan parameter model NARNN

Komponen	Nilai / Deskripsi
Fungsi pelatihan	Bayesian Regularization Backpropagation
Fungsi aktivasi lapisan tersembunyi	<code>tansig</code>
Struktur jaringan	<i>Open-loop</i> (pelatihan), <i>Closed-loop</i> (prediksi)
Jumlah <i>feedback delay</i>	$d \in \{2, 3, \dots, 9\}$
Jumlah neuron tersembunyi	$n \in \{5, 6, \dots, 25\}$
Fungsi pembagian data	<code>divideind</code> (pembagian indeks manual)
Rentang data pelatihan	Indeks 1–84 (Jan 2011 – Des 2017)
Rentang data validasi	Indeks 85–132 (Jan 2018 – Des 2021)
Rentang data pengujian	Indeks 133–156 (Jan 2022 – Des 2023)
Fungsi performa	<code>mse</code> (<i>Mean Squared Error</i>)
Regularisasi performa	Tidak digunakan (0)
Normalisasi performa	Tidak digunakan ('none')

dengan y_t adalah nilai aktual pada waktu ke- t , \hat{y}_t adalah nilai hasil prediksi, dan n adalah jumlah total observasi.

3. Hasil dan Pembahasan

3.1. Deskripsi Data

Data yang digunakan dalam penelitian ini adalah harga saham bulanan dari PT Bank Mandiri (Persero) Tbk (kode saham: BMRI), yang diambil dari periode Januari 2011 hingga Desember 2023. Setiap observasi merepresentasikan nilai rata-rata harga penutupan bulanan, sehingga menghasilkan deret waktu univariat untuk setiap variabel. Visualisasi awal terhadap data saham BMRI memberikan gambaran mengenai tren jangka panjang, fluktuasi musiman, dan potensi adanya outlier yang signifikan. Grafik berikut menyajikan pergerakan harga saham BMRI selama periode pengamatan, yang menunjukkan pola pertumbuhan jangka panjang dengan beberapa fase koreksi dan volatilitas yang tajam, khususnya pada periode krisis global dan pandemi.

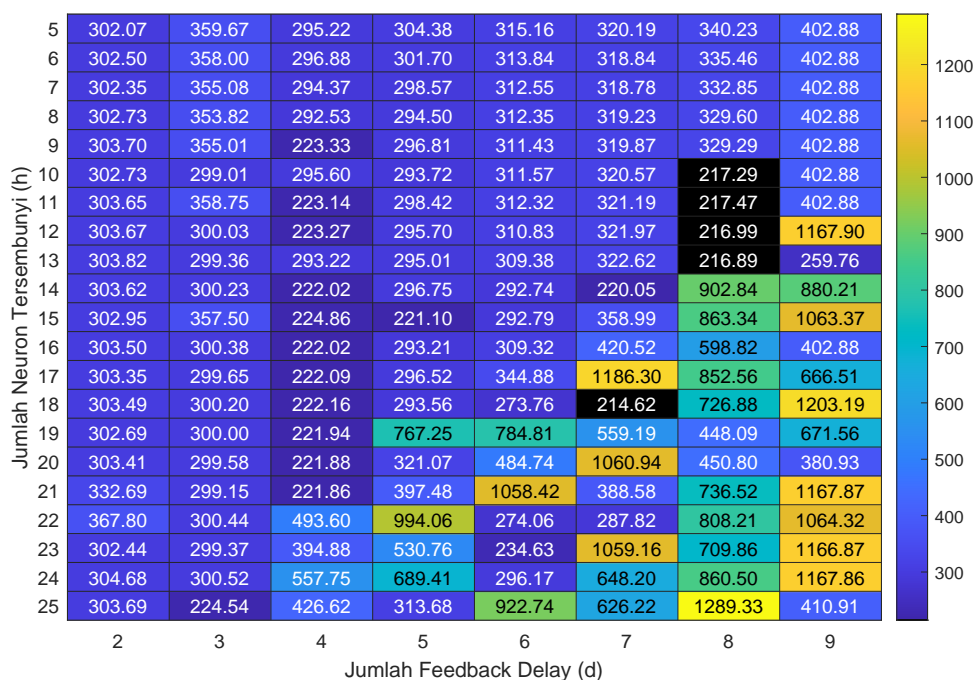
Gambar 2 menunjukkan pergerakan harga saham bulanan BMRI dari Januari 2011 hingga Desember 2023, dibagi ke dalam tiga subset berdasarkan fase pemodelan: data training digunakan untuk melatih model (2011–2017), data validasi untuk menyesuaikan parameter dan menghindari overfitting (2018–2021), serta data testing untuk mengevaluasi kemampuan generalisasi

model (2022–2023). Selama periode training, harga saham menunjukkan tren naik yang relatif stabil. Periode validasi ditandai oleh fluktuasi tinggi, termasuk koreksi tajam pada tahun 2020 akibat dampak pandemi COVID-19. Sementara itu, pada periode testing, harga saham kembali menunjukkan pola naik yang kuat. Garis rata-rata bergerak 6 bulan membantu menyoroti arah tren jangka menengah dan mendeteksi perubahan pola secara visual. Visualisasi ini memberikan konteks yang penting dalam memahami dinamika data sebelum model NARNN diterapkan.

3.2. Konfigurasi Model dan Penentuan Hyperparameter

Pengembangan model NARNN memerlukan penetapan sejumlah parameter dan hyperparameter yang memengaruhi struktur dan kinerja model secara keseluruhan. Tabel 1 merangkum konfigurasi yang digunakan dalam penelitian ini.

Penentuan dua hyperparameter utama, yaitu jumlah *feedback delay* dan jumlah neuron tersembunyi, merupakan bagian penting dalam proses tuning model. *Feedback delay* menentukan kedalaman memori jaringan terhadap input historis, sedangkan jumlah neuron tersembunyi menentukan kapasitas representasi internal model terhadap non-linearitas data. Dalam penelitian ini, dilakukan eksplorasi terhadap kombinasi $d \in \{2, 3, \dots, 9\}$ dan $n \in \{5, 6, \dots, 25\}$. Setiap konfigurasi model dievaluasi ber-



Gambar 3. Heatmap nilai RMSE pada data validasi untuk berbagai kombinasi jumlah feedback delay (d) dan neuron tersembunyi (n)

dasarkan nilai *Mean Absolute Error* (MAE) pada data validasi. Prosedur ini bertujuan untuk menemukan konfigurasi optimal yang meminimalkan kesalahan prediksi sambil menjaga kesederhanaan arsitektur model agar terhindar dari *overfitting*.

Gambar 3 menyajikan representasi visual dari nilai akar kuadrat dari MAE untuk meringkas nilai performa atau sering disebut juga *Root Mean Squared Error* (RMSE) yang diperoleh dari proses *tuning hyperparameter* pada data validasi. Setiap sel dalam grafik menggambarkan performa model NARNN untuk kombinasi jumlah *feedback delay* (d) dan jumlah neuron tersembunyi (n). Warna sel mencerminkan besarnya nilai RMSE, dengan warna lebih gelap menunjukkan kesalahan yang lebih kecil.

Dari visualisasi tersebut, dapat diidentifikasi lima kombinasi terbaik yang menghasilkan nilai RMSE terendah secara signifikan, yang ditandai dengan intensitas warna yang lebih pekat. Kombinasi paling optimal ditemukan pada konfigurasi $d = 7$ dan $n = 18$, dengan nilai RMSE minimum. Empat konfigurasi lain yang juga menunjukkan performa baik berada di sekitar konfigurasi tersebut, yaitu $d = 8$ dan $n = 10, 11, 12, 13$. Konfigurasi-konfigurasi tersebut menunjukkan bahwa peningkatan jumlah neuron tersembunyi di atas 20 tidak selalu menghasilkan peningkatan performa, bahkan justru menyebabkan *overfitting* pada beberapa kasus, yang ditandai dengan meningkatnya nilai RMSE secara drastis di bagian kanan bawah grafik.

3.3. Pengujian Model

Setelah proses pelatihan dan validasi selesai, lima konfigurasi model terbaik dievaluasi pada data pengujian untuk mengukur kemampuan generalisasi model. Pengujian dilakukan menggunakan jaringan dalam mode *closed-loop*, yaitu konfigurasi di mana keluaran model digunakan sebagai input untuk memprediksi nilai masa depan secara berurutan. Berbeda dengan *open-loop* yang menggunakan data historis aktual selama pelatihan, mode *closed-loop* mencerminkan kondisi prediksi nyata di mana hanya nilai terdahulu hasil prediksi yang tersedia.

Gambar 4 menampilkan hasil prediksi dari model terbaik terhadap data aktual harga saham BMRI pada seluruh periode, dengan fokus pada evaluasi kinerja pada subset pengujian (Januari 2022–Desember 2023). Terlihat bahwa model mampu mengikuti tren dan fluktuasi data secara umum, meskipun terdapat deviasi kecil pada beberapa titik ekstrem. Hal ini mengindikasikan bahwa model cukup responsif terhadap dinamika pergerakan harga saham.


Untuk menilai performa lebih lanjut, Tabel 2 menyajikan nilai galat prediksi dalam bentuk *Mean Absolute Percentage Error* (MAPE) pada masing-masing fase: pelatihan, validasi, dan pengujian. Lima konfigurasi model diuji, serta ditampilkan juga performa rata-rata dari ensemble model.

Tabel 2. Kinerja lima konfigurasi model terpilih dan ensemble mean pada masing-masing pembagian data

Konfigurasi Model	Training	Validasi	Testing
Model: 7–18	4,94%	4,21%	6,18%
Model: 8–10	5,74%	5,21%	4,73%
Model: 8–11	5,74%	5,21%	4,74%
Model: 8–12	5,74%	5,21%	4,71%
Model: 8–13	5,74%	5,22%	4,71%
Model: Ensemble Mean		4,89%	4,73%

Dari hasil tersebut, terlihat bahwa konfigurasi 7–18 memberikan hasil validasi terbaik (sesuai dengan pembahasan sebelumnya pada Gambar 3), tetapi menunjukkan kinerja kurang stabil pada data pengujian (MAPE: 6,18%). Sementara itu, konfigurasi 8–12 dan 8–13 menunjukkan keseimbangan yang lebih baik antara performa validasi dan pengujian, dengan MAPE testing hanya 4,71%. Selain itu, strategi ensemble yang menggabungkan output beberapa model juga menghasilkan performa kompetitif dengan MAPE sebesar 4,73%, yang menunjukkan stabilitas dan ketahanan prediksi terhadap fluktuasi data.

Secara keseluruhan, pendekatan ini menunjukkan bahwa



Gambar 4. Perbandingan nilai aktual dan hasil prediksi harga saham BMRI menggunakan konfigurasi model terbaik dalam mode *closed-loop*

penggunaan NARNN dalam mode *closed-loop* efektif dalam menangkap pola musiman dan tren harga saham, serta mampu mempertahankan akurasi prediksi yang baik pada data yang belum pernah dilihat sebelumnya.

3.4. Pembahasan

Penelitian ini menemukan bahwa model NARNN mampu memprediksi harga saham BMRI bulanan dengan tingkat akurasi tinggi, ditunjukkan oleh nilai MAPE terbaik sebesar 4,71%. Hasil ini memperlihatkan kemampuan jaringan saraf nonlinier untuk menangkap pola temporal dan dinamika pasar yang kompleks, bahkan tanpa melibatkan variabel fundamental. Selain itu, penerapan teknik *ensemble* pada beberapa konfigurasi terbaik menghasilkan performa yang stabil, dengan variabilitas error lebih rendah dibandingkan model tunggal. Hal ini menegaskan bahwa strategi *ensemble* dapat meningkatkan reliabilitas hasil prediksi dalam konteks peramalan harga saham.

Jika dibandingkan dengan [59], terdapat beberapa perbedaan penting. Pada penelitian tersebut, Aryawangsa dkk. [59] menggunakan algoritma *random forest* dengan variabel input berupa rasio keuangan perbankan (ROE, ROA, NIM, NPL, LDR, dan CAR) untuk memprediksi harga saham kuartalan empat bank besar di Indonesia (BBCA, BBRI, BMRI, dan BBNI). Hasil penelitian tersebut menunjukkan bahwa model *random forest* mampu mencapai tingkat akurasi cukup tinggi, dengan MAPE terbaik sebesar 5,89% pada BMRI, sementara bank lain berada pada kisaran 8,04%–13,23%.

Perbedaan utama penelitian ini terletak pada pendekatan dan sumber informasi yang digunakan. Penelitian ini berfokus pada pola runtun waktu harga saham itu sendiri sedangkan Aryawangsa dkk. [59] menekankan pada faktor fundamental perbankan melalui analisis rasio keuangan. Menariknya, meskipun tidak menggunakan indikator fundamental, model NARNN dalam penelitian ini justru mampu menghasilkan tingkat kesalahan prediksi yang lebih rendah (MAPE 4,71%) dibandingkan dengan *random forest* berbasis rasio keuangan (MAPE terbaik 5,89%). Hal tersebut menunjukkan bahwa informasi yang terkandung dalam data harga saham historis dapat dimanfaatkan secara optimal oleh model

nonlinier dengan memori jangka panjang seperti NARNN.

Dari sisi kontribusi ilmiah, penelitian ini menunjukkan bahwa prediksi harga saham tidak selalu harus bergantung pada rasio fundamental, melainkan juga dapat dicapai dengan memanfaatkan kekuatan model *deep learning* berbasis runtun waktu. Dengan demikian, penelitian ini menunjukkan efektivitas pemodelan murni berbasis data pasar. Selanjutnya, pengembangan model hibrida yang menggabungkan data fundamental dan teknikal dapat dilakukan guna menghasilkan prediksi yang lebih akurat dan reliabel di masa depan.

4. Kesimpulan

Penelitian ini menunjukkan bahwa model *Nonlinear Autoregressive Neural Network* (NARNN) efektif dalam memodelkan data deret waktu harga saham bulanan, khususnya pada kasus saham BMRI. Melalui eksplorasi berbagai konfigurasi jumlah *feedback delay* dan neuron tersembunyi, ditemukan bahwa kombinasi arsitektur berpengaruh signifikan terhadap akurasi prediksi. Evaluasi model berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa konfigurasi 8–12 dan 8–13 memberikan hasil paling konsisten dengan MAPE pengujian sebesar 4,71%. Lebih lanjut, strategi *ensemble mean* dari lima model terbaik menghasilkan performa yang kompetitif dan stabil dengan MAPE sebesar 4,73%, menunjukkan bahwa penggabungan prediksi dari beberapa model dapat meningkatkan keandalan. Secara keseluruhan, pendekatan NARNN terbukti mampu menangkap pola nonlinier dalam data saham dan dapat menjadi alternatif yang menjanjikan untuk peramalan deret waktu finansial.

Kontribusi Penulis. M. K. Najib: Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, kurasi data, visualisasi, penulisan—penyusunan draf asli, penulisan—tinjauan dan penyuntingan. S. Nurdianti: Supervisi, administrasi proyek, penulisan—tinjauan dan penyuntingan, perolehan pendanaan. Kedua penulis telah membaca dan menyetujui versi akhir manuskrip.

Ucapan Terima Kasih. Para penulis menyampaikan penghargaan dan terima kasih yang sebesar-besarnya kepada Sekolah Sains Data, Matemati-

ka, dan Informatika, IPB University atas dukungan yang telah diberikan, khususnya dalam menyediakan lingkungan penelitian yang kondusif untuk pelaksanaan studi ini.

Pembiayaan. Penelitian ini tidak menerima pembiayaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Ketersediaan Data. Data harga saham yang digunakan dalam penelitian ini tersedia secara publik dan dapat diakses melalui platform Yahoo Finance (<https://finance.yahoo.com>) dengan kode saham BMRI (PT Bank Mandiri Tbk).

Referensi

- [1] M. Mudelsee, "Trend analysis of climate time series: A review of methods," *Earth-science reviews*, vol. 190, pp. 310–322, 2019, doi: [10.1016/j.earscirev.2018.12.005](https://doi.org/10.1016/j.earscirev.2018.12.005).
- [2] D. S. Stoffer and H. Ombao, "Special issue on time series analysis in the biological sciences," pp. 701–703, 2012, doi: [10.1111/j.1467-9892.2012.00805.x](https://doi.org/10.1111/j.1467-9892.2012.00805.x).
- [3] B. Lim and S. Zohren, "Time-series forecasting with deep learning: a survey," *Philosophical Transactions of the Royal Society A*, vol. 379, no. 2194, p. 20200209, 2021, doi: [10.1098/rsta.2020.0209](https://doi.org/10.1098/rsta.2020.0209).
- [4] U. Chatterjee, "Forecasting economic growth: Evidence from housing, banking, and credit conditions," *Journal of Economics and Finance*, vol. 47, no. 4, pp. 936–958, 2023, doi: [10.1007/s12197-023-09637-8](https://doi.org/10.1007/s12197-023-09637-8).
- [5] K. He, Q. Yang, L. Ji, J. Pan, and Y. Zou, "Financial time series forecasting with the deep learning ensemble model," *Mathematics*, vol. 11, no. 4, p. 1054, 2023, doi: [10.3390/math11041054](https://doi.org/10.3390/math11041054).
- [6] M. Shahvaroughi Farahani and S. H. Razavi Hajiagha, "Forecasting stock price using integrated artificial neural network and metaheuristic algorithms compared to time series models," *Soft computing*, vol. 25, no. 13, pp. 8483–8513, 2021, doi: [10.1007/s00500-021-05775-5](https://doi.org/10.1007/s00500-021-05775-5).
- [7] A. Mystakidis, P. Koukaras, N. Tsalikidis, D. Ioannidis, and C. Tjortjis, "Energy forecasting: a comprehensive review of techniques and technologies," *Energies*, vol. 17, no. 7, p. 1662, 2024, doi: [10.3390/en17071662](https://doi.org/10.3390/en17071662).
- [8] J. Kaur, K. S. Parmar, and S. Singh, "Autoregressive models in environmental forecasting time series: a theoretical and application review," *Environmental Science and Pollution Research*, vol. 30, no. 8, pp. 19617–19641, 2023, doi: [10.1007/s11356-023-25148-9](https://doi.org/10.1007/s11356-023-25148-9).
- [9] C. Li and Q. Qi, "A novel hybrid grey system forecasting model based on seasonal fluctuation characteristics for electricity consumption in primary industry," *Energy*, vol. 287, p. 129585, 2024, doi: [10.1016/j.energy.2023.129585](https://doi.org/10.1016/j.energy.2023.129585).
- [10] M. Russo, D. Carvalho, N. Martins, and A. Monteiro, "Forecasting the inevitable: A review on the impacts of climate change on renewable energy resources," *Sustainable Energy Technologies and Assessments*, vol. 52, p. 102283, 2022, doi: [10.1016/j.seta.2022.102283](https://doi.org/10.1016/j.seta.2022.102283).
- [11] L. Vancsura, T. Tatay, and T. Bareith, "Evaluating the effectiveness of modern forecasting models in predicting commodity futures prices in volatile economic times," *Risks*, vol. 11, no. 2, p. 27, 2023, doi: [10.3390/risks11020027](https://doi.org/10.3390/risks11020027).
- [12] N. Döhler, C. Wellenreuther, and A. Wolf, "Market dynamics of biodegradable bio-based plastics: Projections and linkages to european policies," *EFB Bioeconomy Journal*, vol. 2, p. 100028, 2022, doi: [10.1016/j.bioeco.2022.100028](https://doi.org/10.1016/j.bioeco.2022.100028).
- [13] L. C. Roy, S. K. Das, M. S. Yeasar, M. R. Islam, S. Alam, and M. Mamun, "Capturing rainfall dynamics: the efficacy of arima models in environmental forecasting," in *Proceedings of the 7th International Conference on Advances in Civil Engineering (ICACE2024)*. Chattogram, Bangladesh: CUET, Dec. 2024, pp. 583–590.
- [14] A. G. Billé, A. Gianfreda, F. Del Grosso, and F. Ravazzolo, "Forecasting electricity prices with expert, linear, and nonlinear models," *International Journal of Forecasting*, vol. 39, no. 2, pp. 570–586, 2023.
- [15] J. Wang, X. Sun, Q. Cheng, and Q. Cui, "An innovative random forest-based nonlinear ensemble paradigm of improved feature extraction and deep learning for carbon price forecasting," *Science of the Total Environment*, vol. 762, p. 143099, 2021, doi: [10.1016/j.scitotenv.2020.143099](https://doi.org/10.1016/j.scitotenv.2020.143099).
- [16] S. Jaipuria and S. Mahapatra, "A hybrid forecasting technique to deal with heteroskedastic demand in a supply chain," *Operations and Supply Chain Management: An International Journal*, vol. 14, no. 2, pp. 123–132, 2021, doi: [10.31387/oscm0450291](https://doi.org/10.31387/oscm0450291).
- [17] A. Mahmud, I. Hamilton, V. V. Gayah, and R. J. Porter, "Estimation of vmt using heteroskedastic log-linear regression models," *Transportation letters*, vol. 16, no. 4, pp. 320–329, 2024, doi: [10.1080/19427867.2023.2189802](https://doi.org/10.1080/19427867.2023.2189802).
- [18] A. Ameer, A. Berrada, and A. Emrani, "Dynamic forecasting model of a hybrid photovoltaic/gravity energy storage system for residential applications," *Energy and Buildings*, vol. 271, p. 112325, 2022, doi: [10.1016/j.enbuild.2022.112325](https://doi.org/10.1016/j.enbuild.2022.112325).
- [19] M. Ala'raj, M. Majdalawieh, and N. Nizamuddin, "Modeling and forecasting of covid-19 using a hybrid dynamic model based on seird with arima corrections," *Infectious Disease Modelling*, vol. 6, pp. 98–111, 2021, doi: [10.1016/j.idm.2020.11.007](https://doi.org/10.1016/j.idm.2020.11.007).
- [20] Q. Huang, Z. Zhou, K. Yang, and Y. Wang, "Exploiting language power for time series forecasting with exogenous variables," in *Proceedings of the ACM on Web Conference 2025*, 2025, pp. 4043–4052, doi: [10.1145/3696410.3714793](https://doi.org/10.1145/3696410.3714793).
- [21] Y. Wang, H. Wu, J. Dong, G. Qin, H. Zhang, Y. Liu, Y. Qiu, J. Wang, and M. Long, "Timexer: Empowering transformers for time series forecasting with exogenous variables," *arXiv preprint arXiv:2402.19072*, 2024.
- [22] K. G. Olivares, C. Challu, G. Marcjasz, R. Weron, and A. Dubrawski, "Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with nbeatsx," *International Journal of Forecasting*, vol. 39, no. 2, pp. 884–900, 2023, doi: [10.1016/j.ijforecast.2022.03.001](https://doi.org/10.1016/j.ijforecast.2022.03.001).
- [23] W. Song and S. Fujimura, "Capturing combination patterns of long-and short-term dependencies in multivariate time series forecasting," *Neurocomputing*, vol. 464, pp. 72–82, 2021, doi: [10.1016/j.neucom.2021.08.100](https://doi.org/10.1016/j.neucom.2021.08.100).
- [24] X. Guo, Y. Gao, Y. Li, D. Zheng, and D. Shan, "Short-term household load forecasting based on long-and short-term time-series network," *Energy Reports*, vol. 7, pp. 58–64, 2021, doi: [10.54097/fbem.v9i2.9139](https://doi.org/10.54097/fbem.v9i2.9139).
- [25] G. T. Igwama, J. A. Olaboye, C. C. Maha, M. D. Ajegbile, and S. Abdul, "Big data analytics for epidemic forecasting: Policy frameworks and technical approaches," *International Journal of Applied Research in Social Sciences*, vol. 6, no. 7, pp. 1449–1460, 2024, doi: [10.51594/ijarss.v6i7.1334](https://doi.org/10.51594/ijarss.v6i7.1334).
- [26] M. Fathi, M. Hagh Kashani, S. M. Jameii, and E. Mahdipour, "Big data analytics in weather forecasting: A systematic review," *Archives of Computational Methods in Engineering*, vol. 29, no. 2, pp. 1247–1275, 2022, doi: [10.1007/s11831-021-09616-4](https://doi.org/10.1007/s11831-021-09616-4).
- [27] C. Zhao, M. Wu, J. Liu, Z. Duan, L. Shen, X. Shangguan, D. Liu, Y. Wang et al., "Progress and prospects of data-driven stock price forecasting research," *International Journal of Cognitive Computing in Engineering*, vol. 4, pp. 100–108, 2023, doi: [10.1016/j.ijcce.2023.03.001](https://doi.org/10.1016/j.ijcce.2023.03.001).
- [28] P. H. Vuong, L. H. Phu, T. H. Van Nguyen, L. N. Duy, P. T. Bao, and T. D. Trinh, "A bibliometric literature review of stock price forecasting: from statistical model to deep learning approach," *Science Progress*, vol. 107, no. 1, p. 00368504241236557, 2024, doi: [10.1177/00368504241236557](https://doi.org/10.1177/00368504241236557).
- [29] S. Keswani, V. Puri, and R. Jha, "Relationship among macroeconomic factors and stock prices: cointegration approach from the indian stock market," *Cogent Economics & Finance*, vol. 12, no. 1, p. 2355017, 2024, doi: [10.1080/23322039.2024.2355017](https://doi.org/10.1080/23322039.2024.2355017).
- [30] Y. Zhang, J. He, M. He, and S. Li, "Geopolitical risk and stock market volatility: A global perspective," *Finance Research Letters*, vol. 53, p. 103620, 2023, doi: [10.1016/j.frl.2022.103620](https://doi.org/10.1016/j.frl.2022.103620).
- [31] Q. Guo, "The relationship between investor sentiment and stock market price," *Frontiers in Business, Economics and Management*, vol. 9, no. 2, pp. 124–129, 2023, doi: [10.54097/fbem.v9i2.9139](https://doi.org/10.54097/fbem.v9i2.9139).
- [32] H. Alabdulrazzaq, M. N. Alenezi, Y. Rawajfih, B. A. Alghannam, A. A. Al-Hassan, and F. S. Al-Anzi, "On the accuracy of arima based prediction of covid-19 spread," *Results in Physics*, vol. 27, p. 104509, 2021, doi: [10.1016/j.rinp.2021.104509](https://doi.org/10.1016/j.rinp.2021.104509).
- [33] V. Vig, "Time series forecasting using arima models: A systematic literature review of 2000s," *Computational Intelligence Applications for Software Engineering Problems*, pp. 135–152, 2023, doi: [10.1201/9781003283195-7](https://doi.org/10.1201/9781003283195-7).
- [34] S. Ma, Q. Liu, and Y. Zhang, "A prediction method of fire frequency: Based on the optimization of sarima model," *PLoS one*, vol. 16, no. 8, p. e0255857, 2021, doi: [10.1371/journal.pone.0255857](https://doi.org/10.1371/journal.pone.0255857).
- [35] N. Deretić, D. Stanimirović, M. A. Awadh, N. Vujanović, and A. Djukić, "Sarima modelling approach for forecasting of traffic accidents," *Sustainability*, vol. 14, no. 8, p. 4403, 2022, doi: [10.3390/su14084403](https://doi.org/10.3390/su14084403).
- [36] W. Sulandari, Suhartono, Subanar, and P. C. Rodrigues, "Exponential smoothing on modeling and forecasting multiple seasonal time series: An overview," *Fluctuation and Noise Letters*, vol. 20, no. 04, p. 2130003, 2021, doi: [10.1142/S0219477521300032](https://doi.org/10.1142/S0219477521300032).
- [37] M. Mirdaolivia and A. Amelia, "Metode exponential smoothing untuk fore-

- casting jumlah penduduk miskin di kota langsa,” *Jurnal Gamma-PI*, vol. 3, no. 1, pp. 47–52, 2021, doi: [10.33059/jgp.v3i1.3771](https://doi.org/10.33059/jgp.v3i1.3771).
- [38] R. Kozma, C. Alippi, Y. Choe, and F. C. Morabito, *Artificial intelligence in the age of neural networks and brain computing*. Academic Press, 2023, doi: [10.1016/C2021-0-01760-0](https://doi.org/10.1016/C2021-0-01760-0).
- [39] R. Qamar and B. A. Zardari, “Artificial neural networks: An overview,” *Mesopotamian Journal of Computer Science*, vol. 2023, pp. 124–133, 2023, doi: [10.58496/MJCSC/2023/015](https://doi.org/10.58496/MJCSC/2023/015).
- [40] R. Saleem, B. Yuan, F. Kurugollu, A. Anjum, and L. Liu, “Explaining deep neural networks: A survey on the global interpretation methods,” *Neurocomputing*, vol. 513, pp. 165–180, 2022, doi: [10.1016/j.neucom.2022.09.045](https://doi.org/10.1016/j.neucom.2022.09.045).
- [41] Z. Wang, S. Ruan, T. Huang, H. Zhou, S. Zhang, Y. Wang, L. Wang, Z. Huang, and Y. Liu, “A lightweight multi-layer perceptron for efficient multivariate time series forecasting,” *Knowledge-Based Systems*, vol. 288, p. 111463, 2024, doi: [10.1016/j.knsys.2023.111463](https://doi.org/10.1016/j.knsys.2023.111463).
- [42] O. Trisnawati and M. Prastuti, “Peramalan curah hujan di stasiun juanda menggunakan metode arima box-jenkins dan radial basis function neural network,” *Jurnal Sains dan Seni ITS*, vol. 11, no. 1, pp. D82–D88, 2022, doi: [10.12962/j23373520.v11i1.63165](https://doi.org/10.12962/j23373520.v11i1.63165).
- [43] H. Hewamalage, C. Bergmeir, and K. Bandara, “Recurrent neural networks for time series forecasting: Current status and future directions,” *International Journal of Forecasting*, vol. 37, no. 1, pp. 388–427, 2021, doi: [10.1016/j.ijforecast.2020.06.008](https://doi.org/10.1016/j.ijforecast.2020.06.008).
- [44] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, and M. Weyrich, “A survey on long short-term memory networks for time series prediction,” *Procedia Cirp*, vol. 99, pp. 650–655, 2021, doi: [10.1016/j.procir.2021.03.088](https://doi.org/10.1016/j.procir.2021.03.088).
- [45] X. Xu and Y. Zhang, “Soybean and soybean oil price forecasting through the nonlinear autoregressive neural network (narnn) and narnn with exogenous inputs (narnn-x),” *Intelligent Systems with Applications*, vol. 13, p. 200061, 2022, doi: [10.1016/j.iswa.2022.200061](https://doi.org/10.1016/j.iswa.2022.200061).
- [46] N. H. Abd Rahman, “Nonlinear autoregressive neural network for forecasting covid-19 confirmed cases in malaysia,” *Journal of Statistical Modeling & Analytics (JOSMA)*, vol. 5, no. 2, 2023, doi: [10.22452/josma.vol5no2.6](https://doi.org/10.22452/josma.vol5no2.6).
- [47] H. Carreon-Ortiz, F. Valdez, P. Melin, and O. Castillo, “Architecture optimization of a non-linear autoregressive neural networks for mackey-glass time series prediction using discrete mycorrhiza optimization algorithm,” *Micro-machines*, vol. 14, no. 1, p. 149, 2023, doi: [10.3390/mi14010149](https://doi.org/10.3390/mi14010149).
- [48] A. Wunsch, T. Liesch, and S. Broda, “Groundwater level forecasting with artificial neural networks: a comparison of long short-term memory (lstm), convolutional neural networks (cnns), and non-linear autoregressive networks with exogenous input (narx),” *Hydrology and Earth System Sciences*, vol. 25, no. 3, pp. 1671–1687, 2021, doi: [10.5194/hess-25-1671-2021](https://doi.org/10.5194/hess-25-1671-2021).
- [49] I. M. Yassin, A. Zabidi, M. K. M. Salleh, and N. E. A. Khalid, “Malaysian tourism interest forecasting using nonlinear auto-regressive (nar) model,” in *2013 IEEE 3rd International Conference on System Engineering and Technology*. IEEE, 2013, pp. 32–36, doi: [10.1109/ICSEngT.2013.6650138](https://doi.org/10.1109/ICSEngT.2013.6650138).
- [50] Y. Liu, G. Qin, X. Huang, J. Wang, and M. Long, “Autotimes: Autoregressive time series forecasters via large language models,” *Advances in Neural Information Processing Systems*, vol. 37, pp. 122 154–122 184, 2024.
- [51] A. Kozuch, D. Cywicka, and K. Adamowicz, “A comparison of artificial neural network and time series models for timber price forecasting,” *Forests*, vol. 14, no. 2, p. 177, 2023, doi: [10.3390/f14020177](https://doi.org/10.3390/f14020177).
- [52] D. M. Ahmed, M. M. Hassan, and R. J. Mstafa, “A review on deep sequential models for forecasting time series data,” *Applied Computational Intelligence and Soft Computing*, vol. 2022, no. 1, p. 6596397, 2022, doi: [10.1155/2022/6596397](https://doi.org/10.1155/2022/6596397).
- [53] S.-A. Chen, C.-L. Li, N. Yoder, S. O. Arik, and T. Pfister, “Tsmixer: An all-mlp architecture for time series forecasting,” *arXiv preprint arXiv:2303.06053*, 2023.
- [54] P. Sohrabi, B. Jodeiri Shokri, and H. Dehghani, “Predicting coal price using time series methods and combination of radial basis function (rbf) neural network with time series,” *Mineral Economics*, vol. 36, no. 2, pp. 207–216, 2023, doi: [10.1007/s13563-021-00286-z](https://doi.org/10.1007/s13563-021-00286-z).
- [55] J. Wang, X. Li, J. Li, Q. Sun, and H. Wang, “Ngcu: A new rnn model for time-series data prediction,” *Big Data Research*, vol. 27, p. 100296, 2022, doi: [10.1016/j.bdr.2021.100296](https://doi.org/10.1016/j.bdr.2021.100296).
- [56] K. W. Yee and H. B. Samsudin, “Comparison between artificial neural network and arima model in forecasting palm oil price in malaysia,” *International Journal of Scientific Engineering and Science*, vol. 5, no. 11, pp. 12–15, 2021.
- [57] M. Melina, S. Sukono, H. Napitupulu, N. Mohamed, Y. H. Chrisnanto, A. I. Hadiana, V. A. Kusumaningtyas, and U. Nabilla, “Comparative analysis of time series forecasting models using arima and neural network autoregression methods,” *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 18, no. 4, pp. 2563–2576, 2024, doi: [10.30598/barekengvol18iss4pp2563-2576](https://doi.org/10.30598/barekengvol18iss4pp2563-2576).
- [58] İ. Kirbaş, A. Sözen, A. D. Tuncer, and F. Ş. Kazancıoğlu, “Comparative analysis and forecasting of covid-19 cases in various european countries with arima, narnn and lstm approaches,” *Chaos, Solitons & Fractals*, vol. 138, p. 110015, 2020, doi: [10.1016/j.chaos.2020.110015](https://doi.org/10.1016/j.chaos.2020.110015).
- [59] I. G. A. D. Aryawangsa, N. L. P. A. Diantini, P. P. G. Pertama, and P. A. G. Permana, “Analisis pengaruh rasio keuangan perbankan terhadap harga saham menggunakan algoritma random forest,” *Jurnal Teknik Informatika dan Sistem Informasi (JATISI)*, vol. 12, no. 2, pp. 140–152, June 2025.