

## Model Hybrid Fuzzy Logic dan Deep Learning untuk Prediksi Harga Saham

Asep Muhidin<sup>1</sup>, Elkin Rilvani<sup>1</sup>, Candra Naya<sup>1</sup>

<sup>1</sup> Program Studi Informatika, Universitas Pelita Bangsa, Indonesia

\* Correspondence: asepmuhidin@pelitabangsa.ac.id

**Copyright:** © 2025 by the authors

Received: 16 Juni 2025 | Revised: 22 Juni 2025 | Accepted: 30 Juli 2025 | Published: 15 Agustus 2025

### Abstrak

Prediksi harga saham merupakan tantangan dalam bidang keuangan karena dipengaruhi oleh faktor-faktor nonlinier dan ketidakpastian data. Penelitian ini bertujuan mengembangkan model prediksi berbasis *deep learning* yang terintegrasi dengan logika *fuzzy* untuk meningkatkan akurasi dan ketahanan terhadap *noise*. Jenis penelitian ini adalah kuantitatif eksperimental. Data yang digunakan adalah harga saham harian Bank Central Asia (BBCA) sebanyak 1.000 data historis, dikumpulkan melalui *scraping* dari sumber publik. Data dianalisis dengan tiga model jaringan saraf yaitu *Recurrent Neural Network (RNN)*, *Long Short-Term Memory (LSTM)*, dan *Gated Recurrent Unit (GRU)*, baik sebelum maupun sesudah integrasi *fuzzy*. Fuzzifikasi dilakukan pada data harga untuk menghasilkan fitur linguistik sebagai input tambahan ke dalam model. Evaluasi dilakukan menggunakan metrik *Train Cost*, *Test Cost*, dan jumlah *epoch*, serta uji t-test untuk mengukur signifikansi performa. Hasil temuan kami menunjukkan bahwa model LSTM dengan input *fuzzy* memiliki performa terbaik, dengan *Train Cost* 0,0002 dan *Test Cost* 0,0052, serta mampu mengelola *long-term dependencies* secara lebih stabil. Sebaliknya, RNN dan GRU menunjukkan penurunan akurasi setelah integrasi *fuzzy*. Model kombinasi *fuzzy* dan LSTM ini berpotensi diterapkan pada analisis deret waktu lain dalam konteks data tidak pasti.

**Kata kunci:** *deep learning*; *gru*; logika fuzzy; *lstm*; prediksi harga saham

### Abstract

*Stock price prediction is a major challenge in the financial sector due to nonlinear factors and data uncertainty. This study aims to develop a predictive model by integrating fuzzy logic into deep learning algorithms to improve accuracy and robustness against noise. This is a quantitative experimental study using 1,000 daily historical stock price data of BBCA (Bank Central Asia), collected via web scraping from public sources. The data were analyzed using three types of neural networks: Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), and Gated Recurrent Unit (GRU), both before and after fuzzy integration. Fuzzification was applied to the price data to generate linguistic features, which were added as input to the neural network models. The models were evaluated using Train Cost, Test Cost, and the number of epochs, and a t-test was conducted to assess the statistical significance of performance differences. Our findings show that the LSTM model with fuzzy input achieved the best performance, with a Train Cost of 0.0002 and a Test Cost of 0.0052, and demonstrated superior capability in handling long-term dependencies. In contrast, RNN and GRU models showed decreased accuracy after fuzzy integration. The combining fuzzy and LSTM model shows promise for broader applications in time-series forecasting under uncertainty.*

**Keywords:** *deep learning*; *gru*; fuzzy logic; *lstm*; stock price prediction

## PENDAHULUAN

Pasar saham merupakan komponen vital dalam sistem keuangan yang berperan penting dalam mendukung pertumbuhan ekonomi. Namun, harga saham sangat dinamis dan



dipengaruhi oleh berbagai faktor seperti kondisi makroekonomi, sentimen pasar, serta karakteristik data yang tidak stasioner (Patsiarikas et al., 2025). Kompleksitas ini membuat prediksi harga saham menjadi tantangan tersendiri, karena fluktuasinya sering kali tidak mengikuti pola linier yang dapat dijelaskan secara deterministik (Shetty & Ismail, 2023).

Beberapa penelitian sebelumnya yang menggunakan metode kecerdasan buatan, khususnya *machine learning* dan *deep learning* telah menunjukkan potensi yang besar dalam domain prediksi harga saham. Model-model seperti *Recurrent Neural Network* (RNN), *Long Short-Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU) secara khusus dirancang untuk menangani data deret waktu melalui mekanisme pemrosesan sekuensial (Perumal et al., 2024). RNN merupakan arsitektur dasar yang mampu mengenali urutan data, tetapi sering kali mengalami kesulitan dalam menangkap ketergantungan jangka panjang karena masalah *vanishing gradient* (Pascanu et al., 2013). Untuk mengatasi keterbatasan ini, LSTM diperkenalkan dengan mekanisme *gating* yang memungkinkan penyimpanan informasi lebih lama (Susetyo et al., 2025), sedangkan GRU hadir sebagai versi yang lebih ringan secara komputasi namun tetap efektif dalam memahami konteks temporal (Chen et al., 2023).

Meskipun efektif dalam menangkap pola eksplisit dalam data, model-model *deep learning* tersebut memiliki keterbatasan dalam mengelola ketidakpastian, *noise*, dan ambiguitas yang sering muncul dalam data pasar saham. Model *deep learning* cenderung bekerja optimal pada data numerik yang memiliki struktur jelas, namun kurang tangguh dalam menginterpretasi informasi kualitatif atau subjektif yang tidak sepenuhnya terdefiniskan secara matematis. Oleh karena itu, diperlukan pendekatan tambahan yang mampu menangkap dimensi ketidakpastian tersebut.

Logika *fuzzy* merupakan salah satu metode yang dikenal efektif dalam mengatasi ambiguitas dan ketidakpastian data (Kuncoro, 2024; Nurhasanah et al., 2025; Ramazani et al., 2025; Trisely et al., 2023). Dengan melakukan proses fuzzifikasi, data numerik dapat direpresentasikan dalam bentuk linguistik (Rusadi, 2025) seperti "rendah", "sedang", atau "tinggi", sehingga memberikan makna semantik yang lebih kaya sebelum diproses oleh model prediktif. Proses ini dapat dianggap sebagai teknik *soft feature engineering* yang berfungsi memperkaya representasi input, terutama ketika diintegrasikan dengan model sekuensial seperti RNN, LSTM, atau GRU (Pattanayak et al., 2022). Beberapa studi sebelumnya menunjukkan bahwa kombinasi antara *fuzzy logic* dan *deep learning* dapat meningkatkan akurasi prediksi dalam berbagai domain, seperti peramalan cuaca, sistem kendali, dan analisis kesehatan (Abdulwahid, 2025).

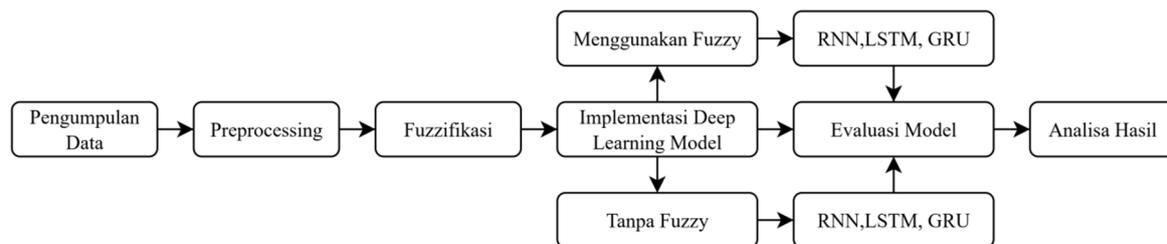
Namun demikian, kajian mengenai integrasi *fuzzy logic* dengan berbagai arsitektur *deep learning* dalam konteks prediksi harga saham masih terbatas. Studi oleh Wang et al. (2023) telah mengembangkan model fuzzy dan LSTM untuk peramalan jangka panjang, namun belum membandingkan performanya dengan arsitektur lain serta belum mengevaluasi pengaruh integrasi *fuzzy* terhadap kemampuan generalisasi model. Penelitian oleh Atmawanti et al. (2024) membandingkan metode *Fuzzy Time Series Markov Chain* dengan metode *Cheng* pada data harga saham BCA, tetapi belum melibatkan pendekatan *deep learning* yang lebih modern.

Sebagian besar penelitian sebelumnya hanya berfokus pada satu jenis *model deep learning* (LSTM), dan belum mengkaji secara sistematis perbandingan kinerja berbagai arsitektur seperti RNN, LSTM, dan GRU baik dalam bentuk murni maupun dalam kombinasi dengan *fuzzy logic*. Selain itu, kontribusi nyata dari proses fuzzifikasi terhadap peningkatan akurasi dan generalisasi model prediktif belum banyak dieksplorasi secara empiris, khususnya dalam konteks pasar saham Indonesia yang memiliki karakteristik tersendiri. Sedangkan pada penelitian ini bertujuan untuk mengevaluasi secara komparatif performa model RNN, LSTM, dan GRU dengan dan tanpa integrasi logika *fuzzy* dalam konteks prediksi harga saham di Indonesia, serta menganalisis kontribusi *fuzzy* terhadap peningkatan akurasi dan generalisasi model. Implikasi dari penelitian ini diharapkan dapat memberikan kontribusi dalam

pengembangan sistem prediksi saham yang lebih adaptif, akurat, dan mampu mengakomodasi ketidakpastian pasar secara lebih efektif.

## METODE

Pada penelitian ini digunakan enam tahapan utama dalam proses pengembangan model prediksi harga saham berbasis integrasi logika *fuzzy* dan *deep learning*. Lima tahapan tersebut meliputi: Pengumpulan data, Pra-pemrosesan, fuzzifikasi, Implementasi model *deep learning* menggunakan arsitektur (RNN, LSTM, GRU), Evaluasi model, Analisis hasil dari model *deep learning* dengan dan tanpa kombinasi *fuzzy*.



**Gambar 1.** Tahapan Penelitian

Pada gambar 1, tahapan penelitian dimulai dengan pengumpulan data historis harga penutupan harian saham BBCA dari *Yahoo Finance*, mencakup periode 8 Juni 2004 hingga 30 Desember 2024. Pemilihan BBCA didasarkan pada likuiditas tinggi dan stabilitas harga. Data kemudian melalui proses pra-pemrosesan yang meliputi penanganan *missing values*, normalisasi menggunakan *Min-Max Scaling*, dan pembentukan *time-series* dengan *teknik sliding window*. Selanjutnya dilakukan proses fuzzifikasi, yakni transformasi data numerik menjadi representasi *linguistik* (rendah, sedang, tinggi) menggunakan fungsi keanggotaan segitiga, untuk menangkap ketidakpastian dalam data. Data hasil normalisasi dan fuzzifikasi digunakan sebagai input ke dalam tiga arsitektur model *deep learning*: RNN, LSTM, dan GRU. Masing-masing model dilatih dalam dua skenario, yaitu dengan dan tanpa fuzzy, menggunakan pustaka *PyTorch*, fungsi aktivasi *ReLU*, *loss MSE*, *optimizer Adam*, serta mekanisme *early stopping*. Evaluasi dilakukan dengan membandingkan hasil pelatihan dan pengujian model. Parameter evaluasi yang digunakan adalah *Train Cost* dan *Test Cost*, yaitu nilai MSE pada data latih dan data uji. Selain itu, jumlah *epoch* hingga model mencapai konvergensi juga dicatat untuk menilai efisiensi pelatihan. Perbandingan performa dilakukan pada seluruh kombinasi model (RNN, LSTM, GRU) dan kondisi input (*fuzzy* dan *non-fuzzy*).

## HASIL DAN PEMBAHASAN

### Hasil

Eksperimen dalam penelitian ini dilakukan dengan menggunakan data historis harga saham harian dari emiten Bank Central Asia (BBCA) sebagai objek studi. Data dikumpulkan melalui pustaka *yfinance* yang terhubung dengan sumber *Yahoo Finance*, yang menyediakan data pasar saham. Dari proses tersebut, diperoleh total sebanyak 5.086 data harian yang mencakup periode panjang, yakni dari tanggal 8 Juni 2004 hingga 30 Desember 2024.

Dataset yang digunakan dalam penelitian ini terdiri dari enam atribut utama yang merepresentasikan karakteristik fundamental dari perdagangan saham harian emiten BBCA. Setiap atribut memiliki peran tersendiri dalam menggambarkan dinamika pergerakan harga dalam suatu periode waktu yang ditentukan, sehingga memberikan gambaran mendalam tentang perilaku pasar saham terkait.

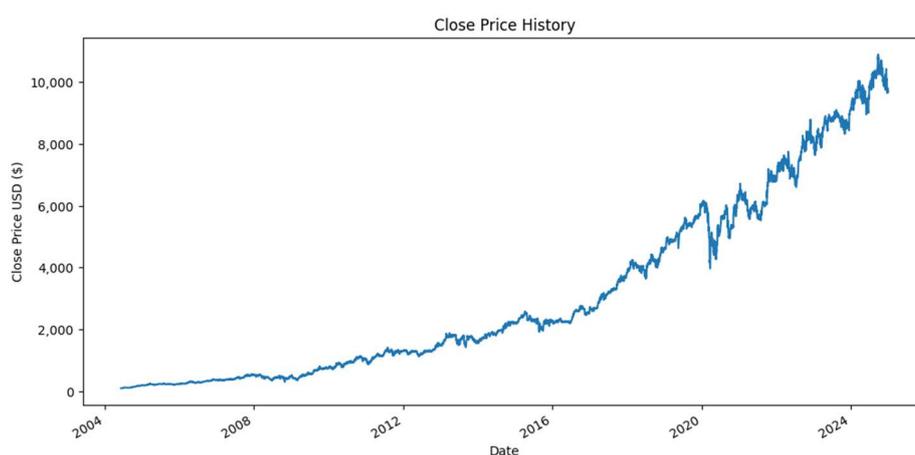
**Tabel 1.** Dataset saham bca

<i>Date</i>	<i>Close</i>	<i>High</i>	<i>Low</i>	<i>Open</i>	<i>Volume</i>
6/8/2004	102.76	104.21	101.32	101.32	499,150,000.00
6/9/2004	104.21	105.66	101.32	102.76	294,290,000.00
6/10/2004	104.21	104.21	102.76	104.21	165,590,000.00
6/11/2004	104.21	104.21	102.76	102.76	135,830,000.00
6/14/2004	102.76	104.21	101.32	104.21	158,540,000.00

**Tabel 2.** Deskripsi saham bca

<b>Kolom</b>	<b>Deskripsi kolom</b>
<i>Date</i>	Tanggal data dicatat, menunjukkan kapan harga saham tersebut berlaku.
<i>Close</i>	Harga penutupan saham, yaitu harga terakhir saham pada akhir sesi perdagangan hari itu.
<i>High</i>	Harga tertinggi saham pada hari tersebut, yaitu harga tertinggi yang dicapai selama sesi perdagangan.
<i>Low</i>	Harga terendah saham pada hari itu, yaitu harga terendah yang dicapai selama sesi perdagangan.
<i>Open</i>	Harga pembukaan saham, yaitu harga pertama yang diperdagangkan di awal sesi perdagangan hari itu.
<i>Volume</i>	Jumlah total saham yang diperdagangkan selama hari tersebut. Volume tinggi menunjukkan banyaknya transaksi yang terjadi dan bisa menjadi indikator likuiditas serta minat investor terhadap saham tersebut.

Pada penelitian ini, harga penutupan (*close*) dipilih sebagai variabel utama yang akan diprediksi oleh model. Pemilihan ini didasarkan pada pertimbangan bahwa harga penutupan secara umum dianggap sebagai representasi paling akurat dari nilai riil suatu saham pada akhir sesi perdagangan. Harga ini mencerminkan hasil akhir dari aktivitas pasar sepanjang hari dan sering menjadi acuan utama dalam analisis teknikal maupun fundamental.


**Gambar 2.** Harga penutupan saham bca

Gambar 2 menunjukkan tren harga penutupan saham BCA dari tahun 2004 hingga 2024 yang secara umum mengalami peningkatan signifikan, meskipun tetap disertai fluktuasi pada periode tertentu. Pola ini mencerminkan volatilitas pasar dan menjadi dasar penting bagi penerapan model prediksi yang mampu menangkap dinamika jangka panjang. Fluktuasi harga juga menegaskan perlunya pendekatan adaptif seperti integrasi logika *fuzzy* dalam mengatasi ketidakpastian data.

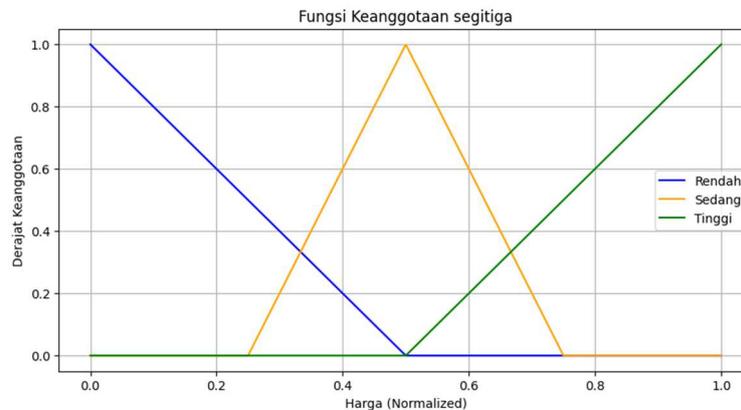
Sebelum digunakan dalam pelatihan model, data diperiksa dan tidak ditemukan *missing value*, outlier ekstrem, atau anomali signifikan, sehingga tidak diperlukan pembersihan tambahan. Data harga penutupan (*Close*) kemudian dinormalisasi ke rentang [0,1] menggunakan *MinMaxScaler* untuk menyamakan skala fitur, guna meningkatkan efisiensi dan kestabilan proses pelatihan model.

**Tabel 3.** Hasil normalisasi data penutupan (*close*)

<i>Date</i>	<i>Close</i>	<i>Close_Scl</i>
6/8/2004	102.76	0.00000
6/9/2004	104.21	0.00013
6/10/2004	104.21	0.00013
6/11/2004	104.21	0.00013
6/14/2004	102.76	0.00000

Tabel 3 menyajikan hasil normalisasi harga penutupan saham BBCA menggunakan teknik skala minimum–maksimum. Nilai *Close\_Scl* merepresentasikan versi berskala dari kolom *close*, dengan rentang antara 0 dan 1. Proses normalisasi ini bertujuan untuk menyamakan skala data agar sesuai dengan kebutuhan pemrosesan pada model deep learning, serta mencegah dominasi fitur tertentu.

Proses selanjutnya dalam pengolahan data adalah tahap fuzzifikasi, yaitu mengubah nilai-nilai numerik pada dataset menjadi representasi linguistik. Representasi ini menggunakan istilah seperti “rendah”, “sedang”, dan “tinggi” untuk menggambarkan rentang nilai tertentu secara lebih interpretatif. Transformasi dilakukan dengan memanfaatkan fungsi keanggotaan segitiga (*triangular membership function*).



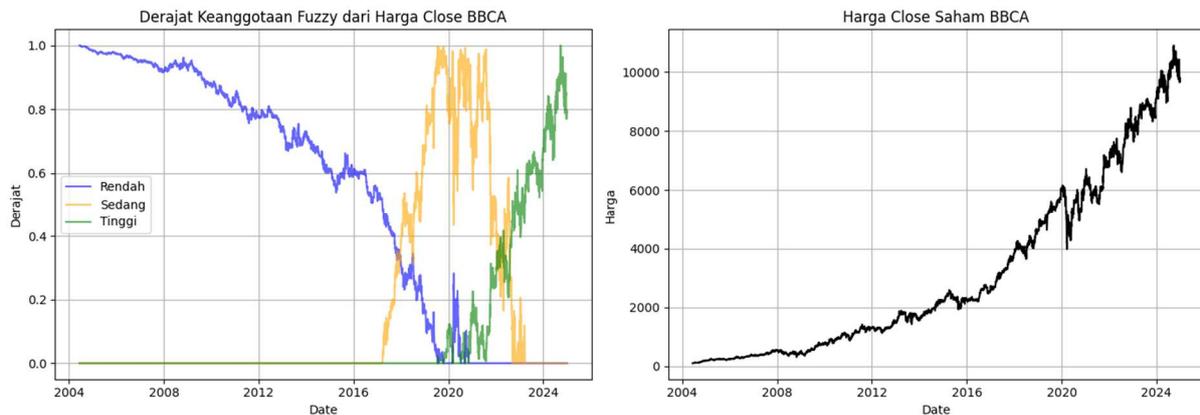
**Gambar 3.** Fungsi keanggotaan fuzzy

Gambar 3 menunjukkan fungsi keanggotaan segitiga (*triangular membership function*) yang digunakan dalam proses fuzzyfikasi data harga penutupan saham. Domain input telah dinormalisasi pada rentang 0 hingga 1, dan dibagi ke dalam tiga kategori linguistik, yaitu rendah, sedang, dan tinggi. Berdasarkan fungsi keanggotaan tersebut digunakan untuk menghitung derajat keanggotaan setiap pergerakan nilai harga penutupan.

Gambar 4 memperlihatkan hasil transformasi *fuzzy* terhadap data harga penutupan saham BBCA. Grafik sebelah kiri menunjukkan derajat keanggotaan fuzzy untuk kategori rendah, sedang, dan tinggi berdasarkan nilai yang telah dinormalisasi. Grafik di sebelah kanan menampilkan harga penutupan aktual BBCA, yang menguat secara signifikan dalam jangka panjang. Pola ini menegaskan bahwa proses fuzzyfikasi berhasil merepresentasikan dinamika

harga secara linguistik, sekaligus menunjukkan transisi nilai saham dari kategori rendah ke tinggi secara bertahap.

Data hasil normalisasi dan fuzzyfikasi digunakan sebagai input untuk membangun tiga *model deep learning* yaitu RNN, LSTM dan GRU. Dataset dibagi menjadi data training sebanyak 4.068 dan data testing 1.018 data. Kemudian data disusun dalam bentuk *time series sliding window (data loader)* di mana 10 hari berturut-turut digunakan sebagai input untuk memprediksi harga pada hari ke-11 dan seterusnya.



**Gambar 4.** Perbandingan harga penutupan sebelum dan sesudah fuzzifikasi

**Tabel 4.** Pembagian data *training-testing (data loader)*

<b>Dataset</b>	<b>N</b>	<b>S</b>	<b>F</b>
<i>Training</i>	406	10	1
<i>Testing</i>	101	10	1

Tabel 4 menunjukkan pembagian data menggunakan skema data loader, dengan 406 sampel untuk pelatihan dan 101 untuk pengujian. Parameter N, S, dan F masing-masing menunjukkan *window size*, *stride*, dan jumlah fitur input. Untuk menjaga keadilan komparasi, seluruh model (RNN, LSTM, GRU) dikonfigurasi dengan parameter yang sama, seperti *sequence length*, *batch size*, *hidden size*, jumlah *layer*, *dropout*, dan *learning rate*, sehingga evaluasi difokuskan pada perbedaan arsitektur, bukan hyperparameter.

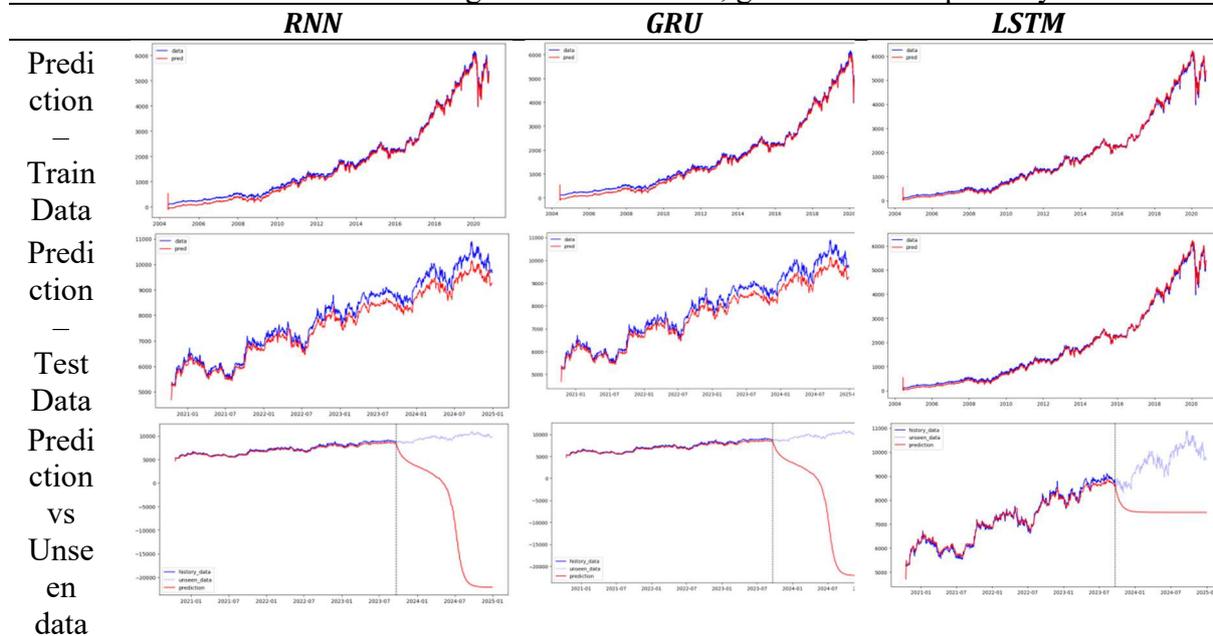
**Tabel 5.** Konfigurasi parameter model (rnn, lstm, gru)

<b>Parameter</b>	<b>Nilai</b>
<i>Input size</i>	1
<i>Sequence len</i>	10
<i>Batch size</i>	16
<i>Output size</i>	1
<i>Hidden size</i>	32
<i>Number layer</i>	2
<i>dropout</i>	0.2
<i>Learning rate</i>	0.0001

Tabel 5 menyajikan konfigurasi parameter utama yang diterapkan secara konsisten pada seluruh model RNN, LSTM, dan GRU untuk memastikan perbandingan performa yang adil. Parameter *input\_size* = 1 dan *output\_size* = 1 menunjukkan penggunaan satu fitur input (harga penutupan yang telah difuzzyfikasi) dan satu keluaran prediksi. Panjang sekuens (*sequence\_len*) ditetapkan sebanyak 10 data historis, sedangkan *hidden\_size* = 32 dan

number\_layer = 2 digunakan untuk membentuk arsitektur jaringan yang cukup dalam namun tetap efisien. Nilai dropout = 0.2 ditambahkan untuk mengurangi risiko overfitting, dan learning rate diatur sebesar 0.0001 untuk stabilitas pelatihan. Pelatihan model dilakukan menggunakan library PyTorch, dengan fungsi aktivasi ReLU, fungsi loss MSE (Mean Squared Error), dan optimizer Adam yang secara umum efektif dalam tugas regresi deret waktu.

**Tabel 6.** Perbandingan hasil model rnn, gru dan lstm tanpa fuzzy



**Tabel 7.** Hasil training dan testing model

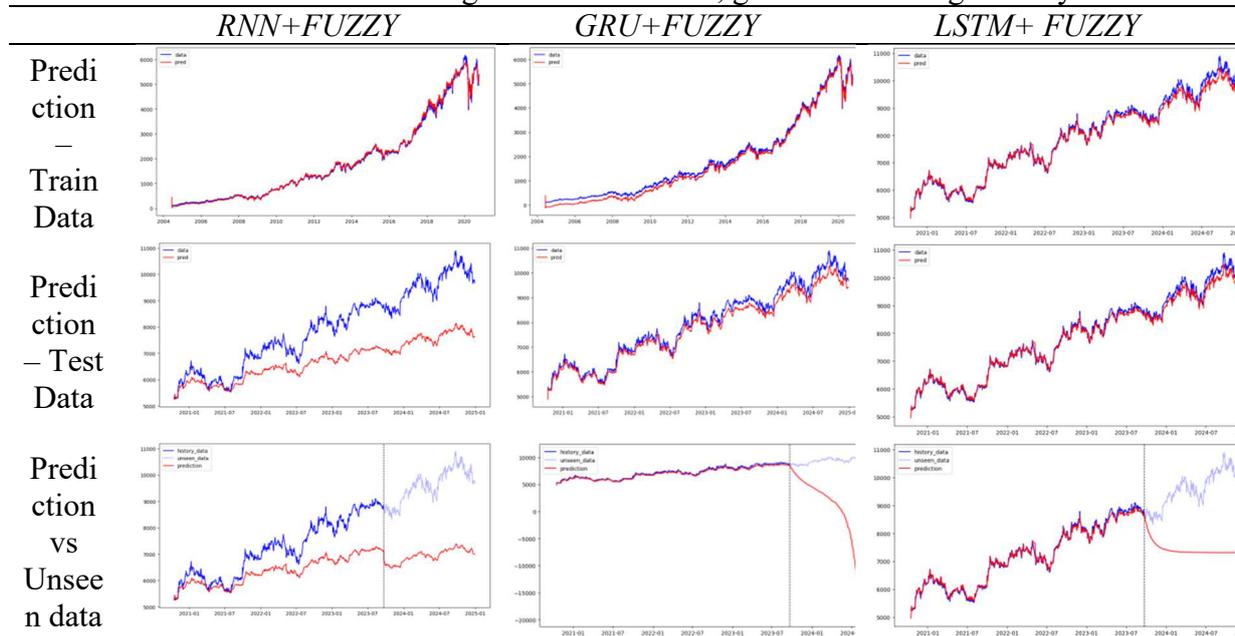
Model	Train Cost	Test Cost	Epochs
RNN	0,0003	0,0009	264
LSTM	0,0003	0,0016	303
GRU	0,0003	0,0016	282

Tabel 6 memperlihatkan hasil prediksi dari tiga model deep learning RNN, GRU, dan LSTM terhadap data harga saham BBCA tanpa integrasi logika fuzzy. Baris pertama menunjukkan performa model pada data pelatihan, di mana ketiganya mampu mengikuti tren historis dengan cukup baik. Namun, perbedaan mulai terlihat pada baris kedua dan ketiga, yang menampilkan prediksi terhadap data uji dan data yang belum pernah dilihat (unseen), model LSTM terlihat lebih stabil dalam mempertahankan tren jangka panjang. Temuan ini diperkuat oleh data kuantitatif pada Tabel 7, yang menunjukkan bahwa meskipun RNN memiliki Test Cost paling rendah (0,0009), LSTM tetap memberikan visualisasi prediksi yang lebih halus dan realistis. Dengan Train Cost yang sama (0,0003) namun epoch pelatihan lebih banyak (303), LSTM menunjukkan kapasitas lebih baik dalam menangkap long-term dependencies, yang penting dalam konteks deret waktu harga saham.

Tabel 8 menyajikan visualisasi hasil prediksi dari tiga model RNN, GRU, dan LSTM setelah integrasi dengan logika fuzzy. Seperti pada skenario sebelumnya, grafik dibagi ke dalam tiga baris yang masing-masing merepresentasikan hasil pada data pelatihan, data pengujian, dan data yang belum pernah dilihat (unseen). Dalam skenario berbasis fuzzy ini, model LSTM menunjukkan performa yang paling unggul secara keseluruhan. Sementara itu, pada tabel 9 menunjukkan bahwa LSTM memiliki performa terbaik dalam pelatihan model berbasis fuzzy, dengan Test Cost terendah (0.0052), Train Cost 0.0002, dan konvergensi pada 351 epoch. RNN menunjukkan kesulitan dengan Test Cost tertinggi (0.0239), sedangkan GRU berada di tengah

dengan Test Cost 0.0145 dan konvergensi pada 220 epoch. Hasil ini menegaskan bahwa LSTM paling adaptif dalam menangani data fuzzy untuk prediksi deret waktu.

**Tabel 8.** Perbandingan hasil model rnn, gru dan lstm dengan fuzzy



**Tabel 9.** Hasil *training model* dengan fuzzy

Model	Train Cost	Test Cost	Epochs
RNN	0.0004	0.0239	200
LSTM	0.0002	0.0052	351
GRU	0.0003	0.0145	220

**Pembahasan**

Hasil penelitian menunjukkan bahwa pada skenario tanpa *integrasi fuzzy logic*, model RNN) menunjukkan performa terbaik dengan nilai *Test Cost* terendah sebesar 0.0009, dibandingkan LSTM dan GRU. Hal ini menunjukkan bahwa RNN cukup efektif dalam mengenali pola data historis yang relatif sederhana dan memiliki dependensi jangka pendek. Temuan ini sejalan dengan penelitian (Haryono et al., 2024), yang menyebutkan bahwa model RNN memberikan hasil prediksi yang baik pada data saham di Bursa Efek Indonesia, terutama ketika pola datanya cukup terstruktur dan tidak mengandung ambiguitas tinggi. Namun, ketika model diuji dengan input data hasil fuzzifikasi, performa model berubah signifikan. Model *Long Short-Term Memory* (LSTM) muncul sebagai model dengan performa terbaik dengan nilai *Test Cost* sebesar 0.0052, mengungguli RNN dan GRU. Fuzzy logic dalam hal ini mengubah domain numerik menjadi representasi linguistik seperti “rendah”, “sedang”, dan “tinggi”, yang memperkenalkan ketidakpastian dan konteks semantik dalam data. Transformasi ini memerlukan model dengan kapasitas memori dan pemrosesan konteks yang lebih kuat. LSTM, dengan kemampuannya menangani dependensi jangka panjang dan mempertahankan informasi melalui mekanisme *gate*, lebih unggul dalam memahami struktur semantik ini. Hasil ini menunjukkan bahwa LSTM memiliki ketahanan yang lebih baik terhadap data yang telah mengalami proses fuzzifikasi, di mana terdapat unsur ketidakpastian dan representasi linguistik. Hal ini selaras dengan temuan (Nasiri & Ebadzadeh, 2023), yang menerapkan metode *Fuzzy Time Series* dalam prediksi harga dan menunjukkan bahwa pendekatan *fuzzy* lebih cocok dikombinasikan dengan model yang mampu menangani dependensi jangka panjang seperti LSTM.

Hasil penelitian ini menunjukkan bahwa model LSTM memberikan performa paling unggul dalam skenario prediksi harga saham berbasis data *fuzzy*, dengan *Test Cost* terendah dan stabilitas prediksi terbaik dibandingkan RNN dan GRU. Temuan ini sejalan dengan penelitian oleh Kallimath et al., (2025) yang juga mencatat keunggulan LSTM dalam memprediksi indeks saham Nifty 50, meskipun memerlukan waktu pelatihan lebih lama dan rentan terhadap *overfitting* pada data yang sangat fluktuatif. Sementara itu, performa GRU dalam studi ini menunjukkan hasil menengah lebih baik dari RNN namun belum melampaui LSTM yang juga mendukung karakteristik GRU sebagaimana dijelaskan oleh Kallimath et al. sebagai model yang efisien namun kurang optimal dalam menangani kompleksitas data yang tinggi. Selain itu, hasil ini memperkuat tinjauan sistematis oleh Seok et al. (2024) dan penelitian empiris oleh Lin & Hsu (2023), yang menyatakan bahwa integrasi *fuzzy logic* dengan *deep learning* dapat meningkatkan akurasi prediksi dalam domain yang mengandung ketidakpastian tinggi, seperti pasar saham.

Secara implisit, hasil temuan ini menegaskan bahwa pendekatan *hybrid fuzzy LSTM* sangat potensial untuk menangani data time-series yang bersifat ambigu dan tidak deterministik. Implikasi dari temuan ini membuka peluang penerapan lebih luas pada sistem pendukung keputusan berbasis kecerdasan buatan dalam sektor finansial yang membutuhkan ketahanan terhadap noise dan ketidakpastian.

## SIMPULAN

Penelitian ini menunjukkan bahwa integrasi logika fuzzy dalam deep learning meningkatkan akurasi prediksi harga saham pada data yang mengandung ketidakpastian. Model RNN unggul pada data *non-fuzzy* (*Test Cost* 0.0009) namun menurun pada data fuzzy, sedangkan LSTM memberikan hasil terbaik pada kondisi fuzzy (*Test Cost* 0.0052; *Train Cost* 0.0002) berkat kemampuannya memahami data linguistik dan pola jangka panjang. GRU cukup baik (*Test Cost* 0.0145) namun masih di bawah LSTM. Pendekatan hybrid fuzzy-LSTM direkomendasikan untuk pengembangan lanjutan melalui optimalisasi hyperparameter, regularisasi, pengujian lintas sektor saham, serta penambahan variabel eksogen seperti sentimen media dan indikator makroekonomi untuk memperkaya konteks data.

## REFERENSI

- Abdulwahid, A. H. (2025). IoT-Based Hybrid Fuzzy LSTM-RNN for Secure Disease Prediction in Healthcare EHRs. *Journal of Information Systems Engineering and Management*, 10(36s), 339–356. <https://doi.org/10.52783/jisem.v10i36s.6438>
- Atmawanti, I. I., Hakim, A. R., & Tarno, T. (2024). Perbandingan Fuzzy Time Series Markov Chain Dan Fuzzy Time Series Cheng. *Jurnal Gaussian*, 13(1), 121-132. <https://doi.org/10.14710/j.gauss.13.1.121-132>
- Chen, C., Xue, L., & Xing, W. (2023). Research on Improved GRU-Based Stock Price Prediction Method. *Applied Sciences (Switzerland)*, 13(15). <https://doi.org/10.3390/app13158813>
- Haryono, A. T., Sarno, R., & Sungkono, K. R. (2024). Stock price forecasting in Indonesia stock exchange using deep learning: A comparative study. *International Journal of Electrical and Computer Engineering*, 14(1), 861–869. <https://doi.org/10.11591/ijece.v14i1.pp861-869>
- Kallimath, S. P., Darapaneni, N., & Paduri, A. R. (2025). Deep Learning Approaches for Stock Price Prediction A Comparative Study on Nifty 50 Dataset. *EAI Endorsed Transactions on Intelligent Systems and Machine Learning Applications*, 1, 1–13. <https://doi.org/10.4108/eetismmla.7481>
- Kuncoro, D. F. (2024). Penerapan Logika Fuzzy dalam Penanganan Penyakit Diabetes: Sistematis Literatur Review. *Jurnal Kolaborasi Riset Sarjana*, 1(1), 1-14.

- Lin, H. Y., & Hsu, B. W. (2024). Application of hybrid fuzzy interval-based machine learning models on financial time series—A case study of Taiwan biotech index during the epidemic period. *Frontiers in Artificial Intelligence*, 6, 1283741. <https://doi.org/10.3389/frai.2023.1283741>
- Nasiri, H., & Ebadzadeh, M. M. (2023). Multi-step-ahead stock price prediction using recurrent fuzzy neural network and variational mode decomposition. *Applied Soft Computing*, 148, 110867. <https://doi.org/10.1016/j.asoc.2023.110867>
- Nurhasanah, Y. I., Kurnia, E., & Sutarti, S. (2025). Integrasi Logika Fuzzy dengan Teknologi Cerdas: Tinjauan Sistematis atas Peluang, Tantangan, dan Arah Masa Depan. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 10(1), 1-17.
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013, May). On the difficulty of training recurrent neural networks. *International conference on machine learning*, 1310-1318. PMLR.
- Patsiarikas, M., Papageorgiou, G., & Tjortjis, C. (2025). Using Machine Learning on Macroeconomic, Technical, and Sentiment Indicators for Stock Market Forecasting. *Information*, 16(7), 1–41. <https://doi.org/10.3390/info16070584>
- Pattanayak, R. M., Sangameswar, M. V., Vodnala, D., & Das, H. (2022). *Fuzzy Time Series Forecasting Approach using LSTM Model*. *Computacion y Sistemas*, 26(1), 485–492. <https://doi.org/10.13053/CyS-26-1-4192>
- Perumal, T., Mustapha, N., Mohamed, R., & Shiri, F. M. (2024). A Comprehensive Overview and Comparative Analysis on Deep Learning Models. *Journal on Artificial Intelligence*, 6(1), 301–360. <https://doi.org/10.32604/jai.2024.054314>
- Ramazani, A., Fuadi, W., & Meiyanti, R. (2025). Prediksi Jumlah Kebutuhan Pemakaian Air Menggunakan Metode Fuzzy Time Series Pada Perumda Aceh Utara. *Jurnal Ilmiah ILKOMINFO-Ilmu Komputer & Informatika*, 8(2), 200-209. <https://doi.org/10.47324/ilkominfo.v8i2.360>
- Rusadi, A., Ula, M., Daud, M., Nurdin, N., & Hasibuan, A. (2025). Comparison of the Performance of Fuzzy Tsukamoto and Fuzzy Mamdani in an Internet of Things Based Grape Greenhouse Control System. *Journal of Artificial Intelligence and Software Engineering*, 5(2), 540-551.
- Seok, S., Cho, H., & Ryu, D. (2024). Dual effects of investor sentiment and uncertainty in financial markets. *The Quarterly Review of Economics and Finance*, 95, 300-315. <https://doi.org/10.1016/j.qref.2024.04.006>
- Shetty, D. K., & Ismail, B. (2023). Forecasting stock prices using hybrid non-stationary time series model with ERNN. *Communications in Statistics: Simulation and Computation*, 52(3), 1026–1040. <https://doi.org/10.1080/03610918.2021.1872631>
- Susetyo, Y. A., Parhusip, H. A., Trihandaru, S., & Susanto, B. (2025). LSTM-IOT (LSTM-based IoT) untuk Mengatasi Kehilangan Data Akibat Kegagalan Koneksi. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 12(1), 175-186. <https://doi.org/10.25126/jtiik.2025129157>
- Trisely, T. L., Saputra, R. A., & Arsyad, R. J. (2023). Metode Fuzzy Tsukamoto Digunakan Untuk Memprediksi Jumlah Produksi Sabun Cuci Piring Surya Lemon. *EJECTS: Journal Computer, Technology, and Informations System*, 3(1), 31-37.
- Wang, W., Shao, J., & Jumahong, H. (2023). Fuzzy inference-based LSTM for long-term time series prediction. *Scientific Reports*, 13(1), 20359. <https://doi.org/10.1038/s41598-023-47812-3>