

**PERBANDINGAN METODE *GATED RECURRENT UNIT* (GRU) DAN
EXTREME GRADIENT BOOSTING (XGBOOST) DALAM
MEMPREDIKSI PENUTUPAN HARGA SAHAM PT GARUDAFOOD
PUTRA PUTRI JAYA TBK**

(Skripsi)

Oleh

HAPPY NUR AZIZAH



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRACT

COMPARISON OF GATED RECURRENT UNIT (GRU) AND EXTREME GRADIENT BOOSTING (XGBOOST) METHODS IN PREDICTING THE CLOSING PRICE OF PT GARUDAFOOD PUTRA PUTRI JAYA TBK

By

Happy Nur Azizah

Time series analysis has become an important method in understanding and predicting stock price behavior in financial markets. GRU and XGBoost are methods that can be used to predict stock prices. GRU is one of the RNN models that has 2 components that regulate the flow of information called the gate, namely the update gate and the reset gate, while XGBoost is an ensemble learning that combines several decision tree models. The purpose of this research is to compare the two methods in predicting the closing stock price of PT Garudafood Putra Putri Jaya Tbk. In this study, data splitting was carried out using several ratios, namely 90:10, 80:20, and 70:30. And produced the best model in the GRU method with 90:10 data splitting which obtained a MAPE value of 1% and RMSE of 6.42. So it can be concluded that the use of the GRU method is better than XGBoost to predict the closing stock price of PT Garudafood Putra Putri Jaya Tbk. because it produces smaller MAPE and RMSE values.

Keywords: Time Series Analysis, Stocks, Gated Recurrent Unit, Extreme Gradient Boosting, Mean Absolute Percentage Error, Root Mean Squared Error.

ABSTRAK

PERBANDINGAN METODE *GATED RECURRENT UNIT* (GRU) DAN *EXTREME GRADIENT BOOSTING* (XGBOOST) DALAM MEMPREDIKSI PENUTUPAN HARGA SAHAM PT GARUDAFOOD PUTRA PUTRI JAYA TBK

Oleh

Happy Nur Azizah

Analisis deret waktu telah menjadi metode yang penting dalam memahami dan memprediksi perilaku harga saham di pasar keuangan. GRU dan XGBoost adalah metode yang dapat digunakan untuk melakukan prediksi harga saham. GRU merupakan salah satu model RNN yang mempunyai 2 komponen pengatur alur informasi yang disebut sebagai *gate* yaitu *update gate* dan *reset gate*, sedangkan XGBoost merupakan salah satu *ensemble learning* yang mengkombinasikan beberapa model *decision tree*. Tujuan penelitian ini untuk membandingkan kedua metode tersebut dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. Pada penelitian ini dilakukan *splitting* data dengan menggunakan beberapa rasio yaitu 90:10, 80:20, dan 70:30. Dan menghasilkan model terbaik pada metode GRU dengan *splitting* data 90:10 yang memperoleh nilai MAPE sebesar 1% dan RMSE sebesar 6.42. Maka dapat disimpulkan penggunaan metode GRU lebih baik dibandingkan dengan XGBoost untuk memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. karena menghasilkan nilai MAPE dan RMSE yang lebih kecil.

Kata kunci: Analisis Deret Waktu, Saham, *Gated Recurrent Unit*, *Extreme Gradient Boosting*, *Mean Absolute Percentage Error*, *Root Mean Squared Error*.

**PERBANDINGAN METODE *GATED RECURRENT UNIT* (GRU) DAN
EXTREME GRADIENT BOOSTING (XGBOOST) DALAM
MEMPREDIKSI PENUTUPAN HARGA SAHAM PT GARUDAFOOD
PUTRA PUTRI JAYA TBK**

Oleh

Happy Nur Azizah

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

Judul Skripsi

**PERBANDINGAN METODE *GATED*
RECURRENT UNIT (GRU) DAN *EXTREME*
GRADIENT BOOSTING (XGBOOST)
DALAM MEMPREDIKSI PENUTUPAN
HARGA SAHAM PT GARUDAFOOD
PUTRA PUTRI JAYA TBK**

Nama Mahasiswa

Happy Nur Azizah

Nomor Pokok Mahasiswa

2017031048

Jurusan

: Matematika

Fakultas

: Matematika dan Ilmu Pengetahuan Alam



I. Komisi Pembimbing

Prof. Ir. Netti Herawati, M.Sc., Ph.D.

NIP. 196501251990032001

Dr. Agus Sutrisno, S.Si., M.Si.

NIP. 197008311999031002

2. Ketua Jurusan Matematika

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

NIP. 197403162005011001

MENGESAHKAN

I. Tim Penguji

Ketua

Prof. Ir. Netti Herawati, M.Sc., Ph.D.

Sekretaris

Dr. Agus Sutrisno, S.Si., M.Si.

Penguji

Bukan Pembimbing

Widiarti, S.Si., M.Si.

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

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

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: **11 Juli 2024**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Happy Nur Azizah**

Nomor Pokok Mahasiswa : **2017031048**

Jurusan : **Matematika**

Judul Skripsi : **PERBANDINGAN METODE *GATED RECURRENT UNIT (GRU)* DAN *EXTREME GRADIENT BOOSTING (XGBOOST)* DALAM MEMPREDIKSI PENUTUPAN HARGA SAHAM PT GARUDAFOOD PUTRA PUTRI JAYA TBK**

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

Bandar Lampung, 11 Juli 2024

Yang menyatakan,



Happy Nur Azizah
NPM. 2017031048

RIWAYAT HIDUP

Penulis bernama lengkap Happy Nur Azizah, anak terakhir dari tiga bersaudara yang dilahirkan di Blitarejo pada tanggal 14 Februari 2002 oleh pasangan Bapak Yahyo dan Ibu Turiem.

Penulis telah menempuh Pendidikan di Taman Kanak-kanak (TK) Bina Mulya Blitarejo pada tahun 2007-2008, sekolah dasar di SDN 2 Blitarejo pada tahun 2008-2014, sekolah menengah pertama di SMPN 4 Gadingrejo pada tahun 2014-2017, dan sekolah menengah atas di SMAN 1 Gadingrejo pada tahun 2017-2020.

Pada tahun 2020, penulis terdaftar sebagai Mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis mengikuti organisasi kampus antara lain menjadi anggota Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) periode 2021 dan menjadi anggota Badan Eksekutif Mahasiswa (BEM) Fakultas Matematika dan Ilmu Pengetahuan Alam periode 2022.

Sebagai bentuk penerapan ilmu yang telah dipelajari, pada bulan Januari-Februari 2023 penulis melaksanakan Kerja Praktik (KP) di PT PLN Unit Induk Distribusi Lampung. Sedangkan pada bulan Juli-Agustus 2023, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Kuripan, Kecamatan Kota Agung Pusat, Kabupaten Tanggamus selama 40 hari sebagai bentuk pengabdian mahasiswa dan aplikasi bidang ilmu kepada masyarakat.

KATA INSPIRASI

*"Dan Dia bersama kamu di mana saja kamu berada. Dan Allah Maha Melihat apa yang kamu kerjakan."
(Q.S Al-Hadid: 4)*

*"Barang siapa keluar untuk mencari sebuah ilmu, maka ia akan berada di jalan Allah hingga ia kembali."
(HR. Tirmidzi)*

*"Pengetahuan tanpa tindakan adalah sia-sia, dan tindakan tanpa pengetahuan adalah kegilaan"
(Abu Hamid Al Ghazali)*

PERSEMBAHAN

Alhamdulillah, puji dan syukur kepada Allah SWT atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Oleh karena itu, dengan rasa syukur dan bahagia penulis persembahkan rasa karya sederhana ini kepada:

Kedua Orang Tua Tercinta

Yang telah memberikan kepercayaan kepada penulis untuk melanjutkan pendidikan ke tahap ini, yang mengorbankan segalanya untuk penulis, selalu memberi semangat, serta tiada hentinya selalu mendoakan yang terbaik untuk penulis di setiap saat.

Kedua Kakak Tersayang

Yang selalu memberikan dukungan, semangat, keceriaan, dan doa kepada penulis.

Dosen Pembimbing dan Pembahas

Yang senantiasa memberikan bimbingan, arahan, dan ilmu yang sangat bermanfaat bagi penulis.

Almamaterku Tercinta, Universitas Lampung

SANWACANA

Segala puji bagi Allah, Tuhan semesta alam, atas limpahan karunia dan rahmat-Nya lah, penulis dapat menyelesaikan skripsi yang berjudul “ Perbandingan Metode *Gated Recurrent Unit (GRU)* dan *Extreme Gradient Boosting (XGBoost)* dalam Memprediksi Penutupan Harga Saham PT Garudafood Putra Putri Jaya Tbk”.

Penulis menyadari bahwa dalam penyelesaian skripsi ini, tidak lepas dari dukungan dan bimbingan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan terima kasih kepada:

1. Ibu Prof. Ir. Netti Herawati, M.Sc., Ph.D., selaku dosen pembimbing utama dan dosen pembimbing akademik atas kesediaan waktu, pemikiran dalam memberikan evaluasi, arahan, dan motivasi yang membangun kepada penulis selama proses penyusunan skripsi ini.
2. Bapak Dr. Agus Sutrisno, S.Si., M.Si., selaku dosen pembimbing kedua yang telah memberikan bimbingan serta kemudahan dalam penyusunan skripsi ini.
3. Ibu Widiarti, S.Si., M.Si., selaku dosen penguji yang telah memberikan evaluasi dan saran bagi perbaikan skripsi penulis.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Seluruh dosen dan staff Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Ibu, Bapak, Tete Ee, dan Tete Nur yang selalu mendoakan, dukungan, kasih sayang, dan pengorbanan kepada penulis.
8. Mawar, Sinta, Cindy, Salsa, Meryam, Maya, Gustina, Chyntia, dan Siska yang selalu menemani, membantu, memberi keceriaan, memberikan kenangan indah dan tak terlupakan pada masa perkuliahan serta memberi semangat.
9. Teman-teman mahasiswa jurusan matematika angkatan 2020 serta seluruh pihak yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan, akan tetapi penulis berharap semoga skripsi ini dapat bermanfaat bagi semua pihak.

Terimakasih banyak untuk segala bentuk doa dan dukungannya, semoga Tuhan Yang Maha Esa membalas kebaikan kalian semua.

Bandar Lampung, 11 Juli 2024

Penulis,

Happy Nur Azizah

DAFTAR ISI

Halaman

DAFTAR TABEL	xv
DAFTAR GAMBAR	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	3
1.3 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA	5
2.1 Peramalan	5
2.2 Analisis Deret Waktu.....	6
2.3 <i>Machine Learning</i>	6
2.4 <i>Deep Learning</i>	7
2.5 <i>Recurrent Neural Network (RNN)</i>	7
2.6 <i>Gated Recurrent Unit (GRU)</i>	7
2.7 <i>Extreme Gradient Boosting (XGBoost)</i>	10
2.8 Normalisasi dan Denormalisasi Data	11
2.9 Fungsi Aktivasi.....	12
2.10 Evaluasi Model.....	13
2.10.1 <i>Mean Absolute Percentage Error (MAPE)</i>	13
2.10.2 <i>Root Mean Square Error (RMSE)</i>	14
III. METODOLOGI PENELITIAN	15
3.1 Waktu dan Tempat Penelitian	15
3.2 Data Penelitian.....	15
3.3 Metode Penelitian	15
IV. HASIL DAN PEMBAHASAN	18
4.1 Analisis Deskriptif.....	18
4.2 Visualisasi Data	19
4.3 <i>Splitting Data</i>	19

4.3	Analisis Metode GRU	20
4.3.1	Normalisasi Data	20
4.3.2	<i>Hyperparameter Tuning</i> Model GRU	21
4.3.3	Pembentukan Model GRU.....	22
4.3.4	Prediksi Model GRU	23
4.4	Analisis Metode XGBoost.....	25
4.4.1	Grafik Dekomposisi.....	25
4.4.2	<i>Hyperparameter Tuning</i> Model XGBoost.....	26
4.4.3	Pembentukan Model XGBoost	27
4.4.4	Prediksi Model XGBoost.....	28
4.5	Perbandingan Metode GRU dan XGBoost.....	30
V.	KESIMPULAN	32
	DAFTAR PUSTAKA	33
	LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
1. Kriteria nilai MAPE	14
2. Statistik Deskriptif data penutupan harga saham	19
3. Nilai Minimum dan Maksimum Data <i>Training</i>	21
4. Nilai Minimum dan Maksimum Data <i>Testing</i>	22
5. <i>Hyperparameter Tuning</i> Data Prediksi GRU.....	23
6. Hasil <i>Hyperparameter Tuning</i> dengan <i>Grid Search</i> GRU.....	24
7. <i>Hyperparameter Tuning</i> Data Prediksi XGBoost.....	28
8. Hasil <i>Hyperparameter Tuning</i> dengan <i>Grid Search</i> XGBoost.....	29
9. Hasil Perbandingan Model GRU dan XGBoost	32

DAFTAR GAMBAR

Gambar	Halaman
1. Plot harga penutupan saham	20
2. Plot hasil prediksi model GRU	25
3. Dekomposisi model XGBoost	27
4. Plot hasil prediksi model XGBoost.....	30

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Analisis deret waktu adalah metode analisis yang memperhitungkan pengaruh waktu secara berurutan. Analisis deret waktu digunakan untuk mengidentifikasi pola variabilitas dalam data historis, yang dapat digunakan untuk memprediksi nilai di masa depan dan merencanakan kegiatan mendatang. Analisis deret waktu dapat diterapkan baik pada data yang terdiri dari satu variabel (*univariate*) maupun data yang terdiri dari lebih dari satu variabel (*multivariate*).

Beberapa metode penelitian dapat digunakan dalam memprediksi data *time series* univariat dengan menggunakan metode *machine learning*. Metode *machine learning* adalah bagian dari bidang kecerdasan buatan dan ilmu komputer yang mengutamakan penggunaan data dan algoritma untuk memodelkan proses pembelajaran manusia, dengan tujuan meningkatkan akurasi secara bertahap. Beberapa metode yang dapat digunakan dalam memprediksi data univariat *time series* adalah metode *Gated Recurrent Unit* (GRU) dan *Extreme Gradient Boosting* (XGBoost).

GRU merupakan evolusi dari model Recurrent Neural Network (RNN) yang disederhanakan dalam arsitektur untuk meningkatkan efisiensi pengolahan data (Tanudy, *et al.*, 2023). Walaupun memiliki struktur yang lebih sederhana, model GRU memberikan tingkat akurasi prediksi yang sebanding dengan model RNN lainnya. Sedangkan XGBoost merupakan metode *machine learning* yang dapat melakukan regresi atau klasifikasi. XGBoost dapat digunakan pada berbagai jenis

data terstruktur, termasuk data deret waktu. Salah satu keunggulan utamanya adalah kemampuannya untuk mengatasi masalah *overfitting* yang umum terjadi dalam pembelajaran *ensemble*, dengan menggunakan teknik regularisasi yang canggih dan proses pembelajaran yang berulang secara iteratif. Selain itu, XGBoost juga memiliki keunggulan dalam menangani dataset dengan jumlah yang besar (Rizky, *et al.*, 2022).

Berbagai macam penelitian telah dilakukan untuk melakukan prediksi pada data univariat menggunakan RNN. Prayogi, *et al.* (2024), memprediksi nilai saham Bank Central Asia dengan menggunakan algoritma *deep learning* GRU dan menghasilkan nilai MAPE 1.039% dengan model data latih dan data uji sebesar 60:40. Jange (2022), melakukan penelitian mengenai prediksi harga saham bank Bank Central Asia menggunakan XGBoost mencapai tingkat akurasi prediksi yang baik, dengan nilai MAPE sebesar 4.01% setelah penyetelan hiperparameter. Namun, prediksi mengalami penurunan performa pada bulan Maret tahun 2020 akibat adanya pandemi Covid-19. Yulisa, *et al.* (2023), melakukan prediksi nilai ekspor migas di Indonesia menggunakan model *Long Short Term* (LSTM) dan *Gated Recurrent Unit* (GRU). Hasil dari penelitian tersebut diperoleh akurasi tertinggi dengan menggunakan model LSTM terbaik yang memiliki nilai parameter α 0.001, jumlah neuron 20, dan dilatih selama 100 epoch, prediksi menunjukkan nilai *Mean Absolute Error* (MAPE) sebesar 12.8% dengan akurasi 87.2%. Pratama & Banowosari (2024), melakukan penelitian perbandingan antara metode XGBoost dan LSTM untuk memprediksi harga saham PT. Bank Mandiri TBK (BMRI) dan menghasilkan model terbaik yaitu LSTM dengan nilai MAPE 1.77% sedangkan nilai MAPE pada XGBoost sebesar 3.21%.

Salah satu implementasi dari metode GRU dan XGBoost yaitu untuk memprediksi indeks harga saham. Menurut Hartono (2008), saham adalah bukti kepemilikan modal dari suatu perseroan terbatas. Harga saham ditentukan oleh interaksi antara penawaran dan permintaan di pasar modal. Dalam investasi saham, investor sering menghadapi berbagai tantangan, salah satunya adalah kesulitan dalam memprediksi harga saham. Oleh karena itu, peramalan menjadi sangat penting

bagi investor untuk memperkirakan data saham di masa depan dan mencapai keuntungan yang optimal. Salah satu saham terkemuka di Indonesia adalah PT Garudafood Putra Putri Jaya Tbk. Saham tersebut merupakan bagian dari perusahaan Garuda Grup yang dikenal atas beragam produk makanan dan minuman berkualitas tinggi yang telah menjadi favorit di pasar domestik maupun internasional.

Berdasarkan pemaparan diatas, penelitian ini akan membandingkan metode GRU dan XGBoost, dengan harapan bahwa perbandingan keduanya dapat membantu menentukan metode yang lebih baik untuk memprediksi harga penutupan saham PT Garudafood Putra Putri Jaya Tbk. Perbandingan metode tersebut dilakukan agar mendapatkan model dengan nilai kesalahan yang kecil. Untuk mengetahui nilai kesalahan dalam memprediksi data *time series* dapat diukur menggunakan MAPE dan RMSE, agar peneliti dapat mengetahui metode mana yang lebih baik dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. yang lebih efektif antara kedua model tersebut.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk melakukan perbandingan metode GRU dan XGBoost untuk mengetahui metode mana yang lebih baik berdasarkan nilai MAPE dan RSME yang terkecil dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah untuk memahami prosedur analisis deret waktu menggunakan perbandingan metode GRU dan XGBoost untuk menentukan

metode mana yang lebih baik dengan melihat nilai MAPE dan RSME yang terkecil dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk.

II. TINJAUAN PUSTAKA

2.1 Peramalan

Peramalan merupakan pendekatan yang digunakan untuk mengantisipasi dan merencanakan situasi di masa depan dengan lebih baik dan terperinci, berdasarkan analisis dari kumpulan data historis dari periode sebelumnya hingga saat ini. Hal ini bertujuan untuk mengurangi tingkat ketidakpastian dan kesalahan dalam pengambilan keputusan (Ahmad, 2020). Peramalan bisa menjadi dasar bagi perencanaan jangka pendek, menengah maupun jangka panjang suatu perusahaan.

Peramalan yang akan dibuat selalu diupayakan agar dapat meminimumkan pengaruh ketidakpastian terhadap perusahaan. Dengan kata lain, peramalan bertujuan mendapatkan ramalan yang bisa meminimumkan kesalahan meramal (*forecast error*) yang biasanya diukur dengan *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan sebagainya (Subagyo, 1986).

Dalam proses peramalan, tidak terdapat metode yang mutlak terbaik dan dapat diaplikasikan untuk semua jenis prediksi. Suatu metode mungkin sangat baik untuk membuat peramalan mengenai suatu hal, tetapi kurang akurat untuk membuat peramalan hal yang lain. Oleh karena itu, untuk mendapatkan metode yang lebih baik maka dapat dilakukan dengan memilih metode yang bisa meminimumkan kesalahan dalam peramalan.

2.2 Analisis Deret Waktu

Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur-struktur probabilistik. Struktur dengan keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan (Aswi & Sukarna, 2006). Deret waktu dianalisis untuk menemukan pola variasi masa lalu yang dapat dipergunakan untuk memperkirakan nilai masa depan dan membuat perencanaan untuk masa depan.

Secara umum, analisis deret waktu terbagi menjadi dua yaitu univariat dan multivariat. Univariat melibatkan penggunaan satu variabel dalam analisisnya. Sedangkan multivariat, merupakan analisis deret waktu yang memiliki dua variabel atau lebih dan saling terkait.

2.3 *Machine Learning*

Menurut Muntiari & Hanif (2022), *machine learning* adalah bagian dari kecerdasan buatan (*Artificial Intelligence*) yang berkaitan dengan pengembangan program komputer untuk meningkatkan kemampuannya dengan cara menganalisis data, seperti pengenalan pola, prediksi, dan klasifikasi.

Secara umum, ada dua tujuan utama dari *machine learning*. Pertama, untuk melakukan prediksi terhadap suatu peristiwa di masa depan yang belum diamati (*unobserved event*). Kedua, untuk mendapatkan pengetahuan baru atau menemukan struktur yang tidak diketahui sebelumnya (*knowledge discovery/discovering unknown structure*). Kedua tujuan ini dapat dicapai dengan memanfaatkan kumpulan data. Selanjutnya, dengan membangun model dapat menggeneralisasi aturan atau pola dari data untuk mendapatkan wawasan baru atau membuat dalam proses pengambilan keputusan (Hand, *et al.*, 2012).

2.4 *Deep Learning*

Deep Learning merupakan bagian dari *machine learning* yang melibatkan algoritma untuk memodelkan abstraksi tingkat tinggi pada data menggunakan serangkaian fungsi transformasi non-linear yang tersusun dalam lapisan-lapisan yang dalam dan kompleks (Cholissodin, *et al.*, 2019). *Deep Learning* telah menjadi metode yang sering digunakan untuk memprediksi data deret waktu karena kemampuannya yang efektif dalam mengidentifikasi pola-pola kompleks dalam data. Algoritma jaringan saraf *deep learning* dapat melakukan *tuning* secara otomatis dan memilih model yang optimal untuk meningkatkan akurasi prediksi.

2.5 *Recurrent Neural Network (RNN)*

Recurrent Neural Network (RNN) adalah jenis arsitektur dalam jaringan saraf tiruan atau *Artificial Neural Network (ANN)* yang dikembangkan khusus untuk memproses data yang berurutan (Yunizar, *et al.*, 2023). RNN merupakan bagian dari *deep learning* karena data yang diproses akan dilakukan melalui beberapa layer. Dalam pengembangannya, RNN sering digunakan untuk menganalisis terkait data *time series*. Pada proses *training*, RNN tidak menghapus data atau informasi dari langkah-langkah sebelumnya. RNN menyimpan informasi dalam memori untuk menangkap pola data yang lebih baik, yang kemudian digunakan untuk membuat prediksi yang lebih akurat.

2.6 *Gated Recurrent Unit (GRU)*

Gated Recurrent Unit (GRU) adalah jenis RNN yang dirancang untuk mengatasi masalah gradien hilang pada RNN. Didalam GRU, terdapat dua komponen

pengatur alur informasi yang dikenal sebagai *gate* yaitu *update gate* dan *reset gate*. Dengan menggunakan *update gate* dan *reset gate*, GRU menentukan informasi mana yang harus dipertahankan dalam outputnya. Dengan kata lain, *update gate* dan *reset gate* merupakan dua komponen yang menentukan bagaimana data diolah dalam GRU. *Update gate* membantu untuk menentukan seberapa banyak informasi dari masa lampau yang harus diteruskan atau diabaikan dalam proses pengolahan selanjutnya, sementara *reset gate* digunakan untuk menghapus seberapa banyak informasi masa lampau yang tidak diperlukan. Maka secara tidak langsung, *update gate* dan *reset gate* dapat membantu mengatasi masalah yang sering terjadi pada model RNN, yaitu *vanishing gradient problem*. *Gate* tersebut dapat dilatih untuk mempertahankan informasi yang relevan dari masa lampau dan menggabungkannya dengan informasi baru (Rahman, *et al.*, 2019).

Menurut Halim, *et al.* (2022), langkah awal dalam proses metode GRU adalah menetapkan metode untuk mengintegrasikan informasi dari *time step* sebelumnya dan *input* baru melalui *reset gate*. Hasil dari langkah ini adalah nilai yang berada dalam rentang antara 0 hingga 1. Rumus untuk menghitung *reset gate* sebagai berikut:

$$r = \sigma(W_{xr} \cdot X_t + W_{hr} \cdot h_{(t-1)} + b_r) \quad 2.1$$

dengan:

- r = *reset gate*
- σ = fungsi aktivasi *sigmoid*
- W_{xr}, W_{hr} = parameter *weight*
- X_t = data input
- $h_{(t-1)}$ = *hidden state* dari *time step* sebelumnya
- b_r = nilai bias pada *reset gate*

Langkah berikutnya adalah menentukan seberapa banyak informasi dari *time step* sebelumnya yang harus disimpan untuk menghitung *hidden state* yang akan digunakan sebagai *input* di *time step* berikutnya, serta menentukan seberapa besar

pengaruh informasi dari *time step* sebelumnya pada *output* di *time step* saat ini. Proses ini terjadi di *update gate* dengan menggunakan fungsi aktivasi sigmoid. Perhitungan *update gate* dapat dijelaskan dengan rumus sebagai berikut:

$$z = \sigma(W_{xz} \cdot X_t + W_{hz} \cdot h_{(t-1)} + b_z) \quad 2.2$$

dengan:

- z = *update gate*
- σ = fungsi aktivasi *sigmoid*
- W_{xz}, W_{hz} = parameter *weight*
- X_t = data input
- $h_{(t-1)}$ = *hidden state* dari *time step* sebelumnya
- b_r = nilai bias pada *update gate*

Langkah selanjutnya adalah menentukan kandidat *hidden state* pada *time step* saat ini (t) berdasarkan informasi yang relevan dari *time step* sebelumnya (t-1), menggunakan fungsi aktivasi tanh. Perhitungan dapat dijelaskan dengan rumus sebagai berikut:

$$\tilde{h} = \tanh(W_{xh} \cdot X_t + r * W_{hh} \cdot h_{(t-1)} + b_z) \quad 2.3$$

dengan:

- \tilde{h} = kandidat *hidden state*
- W_{xh}, W_{hh} = parameter *weight*
- X_t = data input
- r = *reset gate*
- $h_{(t-1)}$ = *hidden state* dari *time step* sebelumnya
- b_z = nilai bias

Selanjutnya adalah menghasilkan output akhir atau informasi akhir dari unit saat ini, kemudian meneruskannya sebagai *hidden state* ke *time step* berikutnya dengan menggunakan persamaan sebagai berikut:

$$h = z * h_{(t-1)} + (1 - z) * \tilde{h} \quad 2.4$$

dengan:

h = output

\tilde{h} = kandidat *hidden state*

z = output pada *update gate*

$h_{(t-1)}$ = *hidden state* dari *time step* sebelumnya

2.7 Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) adalah salah satu metode *ensemble learning* yang menggabungkan beberapa model *decision tree* dan secara iteratif memperbaiki model dengan menambahkan pohon baru yang fokus pada kesalahan prediksi yang dilakukan oleh pohon sebelumnya (Astutiningsih, *et al.*, 2023).

Ensemble learning sendiri merupakan metode yang dibangun dengan beberapa model prediksi dan klasifikasi yang akan digunakan untuk mengklasifikasikan data baru berdasarkan bobot yang telah diprediksi dari hasil sebelumnya. Model akhir dari teknik *boosting* merupakan gabungan dari kumpulan model yang dibuat secara iteratif, dimana setiap iterasi berfokus pada memperbaiki kesalahan prediksi dari model sebelumnya. Proses ini bertujuan untuk menghasilkan model akhir yang memiliki nilai error terkecil dari residual.

Menurut Patrous (2018), dalam algoritme XGBoost, bobot pada setiap *tree* akan diperbarui dan kemudian dijumlahkan saat melakukan prediksi, yang kemudian dimasukkannya ke dalam fungsi. Fungsi tersebut dapat ditulis menggunakan rumus sebagai berikut:

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) \quad 2.5$$

$f_k(x_i)$ menggambarkan model *tree*. Untuk y_i diperoleh dari perhitungan berikut:

$$\hat{y}_i^{(0)} = 0 \quad 2.6$$

$$\hat{y}_i^{(1)} = f_1(x_1) = \hat{y}_i^{(0)} + f_1(x_1) \quad 2.7$$

$$\hat{y}_i^{(2)} = f_1(x_1) + f_2(x_2) = \hat{y}_i^{(1)} + f_2(x_2) \quad 2.8$$

$$\vdots$$

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad 2.9$$

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) \quad 2.10$$

dengan:

$\hat{y}_i^{(t)}$ = *final tree* model

$\hat{y}_i^{(t-1)}$ = model *tree* yang dihasilkan sebelumnya

$f_t(x_i)$ = model baru yang dibangun

t = jumlah total model dari *base tree models*.

Algoritma XGBoost mencapai tingkat optimasi yang lebih tinggi dibandingkan dengan implementasi *Gradient Boosting Machine* (GBM) lainnya. Keberhasilan ini terbukti dengan metode XGBoost menjadi metode yang dominan digunakan dalam kompetisi *machine learning* (Chen & Guestrin, 2016).

2.8 Normalisasi dan Denormalisasi

Normalisasi data adalah proses untuk mengubah data sehingga memiliki skala yang sama besar (Patel & Mehta, 2011). Tujuan normalisasi adalah untuk memperoleh data yang memiliki rentang nilai yang lebih kecil tetapi dapat mewakili karakteristik asli dari data tersebut. Persamaan normalisasi ditunjukkan dalam persamaan berikut (Parto & Sahu, 2015):

$$x' = \frac{x - \min}{\max - \min} \quad 2.11$$

dengan:

x' : hasil normalisasi

x : data ke-i

min : nilai minimum dari data yang digunakan

max : nilai maksimum dari data yang digunakan

Denormalisasi adalah proses mengembalikan data ke nilai aslinya setelah sebelumnya dilakukan proses normalisasi. Umumnya dilakukan untuk hasil akhir atau *output* dari proses *training* peramalan. Persamaan denormalisasi ditunjukkan sebagai berikut:

$$x_i = x'(max - min) + min \quad 2.12$$

dengan:

- x_i : hasil denormalisasi
- x' : data yang akan di denormalisasi
- min : data minimal
- max : data maksimal

2.9 Fungsi Aktivasi

Menurut Sianturi, *et al.* (2023), fungsi aktivasi secara khusus digunakan pada jaringan saraf tiruan agar dapat mempelajari pola-pola kompleks pada data. Keakuratan prediksi jaringan syaraf tiruan bergantung pada jumlah lapisan yang digunakan dan jenis fungsi aktivasi yang digunakan. Secara spesifik, tidak ada jumlah pasti yang dapat digunakan untuk hasil dan akurasi yang lebih baik dari jaringan saraf. Jika fungsi aktivasi tidak digunakan dalam jaringan saraf maka output layer hanya akan menjadi fungsi linear sederhana. Meskipun persamaan linear sederhana dan mudah untuk diselesaikan tetapi kompleksitasnya terbatas dan tidak memiliki kemampuan untuk mempelajari dan mengenali pemetaan kompleks dari data. Fungsi aktivasi yang sering digunakan yaitu fungsi *sigmoid* dan *tanh* sebagai berikut:

1. *Sigmoid*

Fungsi *sigmoid* merupakan fungsi nonlinier dengan rentang nilai antara 0 hingga 1. Bentuk umum dari fungsi *sigmoid* adalah sebagai berikut:

$$F(x) = \frac{1}{(1+e^{-x})} \quad 2.13$$

2. *Tanh*

Fungsi *tanh* memiliki distribusi yang mirip dengan fungsi *sigmoid*, tetapi dengan rentang nilai antara -1 hingga 1 dan distribusi yang lebih sempit.

Bentuk matematis dari fungsi *tanh* sebagai berikut:

$$F(x) = \frac{\sinh x_i}{\cosh x_i} = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}} \quad 2.14$$

Karakteristik fungsi *tanh* yang terpusat pada nol mengatasi kelemahan utama pada fungsi *sigmoid*, sehingga dalam penggunaannya fungsi *tanh* cenderung lebih efektif dibandingkan fungsi *sigmoid*.

2.10 Evaluasi Model

Evaluasi model digunakan untuk memilih model terbaik yang akan digunakan. Model terbaik yang dapat digunakan untuk prediksi adalah yang memiliki nilai kesalahan yang cenderung kecil. Untuk memilih model terbaik, kriteria dapat didasarkan pada evaluasi nilai residual dan kesalahan prediksi (Wei, 2006).

2.10.1 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah metode untuk mengukur perbedaan antara data aktual dan hasil peramalan, dimana perbedaan tersebut diabsolutkan (Swanson, *et al.*, 2011). Sebuah metode dianggap memiliki kinerja yang baik jika menghasilkan nilai MAPE kurang dari 10%. Semakin kecil nilai MAPE, maka semakin baik kinerja metode tersebut dalam memprediksi data. Kriteria MAPE yang digunakan adalah sebagai berikut:

Tabel 1. Kriteria nilai MAPE

Nilai MAPE	Kriteria
< 10%	Sangat Baik
10% - 20%	Baik
20% – 50%	Cukup
> 50%	Buruk

Untuk mendapatkan nilai MAPE, maka dapat digunakan rumus perhitungan sebagai berikut,

$$MAPE = \frac{100}{n} \sum_{i=0}^n \left| \frac{y_i - x_i}{x_i} \right| \quad 2.15$$

dengan:

- x_i = data aktual periode ke-i
- y_i = hasil prediksi periode ke-i
- n = banyaknya data yang diuji

2.10.2 Root Mean Square Error (RMSE)

Menurut Hyndman & Gooijer (2006), *Root Mean Square Error* (RMSE) digunakan sebagai kriteria untuk memilih model terbaik, dimana nilai RMSE mengukur akar rata-rata dari kesalahan kuadrat residual. Menurut Wei (2006), semakin kecil nilai RMSE, semakin kecil pula kesalahan prediksi model tersebut. Nilai RMSE dapat dihitung menggunakan rumus sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad 2.16$$

dengan:

- n = banyak nya data yang diuji
- x_i = data aktual periode ke-i
- y_i = data prediksi periode ke-i

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2023/2024, bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini yaitu data penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. yang diperoleh dari <https://finance.yahoo.com>. Data penelitian yang digunakan yaitu berupa data harian dari tanggal 2 Juni 2020 – 29 April 2024 dan berjumlah 947 data.

3.3 Metode Penelitian

Dalam penelitian ini akan dilakukan perbandingan metode GRU dan XGBoost terhadap data penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. Tahap-tahap dalam penyelesaian ini menggunakan *software Python*. Analisis yang digunakan dalam melakukan perbandingan metode GRU dan XGBoost dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk

dilakukan dengan membandingkan nilai MAPE dan RMSE. Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Menginput data dan melakukan penyajian data dengan statistika deskriptif.
2. Visualisasi data
Visualisasi data digunakan untuk melihat dan mengidentifikasi tren dan pola data
3. *Preprocessing* data
Melakukan *preprocessing* data untuk pengecekan *missing value* pada data.
4. *Splitting* data
Splitting data yang digunakan akan dibagi menjadi dua yaitu data *training* dan *testing*. Pada penelitian ini akan dilakukan *splitting* data menggunakan beberapa rasio yaitu 90:10, 80:20, dan 70:30.
5. Analisis metode GRU
 - Normalisasi data
Normalisasi data dilakukan untuk mengubah skala data ke rentang nilai 0 hingga 1.
 - *Hyperparameter tuning* model GRU
Setelah melakukan normalisasi data, langkah selanjutnya adalah melakukan *hyperparameter tuning*. *Hyperparameter tuning* dilakukan untuk mencari kombinasi hyperparameter yang optimal.
 - Pembentukan model GRU
Selanjutnya yaitu pembentukan model GRU, langkah ini melibatkan pembangunan arsitektur GRU dengan konfigurasi *hyperparameter* yang telah ditentukan.
 - Prediksi model GRU
Selanjutnya yaitu melakukan prediksi model GRU pada data *testing*. Model ini menggunakan informasi dari *time step* sebelumnya dalam deret waktu untuk menghasilkan prediksi pada *time step* berikutnya, dengan tujuan mengevaluasi akurasi prediksi berdasarkan parameter dan struktur yang telah ditentukan selama pelatihan.

6. Analisis metode XGBoost

- Grafik dekomposisi

Sebelum membangun model XGBoost akan dilakukan analisis grafik dekomposisi untuk memahami tren, musiman, dan komponen lain dari data yang digunakan.

- *Hyperparameter Tuning* Model XGBoost

Langkah selanjutnya adalah melakukan *hyperparameter tuning* untuk mencari kombinasi yang optimal.

- Pembentukan model XGBoost

Setelah *hyperparameter* ditentukan, dilakukan pembentukan model XGBoost dengan menggunakan data *training*.

- Prediksi model XGBoost

Selanjutnya yaitu melakukan prediksi model XGBoost pada data *testing*.

7. Perbandingan model GRU dan XGBoost

Dalam membandingkan model GRU dan XGBoost menggunakan perbandingan nilai MAPE dan RSME. Nilai MAPE dan RSME terkecil merupakan model yang lebih baik.

8. Kesimpulan.

V. KESIMPULAN

Berdasarkan hasil dan pembahasan yang diperoleh, penelitian tentang perbandingan metode GRU dan XGBoost dalam memprediksi penutupan harga saham PT. Garudafood Putra Putri Jaya Tbk memberikan kesimpulan sebagai berikut:

1. Pada metode GRU didapatkan hasil nilai MAPE 1% dan nilai RMSE 6.42 dengan *splitting* data 90:10, pada *splitting* data 80:20 mendapatkan nilai MAPE 1.1% dan RMSE 6.84, dan pada *splitting* data 70:30 mendapatkan nilai MAPE 1.1% dan RMSE 6.81..
2. Sedangkan pada metode XGBoost didapatkan hasil nilai MAPE 1.8% dan nilai RMSE 8.78 dengan *splitting* data 90:10, pada *splitting* data 80:20 mendapatkan nilai MAPE 2.3% dan RMSE 11.85, dan pada *splitting* data 70:30 mendapatkan nilai MAPE 2.8% dan RMSE 14.18.
3. Berdasarkan hasil perhitungan MAPE dan RMSE pada metode GRU dan XGBoost dengan beberapa *splitting* data yang digunakan, menunjukkan bahwa metode GRU dengan *splitting* data 90:10 lebih unggul dalam memprediksi penutupan harga saham PT Garudafood Putra Putri Jaya Tbk. karena memperoleh nilai MAPE dan RMSE yang lebih kecil daripada metode XGBoost dan *splitting* data lainnya.

DAFTAR PUSTAKA

- Ahmad, F. 2020. Penentuan Metode Peramalan Pada Produksi Part New Granada Bowl ST di PT.X. *Jurnal Integrasi Sistem Industri*, **7**(1): 31-39.
- Astutiningsih, T., Saputro, D. R. S., & Sutanto. 2023. Optimasi Algoritme Xtreme Gradient Boosting (XGBoost) pada Harga Saham PT. United Tractors Tbk. *SPECTA Journal of Technology*. **7**(3): 632-641.
- Aswi & Sukarna. 2006. *Analisis Deret Waktu Teori dan Aplikasi*. Andira Publisher, Makassar.
- Chen, T. & Guestrin, C. 2016. XGBoost: A Scalable Tree Boosting System, hlm 785-794. International Conference on Knowledge Discovery and Data Mining, New York.
- Cholissodin, I., Sutrisno, Soebroto, A. A., Hasanah, U., & Febiola, Y. I. 2019. Buku Ajar AI, Machine Learning & Deep Larning. Fakultas Ilmu Komputer (FILKOM). Universitas Brawijaya, Malang.
- Halim, J. K., Herwindiati, D. E., & Hendryli, J. 2022. Penerapan *gated reccurent unit* untuk prediksi zat pencemar udara. *Jurnal Ilmu Komputer dan Sistem Informasi*. **10**(2): 1-6.
- Hand, J., Kamber, M. & Pei, J. 2012. *Data Mining Concepts and Techniques. Third Edition*. Morgan Kaufmann Publishers, USA.
- Hartono, J. 2008. *Teori Portofolio dan Analisis Investasi*. BPPE UGM, Yogyakarta.

- Hyndman, R. J. & Gooijer, J. G. D. 2006. 25 years of time series forecasting. *International Journal of Forecasting*. **22**(3): 443-473.
- Jange, B. 2022. Prediksi harga saham bank BCA menggunakan XGBoost. *Journal of Economics and Accounting*. **3**(2): 231-237.
- Muntiari, N. R. & Hanif, K. H. 2022. Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma Machine Learning. *Jurnal Ilmu Komputer dan Teknologi*. **3**(1): 1-6.
- Parto, S. & Sahu, K. 2015. Normalization: A Preprocessing Stage. *International Advanced Research Journal In Science, Engineering and Technology*. **2**(3): 20-22.
- Patel, V. R. & Mehta, R. G. 2011. Impact of Outlier Removal and Normalization Approach in Modified K-Means Clustering Algorithm. *International Journal of Computer Science*. **8**(2): 331-336.
- Patrous, Z. S. 2018. *Evaluating XGBoost for User Classification by using Behavioral Features Extracted from Smartphone Sensors*. KTH Royal Institute of Technology. Stockholm.
- Pratama, B. & Banowosari, L. Y. 2024. Perbandingan metode *extreme gradient boosting* (XGBoost) dengan *long short term memory* (LSTM) untuk prediksi saham PT. Bank Mandiri TBK. (BMRI). *Journal of Economic, Business and Accounting*. **7**(3): 5631-5636.
- 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**(1): 647-658.
- Rahman, M. O., Hossain, M. S., Junaid, T., Forhad, M. S. A., & Hossen, M. K. 2019. Predicting Price of Stock Market using Gated Recurrent Units (GRUs) Neural Networks. *International Journal of Computer Science and Network Security*. **19**(1): 213-222.
- Rizky, P. S., Hirzi, R. H., & Hidayaturrohman, U. 2022. Perbandingan Metode *LightGBM* dan *XGBoost* dalam Menangani Data dengan Kelas Tidak Seimbang. *Jurnal Statistika*. **15**(2): 228-236.

- Sianturi, T. B., Cholissodin, I. & Yudistira, N. 2023. Penrapan Algoritma Long Short Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. **7**(2): 1101-1107.
- Subagyo, P. 1986. *Forecasting Konsep dan Aplikasi*. BPPE UGM, Yogyakarta.
- Swanson, D. A., Tayman, J., & Bryan, T. M. 2011. MAPE-R : a rescaled measure of accuracy for cross-sectional forecasts. *Journal of Population Reser*. **28**(2): 225-243.
- Tanudy, C., Handhayani, T., & Hendryli, J. 2023. Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit. *Jurnal Fasilkom*. **13**(3): 480-488.
- Wei, W. W. S., 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd ed. Pearson education, London.
- Yulisa, P. N., Haris, M. A., & Arum, P. R. 2023. Peramalan Nilai Ekspor Migas di Indonesia dengan Model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). *Jurnal Ilmiah Teori dan Aplikasi Statistika*. **16**(1): 328-341.
- Yunizar, A., Rismawan, T., & Midyanti, D. M. 2023. Penerapan Metode Recurrent Neural Network Model Gated Recurrent Unit Untuk Prediksi Harga Cryptocurrency. *Jurnal Komputer dan Aplikasi*. **11**(1): 32-41.