

PREDIKSI *CLOSING PRICE* SAHAM HARIAN BERBASIS *SOFT COMPUTING*

THESIS

Oleh:
NI'MAH FIRSTA CAHYA SUSILO
NIM. 200605210003



PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024

PREDIKSI *CLOSING PRICE* SAHAM HARIAN BERBASIS *SOFT COMPUTING*

THESIS

**Diajukan kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan dalam Memperoleh Gelar
Magister Komputer (M.Kom)**

**Oleh:
NI'MAH FIRTA CAHYA SUSILO
NIM. 200605210003**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**PREDIKSI CLOSING PRICE SAHAM HARIAN BERBASIS SOFT
COMPUTING**

THESIS

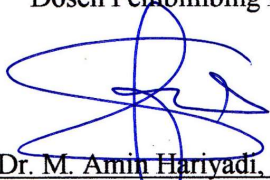
**Oleh:
NI'MAH FIRSTA CAHYA SUSILO
NIM. 200605210003**

**Telah diperiksa dan disetujui untuk diuji
Tanggal: 15 Mei 2024**

Dosen Pembimbing I

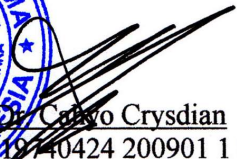

Dr. Cahyo Crysdian
NIP. 19740424 200901 1 008

Dosen Pembimbing II


Dr. M. Amin Hariyadi, M.T
NIP. 19670118 200501 1 001

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




Dr. Cahyo Crysdian
NIP. 19740424 200901 1 008

**PREDIKSI CLOSING PRICE SAHAM HARIAN BERBASIS *SOFT*
*COMPUTING***

THESIS

Oleh:
NI'MAH FIRSA CAHYA SUSILO
NIM. 200605210003

Telah Dipertahankan di Depan Dewan Penguji Thesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M.Kom)
Tanggal: 15 Mei 2024

Susunan Dewan Penguji

Penguji I : Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Penguji II : Dr. M. Imamuddin, Lc., MA
NIP. 19740602 200901 1 010

Pembimbing I : Dr. Cahyo Crysdiان
NIP. 19740424 200901 1 008

Pembimbing II : Dr. M. Amin Hariyadi, M.T
NIP. 19670118 200501 1 001

Tanda Tangan

()

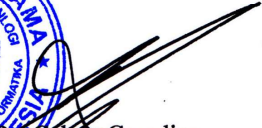
()

()

()

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




Dr. Cahyo Crysdiان
NIP. 19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Ni`mah Firsta Cahya Susilo

NIM : 200605210003

Program Studi : Magister Informatika

Fakultas : Sains dan Teknologi

Judul : Prediksi *Closing Price* Saham Harian Berbasis *Soft Computing*

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

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

Malang, 21 Mei 2024

Yang membuat pernyataan,



Ni`mah Firsta Cahya Susilo

NIM. 200605210003

HALAMAN MOTTO

“Yesterday is history, tomorrow is a mystery, but today is a gift, that’s why it’s called the present.”

HALAMAN PERSEMBAHAN

الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِي

Thesis ini penulis persembahkan untuk kedua orang tua yang telah mendukung secara maksimal, keluarga, seluruh dosen, sahabat, teman-teman seperjuangan, serta seluruh orang yang pernah terlibat dan membantu baik secara langsung maupun secara tidak langsung.

KATA PENGANTAR

Puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat, taufik dan hidayah-Nya sehingga thesis ini dapat terselesaikan. Penulis menyadari bahwa thesis ini tidak akan berhasil tanpa bantuan dari beberapa pihak. Oleh karena itu, penulis ingin menyampaikan rasa hormat dan terima kasih kepada:

1. Bapak Dr. Cahyo Crysdiyan dan Bapak Dr. M. Amin Hariyadi selaku Pembimbing thesis yang telah dengan sabar membimbing dan mengarahkan penulis sehingga dapat menyelesaikan thesis ini,
2. Ibu Prof. Dr. Sri Harini, M.Si, selaku Dekan Fakultas Sains dan Teknologi,
3. Ayahanda Susilo Mansurudin, Ibunda Nuraini Susanti serta keluarga atas segala nasihat, kasih sayang, perhatian dan kesabarannya di dalam membesarkan dan mendidik penulis, serta yang senantiasa tiada henti-hentinya memberikan doa dan semangat demi terselesaikannya skripsi ini,
4. Teman-teman Magister Informatika angkatan 2020 yang telah memberikan semangat,
5. Seluruh civitas akademik Magister Informatika Universitas Islam Maulana Malik Ibrahim Malang yang telah banyak memberi bantuan dan dukungan selama penulis menempuh studi di Magister Informatika Universitas Islam Maulana Malik Ibrahim Malang dan selama penyelesaian thesis ini.

Penulis menyadari bahwa dalam penyusunan thesis ini masih banyak kekurangan, sehingga saran dan kritik yang membangun sangat penulis harapkan.

DAFTAR ISI

| | |
|---|------|
| HALAMAN JUDUL | i |
| HALAMAN PERSETUJUAN | ii |
| HALAMAN PENGESAHAN | iii |
| PERNYATAAN KEASLIAN TULISAN | iv |
| HALAMAN MOTTO..... | v |
| HALAMAN PERSEMBAHAN..... | vi |
| KATA PENGANTAR | vii |
| DAFTAR ISI | viii |
| DAFTAR GAMBAR..... | x |
| DAFTAR TABEL | xi |
| ABSTRAK | xii |
| ABSTRACT | xiii |
| البحث..... | xiv |
| BAB I..... | 1 |
| 1.1 Latar Belakang Masalah | 1 |
| 1.2 Pernyataan Masalah..... | 5 |
| 1.3 Tujuan Penelitian..... | 5 |
| 1.4 Manfaat Penelitian..... | 5 |
| 1.5 Batasan Masalah..... | 5 |
| 1.6 Sistematika Penulisan | 5 |
| BAB II..... | 7 |
| 2.1 Prediksi <i>Closing Price</i> Saham | 7 |
| 2.2 Kerangka Teori..... | 11 |
| BAB III | 14 |
| 3.1 Prosedur Penelitian..... | 14 |
| 3.1.1 Pengumpulan Data | 14 |
| 3.1.2 Desain sistem..... | 16 |
| 3.1.3 Proses Prediksi..... | 18 |
| 3.1.4 Skenario Pengujian | 22 |
| 3.2 Instrumen Penelitian..... | 23 |
| BAB IV | 24 |

| | |
|----------------------------------|----|
| 4.1 Desain | 24 |
| 4.2 Training..... | 25 |
| 4.5 Uji Coba..... | 27 |
| 4.5.1 Uji Asumsi Statistik | 27 |
| 4.5.2 Uji Hasil Prediksi..... | 28 |
| BAB V | 31 |
| 5.1 Model A..... | 31 |
| 5.2 Model B | 36 |
| 5.3 Model C | 42 |
| 5.4 Uji Coba..... | 45 |
| BAB VI | 48 |
| BAB VII..... | 54 |
| 7.1 Kesimpulan | 54 |
| 7.2 Saran..... | 54 |
| DAFTAR PUSTAKA..... | 55 |

DAFTAR GAMBAR

| | |
|--|----|
| Gambar 2. 1 Kerangka Teori..... | 13 |
| Gambar 3. 1 Prosedur Penelitian..... | 14 |
| Gambar 3.2 Desain pengembangan sistem | 17 |
| Gambar 3. 3 Arsitektur ANN | 21 |
| Gambar 4. 1 Alur multiple linear regression..... | 24 |
| Gambar 4. 2 Nilai loss pelatihan MLR..... | 27 |
| Gambar 4. 3 Perbandingan <i>close price actual</i> dan prediksi MLR data saham BRMS | 29 |
| Gambar 4. 4 Perbandingan <i>close price actual</i> dan prediksi MLR data saham GOTO | 30 |
| Gambar 5. 1 Alur <i>artificial neural network</i> | 31 |
| Gambar 5. 2 Desain jaringan model A ANN | 32 |
| Gambar 5. 3 Nilai loss pelatihan model A..... | 36 |
| Gambar 5. 4 Desain jaringan model B ANN | 37 |
| Gambar 5. 5 Nilai loss pelatihan model B | 42 |
| Gambar 5. 6 Desain jaringan model C ANN | 43 |
| Gambar 5. 7 Nilai loss pelatihan model C | 45 |
| Gambar 5. 8 Perbandingan <i>close price actual</i> dan prediksi ANN data saham BRMS | 47 |
| Gambar 5. 9 Perbandingan <i>close price actual</i> dan prediksi ANN data saham GOTO | 47 |

DAFTAR TABEL

| | |
|---|----|
| Tabel 3.1 Daftar Saham Anggota Indeks Jakarta Islamic Index (JII) | 15 |
| Tabel 3. 2 Ilustrasi dan atribut data penelitian | 17 |
| Tabel 3. 3 Data harga saham | 18 |
| Tabel 4. 1 Hasil Pelatihan Model MLR | 25 |
| Tabel 4. 2 Koefisien Regresi | 26 |
| Tabel 4. 3 Koefisien determinasi | 28 |
| Tabel 4. 4 Hasil Uji Asumsi | 28 |
| Tabel 4. 5 Perbandingan <i>close price</i> saham dengan MLR..... | 29 |
| Tabel 5. 1 Kombinasi model <i>hidden layer</i> ANN | 31 |
| Tabel 5. 2 Parameter model A..... | 32 |
| Tabel 5. 3 Hasil Pelatihan Model A | 35 |
| Tabel 5. 4 Parameter model B..... | 37 |
| Tabel 5. 5 Hasil Pelatihan Model B..... | 41 |
| Tabel 5. 6 Parameter model C | 43 |
| Tabel 5. 7 Hasil Pelatihan Model C..... | 44 |
| Tabel 5. 8 Hasil pengujian model ANN | 45 |
| Tabel 5. 9 Perbandingan <i>close price</i> saham dengan ANN..... | 46 |
| Tabel 5. 10 Hasil MAPE kedua metode | 50 |

ABSTRAK

Susilo, Ni`mah Firsta Cahya, 2024. **Prediksi Closing Price Saham Harian Berbasis Soft Computing**. Thesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Cahyo Crysdiyan (II) Dr. M. Amin Hariyadi, M.T

Kata kunci: prediksi, *close price* saham, *multiple linear regression*, *artificial neural network*

Pasar saham memegang peranan penting dalam perekonomian global yang menghasilkan keuntungan sebagai instrumen investasi pertumbuhan ekonomi. Prediksi harga saham adalah tugas kompleks yang bergantung pada banyak faktor seperti kondisi politik, ekonomi global, laporan keuangan perusahaan, dan pendapatan. Oleh karena itu, untuk memaksimalkan keuntungan dan meminimalkan kerugian, diperlukan adanya teknik memprediksi nilai saham dengan menggunakan analisis tren untuk melihat pergerakan pasar saham. Penelitian ini bertujuan untuk membandingkan kinerja kedua metode *artificial neural network* dan *multiple linear regression*. Data yang digunakan merupakan data saham anggota Jakarta Islamic Index (JII) dengan periode pendirian 1 Maret 2024 hingga 31 Mei 2024. Data saham dengan kode emiten BRMS dan GOTO dipilih karena rasio *free float* kedua saham ini lebih dari 50% dan selisih bobot indeksinya cukup besar. Pengujian MAPE (*Mean Absolute Percentage Error*) dilakukan untuk mengetahui besarnya *error* yang dihasilkan kedua metode. Berdasarkan hasil uji coba dan evaluasi yang telah dilakukan, metode *artificial neural network* menunjukkan hasil prediksi dengan nilai MAPE sebesar 2.86%. sedangkan hasil prediksi *multiple linear regression* menunjukkan nilai MAPE sebesar 2.90%.

ABSTRACT

Susilo, Ni'mah Firsta Cahya, 2024. **Daily Stock Closing Price Prediction Based on Soft Computing**. Thesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Promotor: (I) Dr. Cahyo Crysdiyan (II) Dr. M. Amin Hariyadi

Keyword: stock prediction, linear regression, neural network, closing price

The stock market holds an important role in the global economy that generates profits as an investment instrument for economic growth. Stock price forecasting is a complex task that depends on many factors such as political conditions, the global economy, a company's financial statements, and earnings. Therefore, to maximize profits and minimize losses, it is necessary to predict stock values using trend analysis to see stock market movements. This study aims to determine the influence of features on stock *close price* predictions and compare the performance of the two algorithms. The data taken are stocks of members of the Jakarta Islamic Index (JII) for the establishment period of March 1, 2024 to May 31, 2024. BRMS and GOTO stock data were chosen because the free float ratio of these two stocks is more than 50% and the difference in index weighting is quite large. MAPE (Mean Absolute Percentage *Error*) testing is carried out to determine the magnitude of *error* generated by both algorithms. The artificial neural network method shows prediction results with a MAPE value of 2.86%. This shows that artificial neural networks are better at predicting close stock prices.

البحث

سوسيلو، نعمة فيرستا جهيا، 2024. التنبؤ اليومي لسعر إغلاق السهم بناء على الحوسبة الناعمة. رسالة الماجستير. قسم المعلومات، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: د. جهيو كريسيديان. المشرف الثاني: د. محمد أمين هارياي، الماجستير.

الكلمات الرئيسية: تنبؤ، سعر إغلاق السهم، الانحدار الخطي المتعدد، الشبكة العصبية الاصطناعية.

يلعب سوق الأسهم دورا مهما في الاقتصاد العالمي الذي يولد الأرباح كأداة استثمارية للنمو الاقتصادي. يعد التنبؤ بسعر السهم مهمة معقدة تعتمد على العديد من العوامل مثل الظروف السياسية والاقتصاد العالمي والتقارير المالية للشركة والأرباح. لذلك، لتحقيق أقصى قدر من الأرباح وتقليل الخسائر، من الضروري التنبؤ بقيمة الأسهم باستخدام تحليل الاتجاه لمعرفة تحركات سوق الأسهم. تهدف هذه الرسالة إلى مقارنة أداء كلتي الطريقتين الشبكة العصبية الاصطناعية (*artificial neural network*) والانحدار الخطي المتعدد (*multiple linear regression*). البيانات المستخدمة هي بيانات الأسهم لأعضاء مؤشر جاكرتا الإسلامي (JII) مع فترة تأسيس من 1 مارس 2024 إلى 31 مايو 2024. تم اختيار بيانات الأسهم مع رموز المصدر BRMS و GOTO لأن نسبة التعويم الحر لهذين السهمين تزيد عن 50% والفرق في وزن المؤشر كبير جدا. يتم إجراء اختبار MAPE (متوسط النسبة المئوية للخطأ) لتحديد حجم الأخطاء الناتجة عن كلتا الطريقتين. استنادا إلى نتائج التجارب والتقييمات التي تم إجراؤها، أظهرت طريقة الشبكة العصبية الاصطناعية نتائج تنبؤ بقيمة MAPE تبلغ 2.86%. بينما أظهرت نتائج التنبؤ بالانحدار الخطي المتعدد قيمة MAPE بنسبة 2.90%.

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Saham merupakan ekuitas yang mewakili kepemilikan sebagian kecil perusahaan. Ini memberikan hak kepada pemilik saham atas proporsi aset dan keuntungan korporasi yang sama dengan berapa banyak saham yang mereka miliki (Kementerian Keuangan Republik Indonesia Badan Pengawas Pasar Modal Dan Lembaga Keuangan, 2011). Pasar saham memainkan peran penting dalam ekonomi global dimana menghasilkan keuntungan untuk pertumbuhan ekonomi sebagai salah satu instrumen investasi. Pasar saham menurut Masoud (2017) memiliki karakteristik yang dinamis dan non-linear.

Hidayat (2010) menyatakan bahwa keunggulan saham dibandingkan dengan jenis investasi lainnya yaitu investor dapat menjual saham miliknya lebih tinggi daripada harga beli atau yang disebut *capital gain*. Proses tersebut juga dapat dilakukan sewaktu-waktu dan dimanapun. Keuntungan lainnya yaitu dividen, membagi hasil berasal dari keuntungan perusahaan.

Menurut Al-Khaiyyat (1989), Fahd (2007) dan Osmani & Abdullah (2009) sebagaimana dikutip dalam Alam *dkk.* (2017), pasar saham diperbolehkan dalam syariah dan tidak ada larangan dalam Islam untuk pendirian pasar modal. Adapun Fatwa DSN-MUI No. 135/DSN-MUI/V/2020 tentang Saham merupakan salah satu fatwa yang menjadi dasar pengembangan pasar modal syariah. Fatwa tersebut menjelaskan penerapan prinsip syariah dalam mekanisme perdagangan efek bersifat ekuitas di pasar reguler bursa efek. Berdasarkan Otoritas Jasa Keamanan

pada setiap penerbitan efek syariah diatur dengan akad-akad melalui peraturan OJK No. 53/POJK.04/2015. Akad-akad tersebut meliputi akad *ijarah*, *istishna*, *kafalah*, *mudharabah*, *musyarakah* dan *wakalah*.

Jual beli saham pada pasar saham bertujuan sebagai salah satu upaya investasi yang dilakukan para pelaku saham untuk mendapatkan keuntungan di masa depan sebagaimana Kamus Besar Bahasa Indonesia (2016) menyatakan investasi merupakan suatu penanaman uang atau modal dalam sebuah perusahaan ataupun proyek dengan tujuan memperoleh keuntungan. Adapun investasi pada dalam Islam juga dianjurkan merujuk pada QS. An-Nisa' Ayat 9 yang berbunyi:

وَلْيَخْشَ الَّذِينَ لَوْ تَرَكَوْا مِنْ خَلْفِهِمْ ذُرِّيَّةً ضِعْفًا خَافُوا عَلَيْهِمْ فَلْيَتَّقُوا اللَّهَ وَلْيَقُولُوا قَوْلًا سَدِيدًا

Artinya: “Dan hendaklah takut (kepada Allah) orang-orang yang sekiranya mereka meninggalkan keturunan yang lemah di belakang mereka yang mereka khawatir terhadap (kesejahteraan)nya. Oleh sebab itu, hendaklah mereka bertakwa kepada Allah, dan hendaklah mereka berbicara dengan tutur kata yang benar.”

Berdasarkan tafsir Shihab (2002), ayat tersebut menghimbau manusia untuk tidak berlaku zalim terhadap anak-anak yatim dan hendaklah mereka merasa takut keturunannya yang lemah akan mendapat perlakuan zalim seperti yang dirasakan anak belum mampu mandiri di belakang mereka. Pada ayat tersebut juga dinyatakan bahwa manusia jangan sampai meninggalkan generasi yang lemah moral maupun lemah material. Karena itulah, investasi merupakan salah satu usaha untuk mensejahterakan masa depan terutama untuk generasi Indonesia yang lebih maju.

Memprediksi harga saham merupakan satu hal yang menantang dimana bergantung pada beberapa faktor antaranya kondisi politik, ekonomi global, laporan

keuangan perusahaan dan performansi. Maka dari itu, untuk memaksimalkan keuntungan dan meminimalisir kerugian, teknik untuk memprediksi nilai dari saham dibutuhkan dengan analisa tren untuk melihat pergerakan pada pasar saham. Adapun ayat yang memerintahkan umat Islam untuk menggunakan akal nya pada Al-Qur'an surat Yunus ayat 101 yang berbunyi:

قُلْ انظُرُوا مَاذَا فِي السَّمٰوٰتِ وَالْاَرْضِ وَمَا تُعْبٰى الْاٰلِيٰتِ وَالنُّذُرِ عَنْ قَوْمٍ لَا يُؤْمِنُوْنَ

Artinya: “Katakanlah, ‘Perhatikanlah apa yang ada di langit dan di bumi!’ Tidaklah bermanfaat tanda-tanda (kebesaran Allah) dan rasul-rasul yang memberi peringatan bagi orang yang tidak beriman.”

Berdasarkan tafsir ringkas Kementrian Agama RI, Allah menghukum orang-orang yang tidak mau menggunakan akal nya, maka dalam ayat ini Allah bersabda kepada Nabi Muhammad SAW, beritahukan kepada mereka, lihatlah ciptaan Allah, inilah segala sesuatu yang ada di langit dan di bumi. Jika mereka mau menggunakan akal nya untuk memikirkan tanda-tanda kebesaran dan kekuasaan Allah, tentu saja mereka beriman. Menurut ayat tersebut, penelitian dapat dilakukan oleh manusia dengan menggunakan akal nya untuk mengamati fenomena alam dan sekitar yang terjadi. Hal ini juga berkaitan dengan prediksi *close price* saham yang mengamati *close price* saham berdasarkan masukan-masukan yang ada.

Murkute & Sarode (2015) mengungkapkan bahwa memprediksi harga saham adalah tugas yang menantang karena bergantung pada berbagai faktor termasuk namun tidak terbatas pada kondisi politik, ekonomi global, laporan keuangan dan kinerja perusahaan, dll. Dengan demikian, untuk memaksimalkan keuntungan dan meminimalkan kerugian, teknik memprediksi nilai saham di muka dengan menganalisis tren selama beberapa tahun terakhir, bisa terbukti sangat

berguna untuk membuat pergerakan pasar saham. Metode regresi linier dianggap sebagai pendekatan yang dipertimbangkan karena kesederhanaan dan penggunaannya yang luas pada penelitian sebelumnya untuk masalah serupa. Selain itu, *Artificial Neural Network* mendapatkan memiliki kinerja lebih baik daripada regresi linier dalam kasus di mana terdapat hubungan nonlinier (Hallman, 2019).

Vijha *dkk.* (2020) mengungkapkan bahwa prediksi pasar saham merupakan hal yang sangat menantang. Meningkatnya kemampuan komputasi serta berkembangnya kecerdasan buatan terbukti lebih efisien dalam memprediksi harga saham. Pada penelitian miliknya, dilakukan prediksi *close price* saham dengan menggunakan metode *Artificial Neural Network* dan *Random Forest* lalu untuk evaluasi digunakan RMSE dan MAPE. Penelitian tersebut mengungkapkan bahwa *Artificial Neural Network* memberikan hasil yang lebih unggul dengan nilai RMSE (0.42), MAPE (0.77) dan MBE (0.013).

Vazirani *dkk.* (2020) mengajukan usulan pemodelan *hybrid* untuk memprediksi pasar saham dengan beberapa algoritma machine learning yang dipilih meliputi, regresi linear, *Support Vector Machine* (SVM), *K-Nearest Neighbor* (K-NN) dan *Decision Tree*. Diantara pemodelan-pemodelan *hybrid* yang digunakan, pemodelan *hybrid* regresi linear dengan regresi linear memberikan hasil yang paling unggul. Hasil evaluasi menunjukkan MAE sebesar 6.0103^{-15} , MSE sebesar 5.6911^{-29} , dan RMSE sebesar 7.7526^{-8} .

Berdasarkan kesederhaan penggunaan *multiple linear regression* dan hasil pengujian *artificial neural network* yang unggul pada penelitian-penelitian sebelumnya, penelitian ini mengeksplorasi kinerja kedua metode tersebut. Hasil

kinerja tersebut digunakan untuk mengetahui metode paling optimal dalam memprediksi *close price* saham.

1.2 Pernyataan Masalah

Bagaimana perbandingan kinerja metode dalam memprediksi *close price* saham?

1.3 Tujuan Penelitian

Membandingkan kinerja metode prediksi dalam meramalkan *close price* saham.

1.4 Manfaat Penelitian

Manfaat yang diharapkan diperoleh dari penelitian ini adalah dapat memberikan manfaat bagi investor saham, emitan dan perusahaan sekuritas sebagai pertimbangan pembelian saham dan pertimbangan dalam hal keuangan perusahaan.

1.5 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Data penelitian yang dilakukan prediksi adalah data nilai saham harian di Indonesia pada rentang waktu September 2022-Januari 2024.
2. Data saham harian yang digunakan merupakan data *Jakarta Islamic Index* (JII).
3. Saham yang digunakan merupakan BRMS dan GOTO.

1.6 Sistematika Penulisan

Sistematika penulisan pada penelitian ini adalah:

1. Bab I Pendahuluan yang berisi latar belakang masalah, pernyataan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan.
2. Bab II Studi Pustaka membahas tentang prediksi *close price* saham dan kerangka teori yang berisi penelitian-penelitian sebelumnya.
3. Bab III Metodologi Penelitian membahas tentang desain penelitian yang terdiri atas pengumpulan data, pengembangan sistem, proses prediksi dengan *Artificial Neural Network* dan *Multiple Regression*, pengujian, komparasi kinerja metode serta riset instrumen.
4. Bab IV *Multiple linear regression* membahas tentang desain, training dan uji coba hasil prediksi dengan menggunakan *multiple linear regression*.
5. Bab V *Artificial Neural Network* membahas tentang desain, *training* dan uji coba hasil prediksi dengan menggunakan *artificial neural network*.
6. Bab VI Evaluasi Kinerja Metode membahas perbandingan kinerja kedua metode.
7. Bab VII Penutup membahas tentang kesimpulan dan saran.

BAB II

STUDI PUSTAKA

2.1 Prediksi *Closing Price* Saham

Memprediksi harga saham merupakan satu hal yang menantang dimana bergantung pada beberapa faktor diantaranya kondisi politik, ekonomi global, laporan keuangan perusahaan dan performansi (Vijh *dkk.* 2020). Maka dari itu, untuk memaksimalkan keuntungan dan meminimalisir kerugian, teknik untuk memprediksi nilai dari saham dibutuhkan dengan analisa tren untuk melihat pergerakan pada pasar saham.

Penelitian oleh Maulana dan Kumalasari (2019) memprediksi harga saham GGRM dilakukan dengan membandingkan beberapa model algoritma yaitu *Neural Network*, *Linear Regression*, *Support Vector Machine*, *Gaussian Process*, dan *Polynomial Regression*. Untuk mengukur akurasi setiap model algoritma digunakan model validasi *10 Fold Cross Validation* dan evaluasi menggunakan *Root Mean Square Error (RMSE)*. Data harga saham GGRM dapat diprediksi dengan menggunakan model algoritma *Neural Network*, dengan hasil akurasi prediksi RMSE 612.474 +/- 89.402 (mikro: 618.916 +/- 0.000) paling kecil dibandingkan dengan model algoritma lainnya, sehingga dengan prediksi ini dapat membantu dalam memprediksi harga saham GGRM di pasar saham.

Secara umum, metode SVM berbasis teknologi teks *mining* menunjukkan hasil yang luar biasa dalam memprediksi pasar saham terutama dalam memprediksi harga saham tertentu. Sebagai perbandingan, ketika memprediksi kecenderungan saham, SVC tidak cukup baik, meskipun itu juga membuktikan pentingnya

dokumen berita (Xie dan Jiang, 2019). Penelitian ini menghasilkan nilai MSE sebesar 0.00328. Namun, SVM belum sempurna. Ketika jumlah berita rendah, hasil prediksi tidak cukup baik. Dalam kasus seperti itu, bahkan beberapa algoritma regresi linier dasar dan sederhana dapat melakukan pekerjaan yang lebih baik.

Penelitian Vazirani *dkk.* (2020) menggunakan dua metode untuk memprediksi harga yang pertama menggunakan algoritma tunggal dan model *hybrid* lainnya. Ketika model *hybrid* diterapkan dengan algoritma dasar sebagai regresi linier, meskipun kompleksitas komputasi meningkat tetapi diamati bahwa ketika regresi linier digunakan sebagai algoritma kedua maka MAE adalah 6.0103^{-15} , MSE adalah 5.6911^{-29} , dan RMSE adalah 7.7526^{-8} .

Disimpulkan bahwa model *hybrid* dengan regresi linier yang ditambahkan dengan regresi linier lain mencapai hasil yang efisien, akurat dan lebih baik jika dibandingkan dengan KNN, SVM, *decision tree* dan *random forest* saja karena kesalahannya minimal sehingga sangat optimal untuk memprediksi harga saham riil dan meminimalkan ketidakpastian nilai masa depan.

Penelitian oleh Vijha *dkk.* (2020) membandingkan prediksi nilai saham dengan menggunakan algoritma machine learning *Artificial Neural Network* (ANN) dengan Random Forest. Data nilai saham terutama closing price yang telah diprediksi dengan menggunakan dua algoritma tersebut menghasilkan ANN memberikan prediksi harga saham yang lebih baik dibandingkan dengan *Random Forest*. Hasil menunjukkan bahwa nilai terbaik diperoleh model ANN memberikan RMSE (0,42), MAPE (0,77) dan MBE (0,013).

Traders dan *stackholder* saat ini mengandalkan banyak parameter kompleks dan perhitungan model keuangan untuk membuat keputusan beli-jual-tahan yang tepat. Lanbouri dan Achhab (2020) menghasilkan penelitian yang memiliki akurasi yang masih di bawah 50%. Model ini didasarkan pada algoritma *Long-Short Term Memory* menggunakan data historis Frekuensi Tinggi. Ini menegaskan bahwa harga Penutupan dapat diprediksi 10 menit ke depan, 5 menit ke depan dan dengan kinerja yang lebih baik satu menit ke depan tanpa menggunakan Indikator Teknis.

Penelitian oleh Liu *dkk.* (2017) menggunakan model jaringan berdasarkan algoritma *Support Vector Machine* (SVM) yang ditingkatkan untuk mewujudkan penilaian yang benar dari tren harga saham, sehingga mencapai tujuan prediksi harga saham yang akurat, dan meningkatkan akurasi prediksi sambil memastikan kecepatan model. Pemodelan yang berdasarkan SVM mengungguli pemodelan-pemodelan yang lain dengan nilai akurasi tertinggi dimiliki oleh pemodelan pemodelan RBF SVM memiliki nilai akurasi sebesar 65.64%, standar deviasi sebesar 0.233 serta waktu performa sebesar 145.9.

Penelitian oleh Soujanya *dkk.* (2020) mendemonstrasikan pemodelan untuk memprediksi nilai saham dengan akurasi yang lebih tinggi dibandingkan dengan model machine learning sebelumnya. Metode yang digunakan pada penelitian tersebut adalah perbandingan antara *Multiple linear regression* dan *Linear Regression*. Hasil akurasi yang ditunjukkan oleh kedua metode tersebut menghasilkan nilai RMSE 24.63 dan MAPE 4.07% untuk *Multiple linear regression*. Sedangkan, untuk hasil akurasi dengan *Linear Regression* menghasilkan RMSE sebesar 0.00014 serta MAPE sebesar 21.69%.

Algoritma PGCSA digunakan untuk mencapai bobot dan bias ELM yang relevan untuk meningkatkan efektivitas ELM konvensional. Pengaruh model hybrid PGCSA ELM untuk memprediksi harga penutupan hari berikutnya dari tujuh indeks saham yang berbeda diamati dengan menggunakan ukuran kinerja, indikator teknis dan uji hipotesis (*paired t-test*). Tujuh indeks saham dipertimbangkan dengan memasukkan data selama wabah Covid 19. Model ini diuji dengan membandingkan dengan teknik yang ada yang diusulkan dalam karya yang diterbitkan. Pemodelan PGCSA ELM memiliki nilai *error* sebesar 0.0100 yang memiliki *error* terkecil dibandingkan dengan *error* pada pemodelan CSA ELM sebesar 3.0044 dan *error* pada pemodelan ELM sebesar 0.0155. terbukti bahwa model peramalan PGCSA-ELM mengungguli model peramalan CSA-ELM dan ELM untuk memprediksi harga penutupan hari berikutnya (Das *dkk.*, 2021).

Penelitian oleh Kumar *dkk.* (2021) mengusulkan sistem kecerdasan neuro-*fuzzy hybrid* berbasis *swarm intelligence* dengan menggabungkan teknik DPSO yang mencari secara otomatis jumlah indikator teknis yang optimal dan ANFIS melakukan tugas peramalan dua indeks saham utama India yaitu Nifty 50 dan Sensex. Performa akurasi dari masing-masing algoritma menghasilkan bahwa DPSO ANFIS mengungguli dengan nilai MSE 4.16E-04, RMSE 2.04E-02, MAAPE 7.85%, dan 1.68E-02 Theil's U untuk indeks saham Nifty 50. Hal ini juga berlaku pada akurasi ideks saham Sensex dengan nilai MAPE4.48E-04, RMSE 2.12E-02, MAAPE 10.01% serta Theil's U sebesar 1.86E-02.

Memprediksi keberhasilan saham mungkin menjadi aset utama bagi lembaga pencarian saham dan dapat memberikan efek nyata pada masalah yang dihadapi investor ekuitas (Akhtar *dkk.*, 2022). Perbandingan SVM dan *R Forest*

Classifier digunakan karena kedua algoritma ini mudah untuk menangani berbagai jenis dan berbagai jenis atribut. Model SVM pada data set menghasilkan akurasi 78.7% dimana akurasi pada *random forest classifier* sebesar 80.8%.

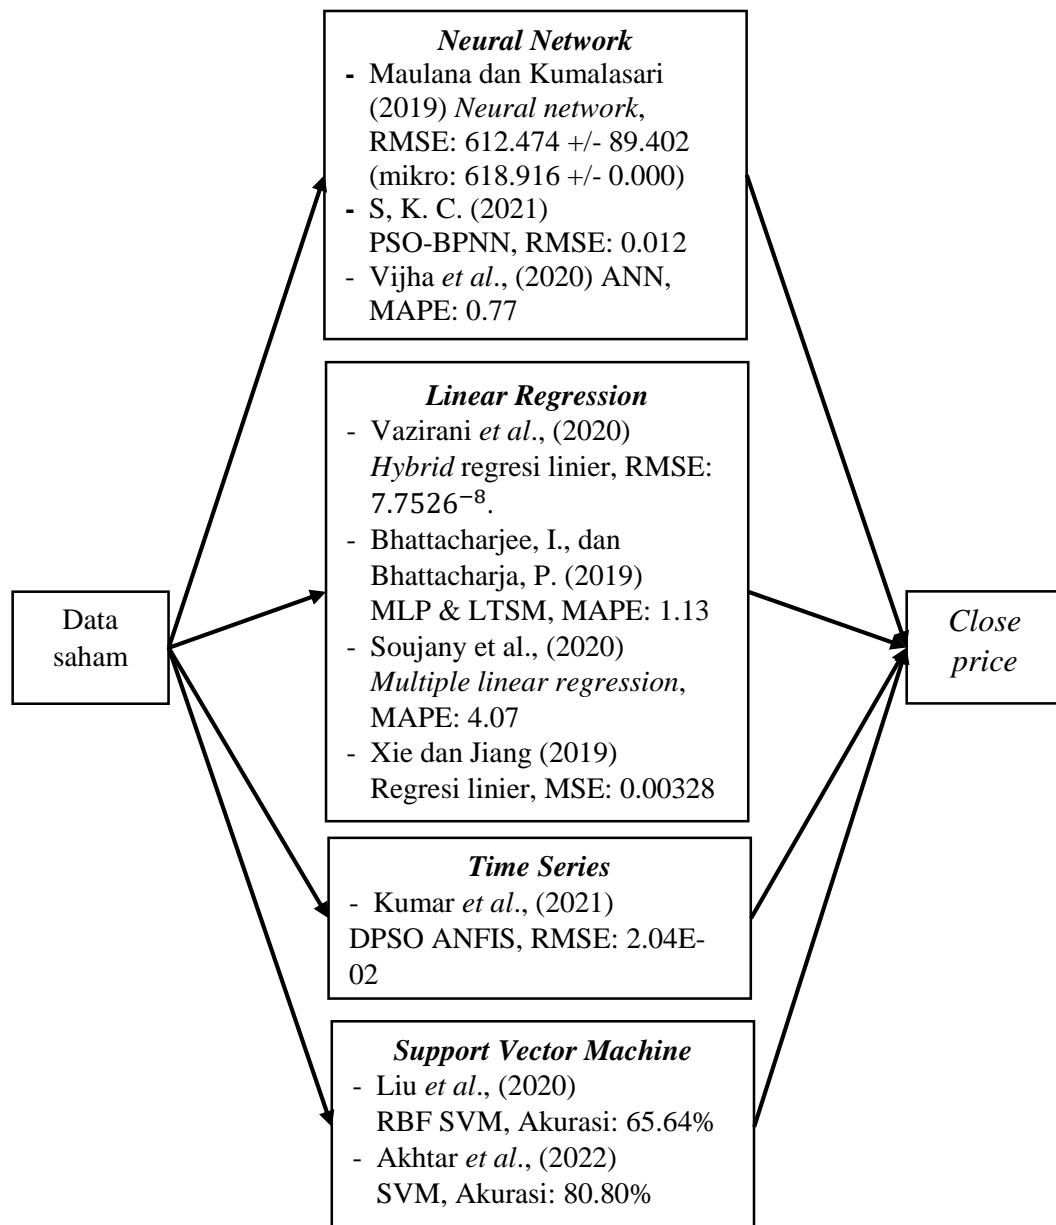
2.2 Kerangka Teori

Soft computing merupakan kumpulan konsep yang sistematis, fungsional, dan dinamis yang bertujuan untuk secara efektif melampaui kerumitan yang dialami dalam masalah dunia nyata (Sharma dan Chandra, 2019). Kerangka teori pada penelitian ini mengacu pada jurnal penelitian-penelitian sebelumnya mengenai *soft computing* yang ditunjukkan pada Gambar 2.1.

Berdasarkan Gambar 2.1, kerangka teori terbagi menjadi *input*, proses serta *output*. Data saham merupakan *input* sedangkan *close price* saham merupakan *output*. Tahapan proses meliputi metode yang berdasarkan *weighting*, variabel independen, *time series* serta *hyperplane*. Pada metode berdasarkan *weighting* ditunjukkan penelitian Maulana dan Kumalasari (2019) dengan metode *neural network* menghasilkan nilai RMSE terendah sebesar 612.474 +/- 89.402 (mikro: 618.916 +/- 0.000). Pada metode berdasarkan variabel independen ditunjukkan penelitian oleh Vazirani dkk. (2020) dengan metode *hybrid* regresi linier menghasilkan nilai RMSE terendah sebesar 7.7526 - 8. Penelitian milik Kumar dkk. (2021) dengan menggunakan metode DPSO ANFIS, yang berdasarkan *time series* menghasilkan nilai RMSE 2.04E-02. Pemodelan berdasarkan *hyperplane* dengan penelitian Liu dkk. (2020) dengan metode RBF dan SVM menghasilkan akurasi 65.64%.

Adapun algoritma multi *layer* perceptron dan LSTM yang juga termasuk ke dalam artificial neural network memiliki nilai MAPE sebagai hasil uji coba sebesar 1.13 (Bhattacharjee & Bhattacharja, 2019). Penelitian Soujanya *dkk.* (2020) juga membuktikan *multiple linear regression* mampu memecahkan permasalahan dengan hasil uji coba MAPE sebesar 4.07.

Mean Absolute Percentage Error (MAPE) lebih sering digunakan dibanding metode evaluasi lainnya karena sifatnya yang tidak bias dan dapat mengatasi kelemahan ukuran. MAPE banyak digunakan di perusahaan dan organisasi untuk akurasi peramalan (Tofallis, 2015). MAPE telah diajukan sebagai fungsi *cost* yang lebih akurat untuk pengoptimalan analisis gambar dan video yang mengatasi masalah seperti sensitivitas terhadap outlier dan bias yang diamati dalam pengukuran kesalahan tradisional. Oleh karena itu, sifatnya yg mengabaikan bias dan kemampuan MAPE untuk mengatasi kelemahan metrik lainnya menjadikannya pilihan yang lebih baik untuk penilaian akurasi perkiraan dan pemilihan model.



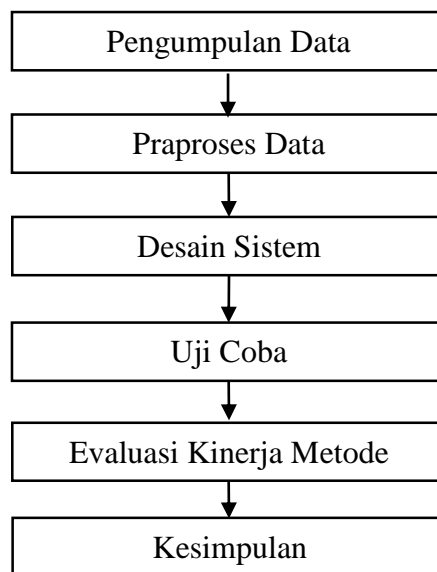
Gambar 2. 1 Kerangka Teori

BAB III

STRATEGI PENELITIAN

3.1 Prosedur Penelitian

Pada penelitian ini terdiri atas beberapa tahapan yang meliputi pengumpulan data saham sebagai input dan output. Data yang telah diperoleh dilakukan praproses data, desain sistem, selanjutnya adalah uji coba pada masing-masing metode yaitu artificial neural network dan multiple linear regression. Hasil prediksi kedua metode tersebut dilakukan komparasi untuk mendapatkan kesimpulan. Prosedur penelitian ditunjukkan pada Gambar 3.1.



Gambar 3. 1 Prosedur Penelitian

3.1.1 Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data saham pada bursa efek Indonesia yang didapat dengan mengakses web laman bursa efek Indonesia dengan alamat tautan <https://finance.yahoo.com/>. Data yang diambil merupakan data saham anggota indeks Jakarta Islamic Index (JII) yang terlampir pada Tabel 3.1

pada periode efektif konstituen 1 Maret 2024 s.d. 31 Mei 2024. PT. Bursa Efek Indonesia (BEI) yang kini dipimpin oleh Iman Rachman sebagai Direktur Utama melalui RUPST pada 29 Juni 2022, menganut sistem *Corporate Governance* (GCG) yang selalu melakukan audit secara berkala serta memiliki beberapa sertifikasi manajemen yaitu:

1. Sistem Manajemen Mutu ISO 9001
2. Sistem Manajemen Keamanan Informasi ISO 27001
3. Sistem Manajemen Kelangsungan Usaha ISO 22301
4. Sistem Manajemen Anti Penyuapan ISO 37001

El-Nader (2018) menyatakan pada penelitiannya bahwa bahwa semakin besar rasio free float dapat meminimalkan permainan harga saham yang dilakukan oleh investor. Berdasarkan Lampiran Pengumuman BEI No. Peng-00040/BEI.POP/02-2024 tanggal 23 Februari 2024 yang ditunjukkan pada Tabel 3.1, data saham Bumi Resources Minerals Tbk PT dengan nama emiten BRMS dan saham GoTo Gojek Tokopedia PT Tbk dengan nama emiten GOTO dipilih sebagai data pada pelatihan ini karena kedua saham tersebut memiliki nilai *rasio free float* diatas 50% dan selisih bobot pada indeks yang cukup tinggi. *Rasio free float* di pasar terbuka merupakan jumlah seluruh saham yang dimiliki masyarakat dengan kepemilikan saham kurang dari 5%. *Rasio free float* dihitung dengan membandingkan jumlah saham yang diperdagangkan bebas dengan jumlah seluruh saham yang tercatat di bursa (Puspitasari, 2015)


Tabel 3.1 Daftar Saham Anggota Indeks *Jakarta Islamic Index* (JII)

| No. | Kode | Rasio Free Float | Jumlah Saham untuk Indeks (lembar) | | | Bobot pada Indeks | | |
|-----|------|------------------|------------------------------------|--------------------------|-------|-------------------|----------------|-------|
| | | | Pra Evaluasi | Pasca Evaluasi (15% Cap) | Ket | Pra Evaluasi | Pasca Evaluasi | Ket |
| 1 | ACES | 40.03% | 6832560000 | 6865145000 | Naik | 0.70% | 0.71% | Naik |
| 2 | ADMR | 16.16% | 6606584770 | 6606584770 | Tetap | 1.23% | 1.25% | Naik |
| 3 | ADRO | 49.91% | 14860677945 | 15964193634 | Naik | 4.62% | 5.00% | Naik |
| 4 | AKRA | 39.31% | 7381016610 | 7890882865 | Naik | 1.54% | 1.66% | Naik |
| 5 | ANTM | 34.84% | 8372318430 | 8372318430 | Tetap | 1.58% | 1.59% | Naik |
| 6 | ASII | 45.09% | 18254034111 | 18254034111 | Tetap | 12.30% | 12.41% | Naik |
| 7 | BRIS | 9.92% | 4511986311 | 4530253462 | Naik | 1.41% | 1.43% | Naik |
| 8 | BRMS | 52.16% | 73968733844 | 73954555440 | Turun | 1.37% | 1.38% | Naik |
| 9 | CPIN | 34.18% | 6578877600 | 5604836400 | Turun | 3.99% | 3.43% | Turun |
| 10 | EMTK | 25.71% | 15445169724 | 15764536806 | Naik | 0.93% | 0.96% | Naik |
| 11 | EXCL | 33.75% | 4349449079 | 4430845349 | Naik | 1.25% | 1.28% | Naik |
| 12 | GOTO | 75.31% | 859128049894 | 904781617082 | Naik | 8.82% | 9.38% | Naik |
| 13 | ICBP | 20.00% | 2332381600 | 2332381600 | Tetap | 3.44% | 3.47% | Naik |
| 14 | INCO | 20.38% | 2025025831 | 2025025831 | Tetap | 0.96% | 0.97% | Naik |
| 15 | INDF | 49.59% | 4352457416 | 4354213501 | Naik | 3.69% | 3.72% | Naik |
| 16 | INKP | 36.62% | 2003473953 | 2003473953 | Tetap | 2.00% | 2.02% | Naik |
| 17 | INTP | 41.97% | 1545012944 | 1545012944 | Tetap | 1.79% | 1.81% | Naik |
| 18 | ITMG | 34.86% | 392422953 | 393891855 | Naik | 1.33% | 1.35% | Naik |
| 19 | KLBF | 42.65% | 19260987675 | 19992239580 | Naik | 3.68% | 3.86% | Naik |
| 20 | MAPI | 49.00% | 8074240000 | 8134000000 | Naik | 2.00% | 2.03% | Naik |
| 21 | MDKA | 47.04% | 11344155288 | 11341744203 | Turun | 3.44% | 3.47% | Naik |
| 22 | MIKA | 37.77% | 4858005180 | 5380846206 | Naik | 1.73% | 1.94% | Naik |
| 23 | PGAS | 43.04% | 10433545128 | 10433545128 | Tetap | 1.58% | 1.59% | Naik |
| 24 | PTBA | 33.72% | 3851356387 | 3884766299 | Naik | 1.29% | 1.31% | Naik |
| 25 | SMGR | 48.77% | 3292726101 | 3292726101 | Tetap | 2.63% | 2.66% | Naik |
| 26 | TLKM | 47.86% | 31433145052 | 27700488656 | Turun | 16.87% | 15% | Turun |
| 27 | TPIA | 15.06% | 12890220219 | 13028638691 | Naik | 7.73% | 7.88% | Naik |
| 28 | UNTR | 40.44% | 1410364095 | 1508466649 | Naik | 4.17% | 4.50% | Naik |
| 29 | UNVR | 14.47% | 5516490000 | 5520305000 | Naik | 1.91% | 1.92% | Naik |
| 30 | WIFI | 49.89% | 1168707543 | 1177082268 | Naik | 0.02% | 0.02% | Tetap |

3.1.2 Desain sistem

Desain pada penelitian ini ditunjukkan pada Gambar 3.2 yang meliputi data *close price* saham harian dilakukan *preprocessing* lalu diproses dengan kedua metode sehingga diperoleh model untuk masing-masing metode. Proses prediksi dengan *artificial neural network* dan *multiple regression* diterapkan pada data

tersebut. Hasil prediksi oleh kedua algoritma kemudian dilakukan evaluasi untuk menentukan hasil uji coba terbaik seperti ditunjukkan pada Gambar 3.2.



Gambar 3.2 Desain pengembangan sistem

A. Data Saham

Pemilihan atribut *input* dan *output* sangat penting pada penelitian ini yang bertujuan untuk meningkatkan performansi dan mengurangi waktu komputasi sistem. Data pada penelitian ini menggunakan 5 fitur diperoleh berdasarkan penelitian Bhuriya *dkk.* (2017), Vijha *dkk.* (2020), dan Soujanya *dkk.* (2020). Adapun fitur-fitur tersebut ditunjukkan pada Tabel 3.2.

Tabel 3. 2 Ilustrasi dan atribut data penelitian

| No. | Atribut | Rentang Nilai | Satuan |
|-----|---------------------------|---------------|-----------------|
| 1 | <i>Date</i> | - | <i>Datetime</i> |
| 2 | Kode Saham | - | <i>String</i> |
| 3 | <i>Open Previous</i> | 58-442 | <i>Numeric</i> |
| 4 | <i>High Previous</i> | 54-398 | <i>Numeric</i> |
| 5 | <i>Low Previous</i> | 56-404 | <i>Numeric</i> |
| 6 | <i>Adj Close Previous</i> | 56-404 | <i>Numeric</i> |
| 7 | <i>Close Previous</i> | 56-404 | <i>Numeric</i> |

Masukan pada penelitian ini merupakan 5 data yang telah diperoleh dari data mentah dengan format *comma separated values* (.csv). Berdasarkan Tabel 3.2, masukan yang digunakan meliputi *date*, kode saham, *open previous*, *high previous*, *low previous*, *adj close previous*, dan *close previous*. *Date* dan kode saham merupakan identitas waktu dan kode saham. *Open previous* merupakan nilai pembukaan harga saham pada hari sebelumnya dengan rentang nilai 58-442. *High*

previous merupakan harga tertinggi saham diperdagangkan pada hari sebelumnya dengan rentang nilai 54-398. *Low previous* adalah harga terendah pada hari sebelumnya dengan rentang 56-404. *Adj close previous* merupakan harga penutupan yang disesuaikan mengacu pada harga saham setelah membayar dividen dengan rentang 56-404. Sedangkan *close previous* merupakan nilai penutupan saham pada hari sebelumnya dengan rentang nilai 56-404.

B. Praproses Data

Pada tahap ini, data yang telah diperoleh dilakukan pembersihan dan pengintegrasian data agar siap untuk dianalisis. Apabila ditemukan data dengan nilai null, maka data disesuaikan dengan mengubah nilainya menjadi 0. Pada Tabel 3.3 ditunjukkan data yang telah disesuaikan untuk dilakukan analisis pada penelitian ini.

Tabel 3. 3 Data harga saham

| Date | Kode Saham | Open | High | Low | Adj Close | Close Prev | Close |
|-------------|-------------------|-------------|-------------|------------|------------------|-------------------|--------------|
| 9/11/2023 | GOTO | 94 | 95 | 92 | 93 | 93 | 89 |
| 9/12/2023 | GOTO | 93 | 93 | 86 | 89 | 89 | 88 |
| 9/13/2023 | GOTO | 89 | 89 | 86 | 88 | 88 | 87 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| | | | | | ... | ... | ... |
| 1/29/2024 | BRMS | 155 | 155 | 145 | 146 | 146 | 148 |
| 1/30/2024 | BRMS | 147 | 151 | 146 | 148 | 148 | 154 |

3.1.3 Proses Prediksi

Proses prediksi *close price* saham harian yang berbasis *soft computing* pada penelitian ini meliputi prediksi dengan menggunakan metode *Artificial Neural Network* yang selanjutnya disebut ANN dan *Multiple linear regression* yang selanjutnya disebut MLR. Proses prediksi dimulai dengan menentukan atribut masukan lalu data diproses dengan kedua metode yang telah ditentukan. Pemodelan

kedua metode dilakukan evaluasi dan validasi. Hasil prediksi dari kedua metode kemudian dibandingkan untuk menemukan metode dengan kinerja paling optimal.

A. Model MLR

Multiple linear regression merupakan regresi linear dengan pemodelan satu variabel dependen dan variabel independen yang lebih dari satu. Simple linear regression bertujuan untuk mengetahui hubungan linear antara satu variabel dependen dan satu variabel independen, sedangkan *multiple linear regression* fokus kepada relasi linear satu variabel dependen dan variabel independen yang lebih dari satu. *Multiple linear regression* melibatkan permasalahan yang lebih daripada simple linear regression yang meliputi kolinearitas, inflasi varians, tampilan grafik diagnosis regresi dan deteksi outlier regresi serta observasi yang berpengaruh.

Pada *multiple linear regression*, data yang dimiliki dibagi menjadi variabel bebas (variable independent) dan variabel terikat (dependent variable) seperti yang telah dijelaskan pada Bab III. Variabel bebas dilambangkan dengan X sedangkan variabel terikat dilambangkan dengan Y. Variabel terikat pada penelitian ini merupakan *close price* saham. Untuk menghitung *close price* prediksi, perlu ditentukan nilai koefisien regresi untuk masing-masing variabel bebas. Jumlah nilai koefisien tersebut sesuai dengan jumlah variabel bebas. Proses prediksi dengan metode MLR lebih lanjutnya dijelaskan pada Bab IV.

B. Model ANN

Arsitektur ANN pada dasarnya terdiri atas *input layer* dan *output layer*. Sedangkan backpropagation terdiri atas *input layer*, *hidden layer* dan *output layer*. Menentukan jumlah *hidden layer* dan node *hidden layer* yang optimal dalam ANN


adalah tugas yang menantang dan sering kali memerlukan kombinasi berdasarkan penelitian yang dilakukan. Arsitektur jaringan yang diusulkan pada penelitian ini menggunakan 3 lapisan NN yang meliputi 5 node pada lapisan *input*, 4 node pada lapisan tersembunyi, dan 1 node pada lapisan *output*.

Thomas (2017) menyatakan bahwa dengan kinerja NN dua *hidden layer* memiliki hasil yang lebih baik dalam sembilan dari sepuluh kasus. Oleh karena itu, untuk arsitektur kedua yang diusulkan adalah menggunakan 4 lapisan NN yang terdiri atas 5 node pada *input layer*, 4 node *hidden layer*, 8 node *hidden layer* dan 1 *output layer*. Hal berikut didasarkan oleh penelitian Heaton (2017) yang membuat metode praktis untuk menentukan jumlah neuron yang dapat diterima untuk digunakan pada *hidden layer* adalah:

1. Jumlah neuron tersembunyi harus berada di antara ukuran lapisan masukan dan ukuran lapisan keluaran.
2. Jumlah neuron tersembunyi harus $\frac{2}{3}$ dari ukuran lapisan masukan, ditambah ukuran lapisan keluaran.
3. Jumlah neuron tersembunyi harus kurang dari dua kali ukuran lapisan masukan.

Kinerja ANN juga dipengaruhi oleh beberapa parameter seperti fungsi aktivasi, learning rate dan optimizer. Adapun untuk fungsi aktivasi yang digunakan pada penelitian ini merupakan ReLU yang memiliki *output* dengan rentang mulai dari 0 hingga max yang sesuai dengan permasalahan prediksi. Sedangkan untuk learning rate yang digunakan adalah 0.01, 0.05 dan 0.1.

Pada umumnya arsitektur ANN terdiri atas *layer* yang memiliki beberapa node. Pada Gambar 3.2 ditunjukkan arsitektur ANN pada penelitian ini yang terdiri dari *input layer*, *hidden layer* serta *output layer*.



Gambar 3. 3 Arsitektur ANN

Pada tahapan *feedforward*, masukan dimasukkan ke dalam jaringan saraf, dan jaringan menghitung keluarannya. Selama propagasi mundur, kesalahan antara keluaran yang diprediksi dan keluaran sebenarnya dihitung, dan bobot serta bias setiap neuron disesuaikan untuk mengurangi kesalahan. Siklus tersebut dilakukan berulang sesuai jumlah epoch yang ditentukan untuk mendapatkan hasil prediksi *close price* yang lebih akurat dengan meminimalkan *error*. Proses prediksi dengan metode MLR lebih lanjutnya dijelaskan pada Bab V.

3.1.4 Skenario Pengujian

Uji coba pada penelitian ini dilakukan dengan beberapa tahapan. Langkah pertama merupakan perolehan nilai prediksi *close price* saham untuk masing-

masing proses prediksi. *Close price* saham sebenarnya dan hasil prediksi *close price* saham tersebut digunakan sebagai *input* untuk melakukan proses perhitungan MAPE. Nilai MAPE merupakan acuan evaluasi untuk masing-masing proses prediksi.

MAPE (*Mean Absolute Percentage Error*) digunakan untuk mengukur keakuratan suatu metode. MAPE menunjukkan nilai kesalahan absolut rata-rata untuk setiap catatan dalam kumpulan data untuk menghitung seberapa akurat *close price* perkiraan dibandingkan dengan *close price* sebenarnya. Nilai MAPE dihitung dengan persamaan 3.1 dimana A_t merupakan hasil observasi, F_t merupakan hasil. Selisih dari kedua variable tersebut dibagi dengan A_t . Nilai tersebut dijumlahkan dan dibagi dengan n banyaknya data yang ada.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (3.1)$$

Hasil prediksi *close price* saham yang telah diperoleh dengan masing-masing metode selanjutnya dilakukan analisa. Analisa dilakukan untuk menemukan factor-faktor yang berpengaruh terhadap nilai *error* yang dihasilkan. Selanjutnya dilakukan perbandingan terhadap nilai *error* pada hasil prediksi. Metode terbaik untuk prediksi *close price* saham didapatkan dari analisa-analisa yang telah dilakukan sebelumnya.

3.2 Instrumen Penelitian


Instrumen pada penelitian ini meliputi variabel bebas, variabel antara dan variabel terikat. Variabel bebas yang digunakan merupakan fitur-fitur yang tersedia pada saham harian yang ditunjukkan pada Tabel 3.2. Variabel antara merupakan prediksi *close price* saham yang diperoleh dari hasil proses prediksi dengan

artificial neural network dan *multiple linear regression*. Variabel terikat merupakan nilai *error* hasil dari uji coba penelitian. Hasil uji coba tersebut diperoleh dengan penghitungan MAPE untuk masing-masing hasil prediksi *close price* saham.

BAB IV

MULTIPLE LINEAR REGRESSION

Proses prediksi dengan metode MLR pada penelitian ini menggunakan 5 *input* sebagai variabel bebas dengan *output* berupa *close price* saham. Stochastic gradient descent diterapkan juga pada penelitian karena berperan penting dalam optimasi metode MLR, yaitu dengan memperbarui parameter model yang terkait dengan koefisien setiap fitur. Adapun alur proses prediksi dengan MLR meliputi proses desain, pemodelan, training, testing, dan uji coba seperti pada Gambar 4.1



Gambar 4. 1 Alur *multiple linear regression*

4.1 Desain

Dalam konteks analisis regresi linier berganda, kumpulan data berisi satu variabel terikat dan beberapa variabel bebas. Fungsi garis regresi linier berubah untuk memasukkan lebih banyak factor.

Bentuk umum dari pemodelan *multiple regression* tercantum pada Persamaan 3.1, dimana y merupakan variabel dependen, $\beta_0, \beta_1, \beta_2 \dots, \beta_p$ merupakan koefisien regresi, $x_1, x_2, x_3, \dots, x_p$ merupakan variabel independen, dan ε diasumsikan sebagai normal *error* independen (Xin dan Xiao, 2009).

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \varepsilon \quad (4.1)$$

$$\beta = [\beta_0, \beta_1, \beta_2 \dots, \beta_p] \quad (4.2)$$

$$X = \begin{bmatrix} x_1 \\ \dots \\ x_p \end{bmatrix} \quad (4.3)$$

Variabel independen pada persamaan 4.1 merupakan *input-input* yang digunakan pada penelitian ini adalah:

x_1 = open price sebelumnya
 x_2 = tertinggi sebelumnya
 x_3 = terendah sebelumnya
 x_4 = *adj close* sebelumnya
 x_5 = *close price* sebelumnya

4,2 Training

Proses training pada MLR dimulai dengan *update* koefisien regresi dengan persamaan 4.4 dimana β_p merupakan koefisien regresi atau bobot, α adalah learning rate, $f(x_i)$ merupakan prediksi dengan model yang sudah dibangun, y_i adalah target sedangkan x_{ip} data ke-i pada *input* ke-p. Proses ini dilakukan sebanyak epoch yang telah ditentukan. Stochastic Gradient Descent memperkirakan setiap sampel pada satu waktu dan model diperbarui seiring dengan learning rate.

$$\beta_p = \beta_p - \alpha(f(x_i) - y_i) x_{ip} \quad (4.4)$$

Hasil dari pelatihan model MLR ditunjukkan pada Tabel 4.1. Pada tabel tersebut ditunjukkan MAPE pada proses pelatihan dengan masing-masing learning rate. Model dengan *learning rate* 0.01 memiliki rata-rata MAPE yang paling rendah yaitu sebesar 3.22%. Dalam hal ini, percobaan ke-5 menunjukkan nilai MAPE terendah dengan 3.15%.

Tabel 4. 1 Hasil Pelatihan Model MLR

| Percobaan ke- | MAPE | | |
|---------------|-----------------|-----------------|----------------|
| | $\alpha = 0.01$ | $\alpha = 0.05$ | $\alpha = 0.1$ |
| 1 | 3.239 | 3.398 | 3.497 |
| 2 | 3.312 | 3.402 | 3.527 |
| 3 | 3.209 | 3.380 | 3.578 |

Tabel 4. 2 Hasil Pelatihan Model MLR

| | | | |
|-----------|-------|-------|-------|
| 4 | 3.199 | 3.324 | 3.536 |
| 5 | 3.149 | 3.372 | 3.452 |
| Rata-rata | 3.222 | 3.375 | 3.518 |
| Min | 3.149 | 3.324 | 3.452 |
| Max | 3.312 | 3.402 | 3.578 |


Merujuk pada persamaan 4.4, dihitung masing-masing koefisien regresi dan intercept untuk membentuk satu model regresi. Hal tersebut berfungsi untuk melakukan prediksi pada data testing pada langkah selanjutnya.

Tabel 4. 3 Koefisien Regresi

| | |
|---|---------------|
| <i>Intercept</i> (β_0) | $5.09e^{10}$ |
| Koefisien open price Sebelumnya (β_1) | $2.54e^{10}$ |
| Koefisien tertinggi Sebelumnya (β_2) | $-8.96e^{10}$ |
| Koefisien terendah sebelumnya (β_3) | $4.23e^{11}$ |
| Koefisien adj close sebelumnya (β_4) | $-1.95e^{11}$ |
| Koefisien <i>close price</i> sebelumnya (β_5) | $-1.95e^{11}$ |

Koefisien regresi yang telah diperoleh membentuk satu persamaan model *multiple linear regression* berdasarkan data training. Berdasarkan Tabel 4.1, maka model MLR pada penelitian ini ditunjukkan oleh Persamaan 4.4 dimana x merupakan variabel independen pada penelitian ini. Proses pelatihan dengan model MLR menunjukkan grafik konvergen pada Gambar 4.2, dapat dilihat bahwa nilai *loss* pelatihan yang semakin stabil dengan bertambahnya *epoch*.

$$Y = 5.09e^{10} + 2.54e^{10}X_1 + (-8.96e^{10})X_2 + 4.23e^{11}X_3 + (-1.95e^{11})X_4 + (-1.95)X_5 \quad (4.4)$$



Gambar 4. 2 Nilai *loss* pelatihan MLR

4.5 Uji Coba

Tahap uji coba metode *multiple linear regression* pada penelitian ini terdiri atas uji asumsi statistik yang meliputi koefisien determinasi, aspek multikolinearitas, autokorelasi, normalitas serta uji hasil prediksi. Pengujian hasil prediksi dilakukan untuk mengetahui *error* pada hasil prediksi yang berdasarkan tinggi rendahnya nilai MAPE.

4.5.1 Uji Asumsi Statistik

Pengujian ini dilakukan untuk memastikan persamaan regresi linier yang dihasilkan dapat memprediksi harga penutupan saham secara optimal. Uji ini meliputi aspek autokorelasi dan normalitas. Fokus utamanya adalah pada koefisien determinasi yang diperoleh. Hal ini dikarenakan semakin tinggi nilai koefisien determinasi maka semakin kuat pengaruh gabungan variabel X terhadap variabel Y.

Menurut Chin (1998), nilai R^2 tergolong kuat apabila lebih besar dari 0,67, sedang apabila lebih besar dari 0,33 tetapi kurang dari 0,67, dan lemah apabila lebih

besar dari 0,19 tetapi kurang dari 0,33. Nilai koefisien determinasi terhadap *close price* saham pada penelitian ini dihitung dengan menggunakan Persamaan 4.3.

Tabel 4. 4 Koefisien determinasi

| Konstruk | Koefisien Determinasi | Keterangan |
|------------------------------|------------------------------|-------------------|
| <i>Close price</i> Saham (Y) | 0.826 | Kuat |

Nilai koefisien determinasi (R^2) variabel dependen *close price* saham sebesar 0,867 menunjukkan bahwa seluruh variabel independen secara simultan mempunyai pengaruh sebesar 82.6% terhadap *close price* saham sebagai variabel dependen berdasarkan Tabel 4.3. Sedangkan sisanya yaitu sebesar 17.4% dipengaruhi oleh variabel lain yang tidak diuji dalam penelitian ini.

Tabel 4. 5 Hasil Uji Asumsi

| Uji Asumsi | Metode Pengujian | Hasil | Kesimpulan |
|-------------------|-------------------------|---------------------------|--|
| Autokorelasi | Run Test | <i>Asymp. Sig</i> = 0.178 | Tidak terjadi autokorelasi karena nilai <i>Asymp. Sig</i> > 0.05 |

Pada Tabel 4.4 ditunjukkan hasil pengujian asumsi autokorelasi dan dapat disimpulkan bahwa tidak terjadi autokorelasi pada variabel independen. Hal ini disebabkan nilai *Asymp. Sig* yang dihasilkan lebih dari 0.05.


4.5.2 Uji Hasil Prediksi

Setelah dihasilkan koefisien regresi sehingga membentuk model MLR, dilanjutkan oleh proses pengujian. Proses ini dilakukan untuk mengetahui besar *error* pada pemodelan MLR sehingga dapat dibandingkan dengan metode ANN untuk mendapatkan hasil prediksi yang optimal.

Tabel 4. 6 Perbandingan *close price* saham dengan MLR


| Tanggal | GOTO | | | BRMS | | |
|--------------------|--------|---------|---------|--------|---------|---------|
| | Actual | Predict | % Error | Actual | Predict | % Error |
| 10/3/2023 | 89 | 93.84 | 5.45 | 214 | 213.25 | 0.34 |
| 10/4/2023 | 88 | 90.32 | 2.64 | 206 | 214.94 | 4.34 |
| 10/5/2023 | 87 | 88.57 | 1.81 | 202 | 208.94 | 3.43 |
| 10/6/2023 | 88 | 88.13 | 0.15 | 208 | 202.45 | 2.66 |
| 10/9/2023 | 92 | 89.01 | 3.26 | 214 | 205.32 | 4.05 |
| ... | ... | ... | ... | ... | ... | ... |
| 1/24/2024 | 84 | 86.25 | 2.68 | 154 | 161.80 | 5.06 |
| 1/25/2024 | 84 | 84.9 | 1.18 | 154 | 155.68 | 1.09 |
| 1/26/2024 | 82 | 84.87 | 3.51 | 146 | 153.89 | 5.41 |
| 1/29/2024 | 78 | 83.33 | 6.84 | 148 | 148.23 | 0.16 |
| 1/30/2024 | 87 | 79.85 | 8.21 | 154 | 147.73 | 4.06 |
| TOTAL ERROR | | | 360.74 | | | 209.10 |
| MAPE | | | 3.68% | | | 2.13% |

Nilai MAPE ditunjukkan pada Tabel 4.5 dengan distribusi 80% data training dan 20% data testing. Persentase *error* yang dihitung dengan MAPE menghasilkan 3.68% pada data saham GOTO dan 2.17% pada data saham BRMS. Dilihat dari besarnya nilai MAPE dapat disimpulkan bahwa prediksi pada *close price* yang dilakukan memiliki nilai *error* yang rendah.

Gambar 4. 3 Perbandingan *close price* actual dan prediksi MLR data saham BRMS

Terlampir pada Gambar 4.3 dan Gambar 4.4 perbandingan antara *close price* actual dan *close price* prediksi menggunakan MLR. Pada kedua gambar

tersebut dapat dilihat bahwa garis antara nilai aktual dan nilai prediksi memiliki pola grafik yang mirip dan membuktikan bahwa pemodelan MLR memprediksi *close price* saham dengan baik.



Gambar 4. 4 Perbandingan *close price* actual dan prediksi MLR data saham GOTO

BAB V


ARTIFICIAL NEURAL NETWORK

Pada penelitian ini digunakan model ANN algoritma backpropagation dalam prediksi *close price* saham dengan *close price* saham sebagai *output*. Adapun untuk variasi pada jumlah *hidden layer* dan banyaknya node ditunjukkan pada Tabel 5.1. Hal ini bertujuan untuk menemukan kombinasi terbaik sehingga dapat diperoleh *close price* prediksi yang optimal.

Tabel 5. 1 Kombinasi model *hidden layer* ANN

| Model | Node | Arsitektur |
|-------|------|---------------------------------------|
| A | 4 | 5 input – 4 node – 1 output |
| B | 4-4 | 5 input – 4 node – 4 node – 1 output |
| C | 4-8 | 5 input – 4 node – 8 input – 1 output |

Kombinasi model pada tabel 5.1 selanjutnya dilakukan proses training untuk membandingkan hasil prediksi yang telah dilakukan. Pemodelan dengan nilai error terendah dipilih sebagai model ANN yang paling optimal untuk memprediksi *close price* saham. Adapun alur proses prediksi dengan ANN meliputi proses desain, pemodelan, training, testing, dan uji coba seperti pada Gambar 5.1.




Gambar 5. 1 Alur *artificial neural network*

5.1 Model A

Model A dengan satu *hidden layer* terdiri atas lima node *input layer* dari data masukan, bobot antara *input layer* dan *hidden layer* pertama (W_{ij}), hasil keluar pada *hidden layer* pertama dengan empat node (H_j), bobot antara *hidden*

layer dan *ouput* (V_{jk}) dan satu node *output layer* berupa *close price* saham yang ditunjukkan pada Gambar 5.2.



Gambar 5. 2 Desain jaringan model A ANN

Parameter yang digunakan pada pelatihan model A terlampir pada Tabel 5.2. Pada model A terdiri atas satu *input layer* dengan 5 node, satu *hidden layer* dengan 4 node serta satu *output layer*. Learning rate yang ditentukan merupakan variasi 0.01, 0.05 dan 0.1.

Tabel 5. 2 Parameter model A

| | |
|--------------------------|-----------------|
| Tipe Jaringan | BP-ANN |
| Fungsi aktivasi | ReLU |
| Optimizer | Adam |
| Persamaan | MAPE |
| <i>Input layer</i> | 5 |
| <i>Hidden layer</i> | 1 |
| Node <i>Hidden layer</i> | 4 |
| <i>Output layer</i> | 1 |
| Learning rate | 0.01, 0,05, 0,1 |

Proses perhitungan ANN backpropagation berdasarkan kombinasi tersebut adalah:

1. Inisiasi data pelatihan dan learning rate.
2. Inisiasi bobot serta jumlah node sesuai dengan kombinasi.
3. Fase forward pass

- a. Pada tiap unit *input layer* menerima sinyal dan meneruskan ke unit *hidden layer* pada persamaan 5.1.

$$H_{net\ j} = W_{0j} + \sum_{i=1}^n I_i W_{ij} \quad (5.1)$$

Dimana i merupakan node ke- i pada *input layer* dan j adalah node ke- j pada *hidden layer* pertama. W_{0j} merupakan bias pada *input layer* dan W_{ij} merupakan bobot pada *input* i menuju neuron j .

- b. Pada keluaran *hidden layer* dapat dihitung setelah mendapatkan dengan menggunakan aktivasi ReLU yang ditunjukkan pada persamaan 4.3. Hasil dari $f(H_{net\ j})$ selanjutnya dikirimkan ke seluruh node *output layer*.

$$f(H_{net\ j}) = \max(0, H_{net\ j}) \quad (5.2)$$

- c. Sinyal keluaran dihitung dengan fungsi aktivasi ReLU dengan kisaran antara 0 hingga $O_{net\ l}$ yang dihitung dengan persamaan 5.5. Dimana $O_{net\ l}$ merupakan hasil penjumlahan bobot pada *hidden layer* kedua dan node keluaran.

$$f(O_{net\ k}) = \max(0, O_{net\ k}) \quad (5.7)$$

4. Hitung loss yang merupakan selisih keluaran target dengan menggunakan persamaan 5.6.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad (5.8)$$

Proses ini dilakukan hingga mencapai *epoch* yang telah ditentukan sebelumnya. Bobot terakhir yang diperoleh merupakan bobot yang digunakan untuk menghitung data testing.

5. Backward pass

- a. Proses pertama pada backward pass adalah menghitung faktor kesalahan pada *output layer* dan *hidden layer* pertama. Faktor kesalahan diperoleh dengan persamaan 5.7, dimana t merupakan target atau *close price* awal sedangkan y merupakan *close price* prediksi.

$$f'(O_{net\ k}) = (1 - f(O_{net\ k}))f(O_{net\ k}) \quad (5.9)$$

$$\delta_l = (t_l - y_l)f'(O_{net\ k}) \quad (5.10)$$

- b. Hitung nilai kesalahan pada *input layer* dan *hidden layer* pertama dengan menggunakan persamaan 5.

$$\delta_{net\ j} = \sum_{j=1}^m \delta_j W_{ij} \quad (5.14)$$

$$f'(H_{net\ j}) = (1 - f(H_{net\ j}))f(j) \quad (5.15)$$

$$\delta_j = \delta_j f'(H_{net\ j}) \quad (5.16)$$

- c. Bobot yang telah diperoleh sebelumnya dilakukan koreksi ataupun *update* bobot dengan perhitungan pada persamaan 5.17

$$\Delta W_{ij} = \alpha \delta_j I_i \quad (5.17)$$

$$\Delta V_{jk} = \alpha \delta_k H_j \quad (5.18)$$

Dimana ΔW_{ij} dan ΔV_{jk} merupakan bobot lama yang telah diperbarui, dengan δ_j merupakan nilai kesalahan pada *input layer* dan *hidden layer*

pertama, δ_k merupakan nilai kesalahan pada *hidden layer* pertama dan *output layer*.

6. Update bobot

Langkah terakhir merupakan *update* pada masing-masing bobot dengan menggunakan persamaan berikut.

$$W_{ij}(\text{baru}) = W_{ij}(\text{lama}) + \Delta W_{ij} \quad (5.20)$$

$$V_{jk}(\text{baru}) = V_{jk}(\text{lama}) + \Delta V_{jk} \quad (5.21)$$


$W_{ij}(\text{baru})$ merupakan bobot baru antara *input layer* dan *hidden layer* pertama, $V_{jk}(\text{baru})$ merupakan bobot baru antara *hidden layer* pertama dan *hidden layer* kedua.

Hasil dari pelatihan model A ditunjukkan pada Tabel 5.3. Pada tabel tersebut ditunjukkan MAPE pada proses pelatihan dengan masing-masing learning rate. Model A dengan learning rate 0.1 memiliki rata-rata MAPE yang paling rendah yaitu sebesar 3.26%. Dalam hal ini, percobaan ke-4 menunjukkan nilai MAPE terendah dengan 3.05%.

Tabel 5. 3 Hasil Pelatihan Model A

| Percobaan ke- | MAPE | | |
|------------------|-----------------|-----------------|----------------|
| | $\alpha = 0.01$ | $\alpha = 0.05$ | $\alpha = 0.1$ |
| 1 | 3.208 | 3.151 | 3.491 |
| 2 | 3.44 | 2.975 | 3.326 |
| 3 | 3.038 | 3.827 | 3.363 |
| 4 | 3.401 | 4.958 | 3.052 |
| 5 | 3.513 | 4.012 | 3.068 |
| Rata-Rata | 3.32 | 3.7846 | 3.26 |
| Min | 3.038 | 2.975 | 3.052 |
| Max | 3.513 | 4.958 | 3.491 |


Proses pelatihan menggunakan model A dengan menggunakan parameter empat node *hidden layer*, *learning rate* 0.1 dan epoch 100 menunjukkan grafik konvergen pada Gambar 5.3. Hasil plotting model tersebut menunjukkan bahwa loss semakin turun dan stabil mendekati epoch yang telah ditentukan sebelumnya dan menunjukkan bahwa model telah konvergen.



Gambar 5. 3 Nilai loss pelatihan model A

5.2 Model B

Model B dengan dua *hidden layer* terdiri atas lima node *input layer* dari data masukan, bobot antara *input layer* dan *hidden layer* pertama (W_{ij}), hasil keluaran pada *hidden layer* pertama dengan empat node (H_j), bobot antara *hidden layer* pertama dan *hidden layer* kedua (V_{jk}), hasil keluaran pada *hidden layer* kedua dengan empat node (G_k), bobot antara *hidden layer* kedua dengan *output* (U_{kl}) dan satu node *output layer* berupa *close price* saham yang ditunjukkan pada Gambar 5.4.



Gambar 5. 4 Desain jaringan model B ANN

Parameter yang digunakan pada pelatihan model B terlampir pada Tabel 5.4. Pada model B terdiri atas satu *input layer* dengan 5 node, *hidden layer* pertama dengan 4 node, *hidden layer* kedua dengan 4 node, serta satu *output layer*. Learning rate yang ditentukan merupakan variasi 0.01, 0.05 dan 0.1.

Tabel 5. 4 Parameter model B

| | |
|--------------------------|-----------------|
| Tipe Jaringan | BP-ANN |
| Fungsi aktivasi | ReLU |
| Optimizer | Adam |
| Persamaan | MAPE |
| <i>Input layer</i> | 5 |
| <i>Hidden layer</i> | 2 |
| Node <i>Hidden layer</i> | 4-4 |
| <i>Output layer</i> | 1 |
| Learning rate | 0.01, 0.05, 0.1 |

Proses perhitungan ANN backpropagation berdasarkan kombinasi tersebut adalah:

1. Inisiasi data pelatihan dan *learning rate*.

2. Inisiasi bobot serta jumlah node sesuai dengan kombinasi.
3. Fase *forward pass*
 - d. Pada tiap unit *input layer* menerima sinyal dan meneruskan ke unit *hidden layer* pada persamaan 5.1.

$$H_{net\ j} = W_{0j} + \sum_{i=1}^n I_i W_{ij} \quad (5.1)$$

Dimana i merupakan node ke- i pada *input layer* dan j adalah node ke- j pada *hidden layer* pertama. W_{0j} merupakan bias pada *input layer* dan W_{ij} merupakan bobot pada *input* i menuju neuron j .

- e. Pada keluaran *hidden layer* dapat dihitung setelah mendapatkan dengan menggunakan aktivasi ReLU yang ditunjukkan pada persamaan 4.3. Hasil dari $f(H_{net\ j})$ selanjutnya dikirimkan ke seluruh node *output layer*.

$$f(H_{net\ j}) = \max(0, H_{net\ j}) \quad (5.2)$$

- f. Hitung sinyal dari setiap node *hidden layer* kedua (G_k) yang diberikan diteruskan oleh fase informasi dari *hidden layer* pertama. Hal ini ditunjukkan pada Persamaan 5.3.

$$G_{net\ k} = V_{0k} + \sum_{i=1}^n H_i V_{ij} \quad (5.3)$$

Dimana V_{0k} merupakan bias pada *input layer* dan V_{ij} merupakan bobot pada node j yang menuju neuron k . Langkah ini hanya dilakukan pada model yang memiliki dua *hidden layer*.

- g. Keluaran pada *hidden layer* kedua dihitung dengan menggunakan fungsi aktivasi ReLU dengan kirsan antara 0 hingga $G_{net\ k}$ pada persamaan

5.4. Langkah ini hanya dilakukan pada model yang memiliki dua *hidden layer*.

$$f(G_{net\ k}) = \max(0, G_{net\ k}) \quad (5.4)$$

- h. *Output layer* menerima sinyal yang diteruskan oleh *hidden layer*. Sinyal yang masuk pada *output layer* dihitung dengan persamaan 5.5, dimana l adalah jumlah output *layer*.

$$O_{net\ l} = G_{0l} + \sum_{i=1}^n G_i U_{kl} \quad (5.6)$$

- i. Sinyal keluaran dihitung dengan fungsi aktivasi ReLU dengan kisaran antara 0 hingga $O_{net\ l}$ yang dihitung dengan persamaan 5.5. Dimana $O_{net\ l}$ merupakan hasil penjumlahan bobot pada *hidden layer* kedua dan node keluaran.

$$f(O_{net\ l}) = \max(0, O_{net\ l}) \quad (5.7)$$

4. Hitung loss yang merupakan selisih keluaran target dengan menggunakan persamaan 5.6.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad (5.8)$$

Proses ini dilakukan hingga mencapai *epoch* yang telah ditentukan sebelumnya. Bobot terakhir yang diperoleh merupakan bobot yang digunakan untuk menghitung data testing.

5. Backward pass

- d. Proses pertama pada backward pass adalah menghitung faktor kesalahan pada *output layer* dan *hidden layer* kedua. Faktor kesalahan diperoleh dengan persamaan 5.7, dimana t merupakan target atau *close price* awal sedangkan y merupakan *close price* prediksi.

$$f'(O_{net\ l}) = (1 - f(O_{net\ l}))f(O_{net\ l}) \quad (5.9)$$

$$\delta_l = (t_l - y_l)f'(O_{net\ l}) \quad (5.10)$$

- e. Hitung nilai kesalahan pada *hidden layer* pertama dan kedua dengan menggunakan persamaan 5.11.

$$\delta_{net\ k} = \sum_{l=1}^m \delta_k U_{kl} \quad (5.11)$$

$$f'(G_{net\ k}) = (1 - f(G_{net\ k}))f(G_{net\ k}) \quad (5.12)$$

$$\delta_k = \delta_k f'(G_{net\ k}) \quad (5.13)$$

- f. Hitung nilai kesalahan pada *input layer* dan *hidden layer* pertama dengan menggunakan persamaan 5.

$$\delta_{net\ j} = \sum_{k=1}^m \delta_j V_{jk} \quad (5.14)$$

$$f'(H_{net\ j}) = (1 - f(H_{net\ j}))f(j) \quad (5.15)$$

$$\delta_j = \delta_j f'(H_{net\ j}) \quad (5.16)$$

- g. Bobot yang telah diperoleh sebelumnya dilakukan koreksi ataupun *update* bobot dengan perhitungan pada persamaan 5.17

$$\Delta W_{ij} = \alpha \delta_j I_i \quad (5.17)$$

$$\Delta V_{jk} = \alpha \delta_k H_j \quad (5.18)$$

$$\Delta U_{kl} = \alpha \delta_l G_k \quad (5.19)$$

Dimana ΔW_{ij} , ΔV_{jk} , ΔU_{kl} , merupakan bobot lama yang telah diperbarui, dengan δ_j merupakan nilai kesalahan pada *input layer* dan *hidden layer* pertama, δ_k merupakan nilai kesalahan pada *hidden layer* pertama dan *hidden layer* kedua serta δ_l merupakan nilai kesalahan pada *hidden layer* kedua dan *output layer*.

6. Update bobot

Langkah terakhir merupakan *update* pada masing-masing bobot dengan menggunakan persamaan berikut.

$$W_{ij}(\text{baru}) = W_{ij}(\text{lama}) + \Delta W_{ij} \quad (5.20)$$

$$V_{jk}(\text{baru}) = V_{jk}(\text{lama}) + \Delta V_{jk} \quad (5.21)$$

$$U_{kl}(\text{baru}) = U_{kl}(\text{lama}) + \Delta U_{kl} \quad (5.22)$$

$W_{ij}(\text{baru})$ merupakan bobot baru antara *input layer* dan *hidden layer* pertama, $V_{jk}(\text{baru})$ merupakan bobot baru antara *hidden layer* pertama dan *hidden layer* kedua, serta $U_{kl}(\text{baru})$ merupakan bobot baru antara *hidden layer* kedua dan *output layer*.


Hasil dari pelatihan model B ditunjukkan pada Tabel 5.5. Pada tabel tersebut ditunjukkan MAPE pada proses pelatihan dengan masing-masing *learning rate*. Model B dengan *learning rate* 0.01 memiliki rata-rata MAPE yang paling rendah yaitu sebesar 3.14%. Dalam hal ini, percobaan ke-4 menunjukkan nilai MAPE terendah dengan 2.74%.

Tabel 5. 5 Hasil Pelatihan Model B

| Percobaan ke- | MAPE | | |
|---------------|-----------------|-----------------|----------------|
| | $\alpha = 0.01$ | $\alpha = 0.05$ | $\alpha = 0.1$ |
| 1 | 3.367 | 5.22 | 2.904 |
| 2 | 2.908 | 2.801 | 3.089 |
| 3 | 3.623 | 3.279 | 4.914 |
| 4 | 2.745 | 4.052 | 2.783 |
| 5 | 3.066 | 4.395 | 2.994 |
| Rata-rata | 3.1418 | 3.9494 | 3.3368 |
| Min | 2.745 | 2.801 | 2.783 |
| Max | 3.623 | 5.22 | 4.914 |

Proses pelatihan menggunakan model A dengan menggunakan parameter empat node *hidden layer*, *learning rate* 0.01 dan epoch 100 menunjukkan grafik


yang konvergen pada Gambar 5.5. Hasil *plotting model* tersebut menunjukkan bahwa loss semakin turun dan stabil mendekati epoch yang telah ditentukan sebelumnya dan menunjukkan bahwa model telah konvergen.



Gambar 5. 5 Nilai *loss* pelatihan model B

5.3 Model C

Model C dengan dua *hidden layer* terdiri atas lima node *input layer* dari data masukan, bobot antara *input layer* dan *hidden layer* pertama (W_{ij}), hasil keluaran pada *hidden layer* pertama dengan empat node (H_j), bobot antara *hidden layer* pertama dan *hidden layer* kedua (V_{jk}), hasil keluaran pada *hidden layer* kedua dengan delapan node (G_k), bobot antara *hidden layer* kedua dengan *output* (U_{kl}) dan satu node *output layer* berupa *close price* saham yang ditunjukkan pada Gambar 5.2.



Gambar 5. 6 Desain jaringan model C ANN

Parameter yang digunakan pada pelatihan model C terlampir pada Tabel 5.6. Pada model C terdiri atas satu *input layer* dengan 5 node, *hidden layer* pertama dengan 4 node, *hidden layer* kedua dengan 8 node, serta satu *output layer*. Learning rate yang ditentukan merupakan variasi 0.01, 0.05 dan 0.1. Proses perhitungan model C telah dijelaskan sebelumnya pada langkah model C. Hal ini disebabkan kedua model tersebut memiliki jumlah *hidden layer* yang sama.

Tabel 5. 6 Parameter model C


| | |
|--------------------------|--------|
| Tipe Jaringan | BP-ANN |
| Fungsi aktivasi | ReLU |
| Optimizer | Adam |
| Persamaan | MAPE |
| <i>Input layer</i> | 5 |
| <i>Hidden layer</i> | 2 |
| Node <i>Hidden layer</i> | 4-8 |
| <i>Output layer</i> | 1 |
| <i>Learning rate</i> | 0.1 |

Hasil dari pelatihan model C ditunjukkan pada Tabel 5.7. Pada tabel tersebut ditunjukkan MAPE pada proses pelatihan dengan masing-masing learning rate. Model C dengan learning rate 0.01 memiliki rata-rata MAPE yang paling rendah yaitu sebesar 3.03%. Dalam hal ini, percobaan ke-3 menunjukkan nilai MAPE terendah dengan 2.75%.

Tabel 5. 7 Hasil Pelatihan Model C

| Percobaan ke- | MAPE | | |
|---------------|-----------------|-----------------|----------------|
| | $\alpha = 0.01$ | $\alpha = 0.05$ | $\alpha = 0.1$ |
| 1 | 2.832 | 2.807 | 3.114 |
| 2 | 3.14 | 2.984 | 3.365 |
| 3 | 2.752 | 3.665 | 4.289 |
| 4 | 2.804 | 2.725 | 2.868 |
| 5 | 3.665 | 2.995 | 3.086 |
| Rata-rata | 3.0386 | 3.0352 | 3.3444 |
| MIN | 2.752 | 2.725 | 2.868 |
| MAX | 3.665 | 3.665 | 4.289 |

Proses pelatihan menggunakan Model C dengan menggunakan parameter empat node *hidden layer*, learning rate 0.01 dan epoch 100 menunjukkan grafik konvergen pada Gambar 5.7. Hasil *plotting model* tersebut menunjukkan bahwa loss semakin turun dan stabil mendekati epoch yang telah ditentukan sebelumnya dan menunjukkan bahwa model telah konvergen.



Gambar 5. 7 Nilai *loss* pelatihan model C

5.4 Uji Coba

Setelah sebelumnya dilakukan proses pelatihan pada masing-masing model, proses selanjutnya merupakan proses pengujian. Pengujian pada model A dilakukan dengan parameter *learning rate* 0.1 serta model B dan model C dilakukan dengan parameter *learning rate* 0.01. Hasil pengujian masing-masing model ditunjukkan pada Tabel 5.8. Setiap model memiliki rata-rata MAPE yang menunjukkan tingkat performa model.

Tabel 5. 8 Hasil pengujian model ANN

| Percobaan ke- | Model A | Model B | Model C |
|---------------|---------|---------|---------|
| 1 | 4.346 | 3.246 | 3.124 |
| 2 | 3.225 | 3.276 | 3.159 |
| 3 | 3.745 | 3.28 | 3.352 |
| 4 | 4.429 | 3.714 | 3.422 |
| 5 | 3.524 | 3.314 | 3.212 |
| Rata-rata | 3.8538 | 3.366 | 3.2538 |
| Min | 3.225 | 3.246 | 3.124 |
| Max | 4.429 | 3.714 | 3.422 |


Model C menunjukkan rata-rata MAPE terendah sebesar 3.25% dengan, dilanjutkan model B pada tempat kedua dengan rata-rata 3.36% dan model A

dengan rata-rata 3.85%. Berdasarkan rata-rata MAPE tersebut, model ANN dengan performa terbaik merupakan model B dengan 2 *hidden layer* 4-4 node serta learning rate sebesar 0.01.

Tabel 5. 9 Perbandingan *close price* saham dengan ANN


| Tanggal | GOTO | | | BRMS | | |
|--------------------|--------|---------|---------|--------|---------|---------|
| | Actual | Predict | % Error | Actual | Predict | % Error |
| 10/3/2023 | 89 | 94.11 | 5.74 | 214 | 213.95 | 0.02 |
| 10/4/2023 | 88 | 89.64 | 1.87 | 206 | 215.40 | 4.56 |
| 10/5/2023 | 87 | 88.84 | 2.12 | 202 | 208.99 | 3.46 |
| 10/6/2023 | 88 | 87.96 | 0.05 | 208 | 203.23 | 2.29 |
| 10/9/2023 | 92 | 88.79 | 3.49 | 214 | 206.85 | 3.34 |
| ... | ... | ... | ... | ... | ... | ... |
| 1/24/2024 | 84 | 86.59 | 3.09 | 154 | 163.06 | 5.88 |
| 1/25/2024 | 84 | 85.06 | 1.26 | 154 | 155.82 | 1.18 |
| 1/26/2024 | 82 | 84.88 | 3.52 | 146 | 144.55 | 1.00 |
| 1/29/2024 | 78 | 83.10 | 6.53 | 148 | 147.99 | 0.01 |
| 1/30/2024 | 87 | 78.82 | 9.41 | 154 | 148.64 | 3.48 |
| TOTAL ERROR | | | 347.27 | | | 212.96 |
| MAPE | | | 3.54% | | | 2.17% |

Tabel 5.9 menunjukkan nilai MAPE dengan distribusi 80% data training dan 20% data testing. Persentase *error* yang dihitung dengan MAPE menghasilkan 3.54% pada data saham GOTO dan 2.28% pada data saham BRMS. Dilihat dari besarnya nilai MAPE dapat disimpulkan bahwa prediksi pada *close price* yang dilakukan memiliki nilai *error* yang rendah.



Gambar 5. 8 Perbandingan *close price* actual dan prediksi ANN data saham BRMS

Terlampir pada Gambar 5.7 dan Gambar 5.8 perbandingan antara *close price* actual dan *close price* prediksi menggunakan ANN. Pada kedua gambar tersebut dapat dilihat bahwa garis antara nilai actual dan nilai prediksi memiliki pola grafik yang mirip dan membuktikan bahwa pemodelan ANN model B memprediksi *close price* saham dengan baik.



Gambar 5. 9 Perbandingan *close price* actual dan prediksi ANN data saham GOTO

BAB VI

EVALUASI KINERJA METODE

Pada bab ini dilakukan perbandingan hasil kinerja algoritma *multiple linear regression* dan *artificial neural network*. Hal ini bertujuan untuk mengetahui algoritme yang lebih baik dalam prediksi *close price* saham. Hasil kinerja algoritme pada penelitian ini diukur dengan melihat nilai *Mean Absolute Percentage Error* (MAPE) antara kedua algoritma tersebut.

Koefisien determinasi yang dihasilkan pada metode *multiple linear regression* sebesar 0.826 menunjukkan bahwa seluruh variabel independen secara simultan mempunyai pengaruh sebesar 82.6% terhadap *close price* saham sebagai variabel dependen. Sedangkan sisanya yaitu sebesar 17.4% dipengaruhi oleh variabel lain yang tidak diuji dalam penelitian ini. Uji asumsi pada autokorelasi dengan menggunakan metode pengujian *Run Test* menunjukkan data pada penelitian ini tidak terjadi autokorelasi yang disebabkan nilai *Asymp.Sig* > 0.05. Analisa autokorelasi dilakukan pada data penelitian untuk mengetahui pengaruh suatu variabel bebas terhadap variabel terikat sehingga tidak ada korelasi antara pengamatan dengan pengamatan yang lalu.

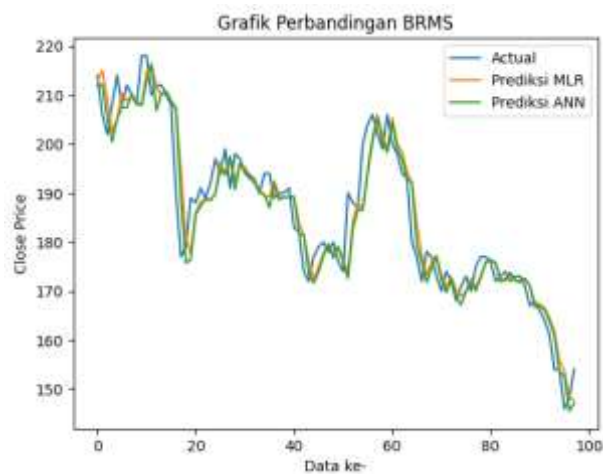
Tabel 6. 1 Perbandingan hasil prediksi MLR dan ANN-BP

| Aktual | | Prediksi MLR | | Prediksi ANN | |
|--------|------|--------------|-------|--------------|-------|
| BRMS | GOTO | BRMS | GOTO | BRMS | GOTO |
| 189 | 73 | 190.27 | 79.59 | 190.66 | 80.49 |
| 192 | 67 | 187.60 | 74.23 | 190.78 | 73.89 |
| 197 | 66 | 191.37 | 68.29 | 191.62 | 68.09 |
| ... | ... | ... | ... | ... | ... |
| 194 | 65 | 196.30 | 69.06 | 197.31 | 62.58 |
| 199 | 63 | 192.50 | 66.61 | 196.03 | 64.79 |
| 191 | 64 | 197.86 | 64.02 | 199.26 | 63.97 |
| 198 | 60 | 189.64 | 65.22 | 193.63 | 64.23 |

Tabel 6.2 Perbandingan hasil prediksi MLR dan ANN-BP

| | | | | | |
|-----|----|--------|-------|--------|-------|
| 197 | 63 | 197.07 | 61.19 | 197.88 | 60.54 |
| 194 | 63 | 196.50 | 64.30 | 196.48 | 63.05 |
| 193 | 60 | 192.45 | 63.90 | 195.98 | 64.16 |

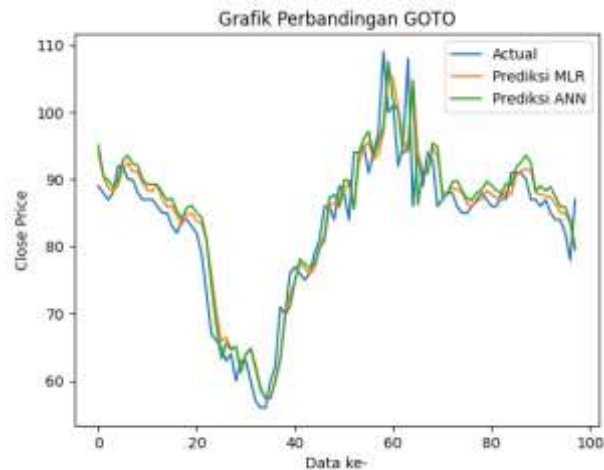
Tabel 6.1 membandingkan data aktual dan data prediksi *close price* saham dari dua metode yakni *multiple linear regression* dan artificial neural network backpropagation. Berdasarkan perbandingan tersebut, maka kedua metode mampu dalam melakukan prediksi *close price* saham.



Gambar 6. 1 Grafik perbandingan hasil prediksi BRMS

Gambar 6.1 menyajikan perbandingan antara nilai *close price* saham aktual dengan hasil prediksi kedua metode pada emiten BRMS. Pada beberapa titik terlihat hasil prediksi MLR memiliki garis yang selaras dengan nilai *close price* aktual.

Perbandingan antara nilai *close price* saham aktual dengan hasil prediksi kedua metode pada emiten GOTO disajikan pada Gambar 6.2. Pada beberapa titik terlihat ketiga garis tersebut membentuk garis yang bersinggungan dekat antara satu sama lain. Hal ini menandakan nilai aktual *close price* saham memiliki selisih yang tidak banyak dengan hasil prediksi kedua metode.



Gambar 6. 2 Grafik perbandingan hasil prediksi GOTO

Berdasarkan kedua gambar tersebut dapat dilihat bahwa kedua metode mampu melakukan prediksi *close price* saham dengan selisih yang tidak jauh beda antara keduanya. Namun, dapat dilihat bahwa garis prediksi ANN lebih mendekati garis aktual. Hal ini menandakan hasil prediksi *close price* saham dengan menggunakan ANN lebih baik.

Tabel 5. 10 Hasil MAPE kedua metode

| | MAPE <i>Multiple linear regression</i> | MAPE ANN backpropagation |
|----------------|---|-----------------------------|
| BRMS | 2.13% | 2.17% |
| GOTO | 3.68% | 3.54% |
| Rata-Rata MAPE | 2.90% | 2.86% |

Perbedaan hasil MAPE kedua metode dalam penelitian ini yakni *multiple linear regression* dan artificial neural network backpropagation dapat dilihat pada Tabel 5.10. Dari hasil perbandingan tersebut, dapat disimpulkan bahwa metode artificial neural network backpropagation lebih baik dalam memprediksi saham dilihat dari nilai MAPE yang dihasilkan lebih rendah daripada metode *multiple linear regression*. Secara umum, metode *artificial neural network backpropagation* lebih baik karena dapat digunakan untuk semua jenis data baik linier maupun non linier. *Backpropagation* dapat menangani *noise* pada data pelatihan dan dapat

menggeneralisasi dengan lebih baik ketika terdapat *noise* pada data pelatihan (Walczak, 2003). Sedangkan *multiple linear regression* bekerja paling baik dengan data terdistribusi normal. Karena itu, distribusi antar variabel pada *multiple linear regression* sangat berpengaruh pada persamaan koefisien yang diperoleh.

Berdasarkan nilai perbandingan nilai MAPE kedua algoritma yang dinilai rendah maka dapat disimpulkan bahwa kedua metode tersebut berhasil untuk memprediksi *close price* saham. Hasil pada penelitian ini diharapkan dapat mendorong keinginan untuk berinvestasi saham sebagai seorang muslim untuk mempersiapkan masa depan seperti dijelaskan pada Al-Qur'an surat Luqman Ayat 34 yaitu:

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنزِلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ

Artinya: “*Sesungguhnya hanya di sisi Allah ilmu tentang hari kiamat; dan Dia yang menurunkan hujan, dan mengetahui apa yang ada dalam Rahim. Dan tidak ada seorang pun yang dapat mengetahui (dengan pasti) apa yang akan dikerjakannya besok. Dan tidak ada seorang pun yang dapat mengetahui di bumi mana dia akan mati. Sungguh, Allah Maha Mengetahui, Maha Mengenal.*”

Berdasarkan tafsir Shihab (2002), ayat tersebut bermakna hanya Allah yang mengetahui secara mutlak tentang hari kiamat. Tidak ada yang tahu selain Allah. Tak seorang pun, baik atau buruk, tahu apa yang akan dia lakukan besok, baik atau buruk. Berdasarkan ayat tersebut, dapat disimpulkan bahwa manusia tidak dapat mengetahui secara pasti apa yang akan mereka lakukan atau apa yang akan mereka peroleh esok hari. Namun, mereka harus mencobanya. Salah satu maksud dari kata ini adalah menebak apa yang akan terjadi berdasarkan masa lalu yang pernah terjadi. Hal ini juga berlaku pada prediksi *close price* saham yang didasarkan data saham pada hari sebelumnya.

Prediksi *close price* saham pada penelitian ini diharapkan mampu mengurangi *mafsadat* yang terjadi dan dapat mengurangi kerugian karena ketidakpastian, tidak mengeluhkan nasib buruk, sehingga dianjurkan untuk berpikir dan bersyukur. Hal ini juga merupakan salah satu bentuk ikhtiar sebelum berinvestasi saham seperti dijelaskan pada Al-Qur'an surat An-Najm ayat 39-42 adalah:

وَأَنْ لَّيْسَ لِلْإِنْسَانِ إِلَّا مَا سَعَىٰ ۝ ٣٩

وَأَنَّ سَعْيَهُ سَوْفَ يُرَىٰ ۝ ٤٠

ثُمَّ يُجْزَاهُ الْجَزَاءَ الْأَوْفَىٰ ۝ ٤١

وَأَنَّ إِلَىٰ رَبِّكَ الْمُنْتَهَىٰ ۝ ٤٢

Artinya: “*dan bahwa manusia hanya memperoleh apa yang telah diusahakannya, dan sesungguhnya usahanya itu kelak akan diperlihatkan (kepadanya), kemudian akan diberikan balasan kepadanya dengan balasan yang paling sempurna, dan sesungguhnya kepada Tuhanmulah kesudahannya (segala sesuatu),*”

Apapun hasil dari investasi saham yang telah dilakukan, tugas manusia hanya berusaha dan hasilnya hanya bisa ditentukan oleh Allah SWT. Usaha juga dapat membawa manfaat bagi manusia, seperti menunjukkan kemandirian, menghargai usaha, mudah menyerah, dan merasa puas karena telah melakukan yang terbaik. Pada saat yang sama, hal ini menuntun seseorang layak di hadapan manusia dan terhormat di hadapan Allah SWT.

BAB VII

PENUTUP

7.1 Kesimpulan

Berdasarkan hasil pengujian dan analisis prediksi *close price* saham harian dengan menggunakan *artificial neural network* dan *metode multiple linear regression*, maka diperoleh kesimpulan pada uji coba perbandingan nilai MAPE antara kedua metode yang telah dilakukan, kesalahan prediksi dengan algoritme *multiple linear regression* memiliki nilai MAPE 2.90% yang lebih rendah daripada *artificial neural network* yang memiliki nilai MAPE 2.86%. Hal ini menunjukkan bahwa *artificial neural network* lebih unggul dalam melakukan prediksi *close price* saham pada penelitian ini. Adapun arsitektur terbaik pada pemodelan *artificial neural network* yaitu dengan pemodelan satu *input layer*, *hidden layer* pertama dan kedua dengan empat node, serta *output layer*.

7.2 Saran

Peneliti menyadari bahwa masih terdapat kesenjangan dalam penelitian ini dan beberapa saran yang dapat dijadikan acuan bagi penelitian selanjutnya, antara lain:

1. Metode *machine learning* prediksi lainnya dapat digunakan sebagai perbandingan untuk mendapatkan nilai *error* yang lebih rendah.
2. Banyaknya variabel dan data penelitian dapat digunakan untuk meningkatkan akurasi hasil prediksi.

DAFTAR PUSTAKA

- Akhtar, Md., Zamani, Abu., Khan, Shakir., Shatat, Abdallah., Dilshad, Sara & Samdani, Faizan. (2022). Stock market prediction based on statistical data using machine learning algorithms. *Journal of King Saud University - Science*. 34. 101940. 10.1016/j.jksus.2022.101940.
- Alam, Md. Mahmudul & Akbar, Chowdhury & Shahriar, Shawon & Mohammad, Monzur-E-Elahi. The Islamic Shariah Principles for Investment in Stock Market, *Qualitative Research in Financial Markets*, 9(2): 132-146. <http://www.emeraldinsight.com/doi/full/10.1108/QRFM-09-2016-0029>
- Al-Khaiyyat, A. A. (1989). *As-Sharikat fi Daw' Al-Islam*, Al-Guriyyah: Amman.
- Badan Pengembangan dan Pembinaan Bahasa Kemendikbud RI. (2016). *Kamus Besar Bahasa Indonesia*. Jakarta: Kemendikbud RI.
- Bhuriya, Dinesh., Kaushal, Girish., Sharma, Ashish & Singh, Upendra. (2017). Stock market predication using a linear regression. 2017 International conference of Electronics, Communication and Aerospace Technology (ICECA), pp. 510-513, doi: 10.1109/ICECA.2017.8212716.
- Chin, W. W. (1998). The partial least squares approach for structural equation modeling. In G. A. Marcoulides (Ed.), *Modern methods for business research* (pp. 295–336). Lawrence Erlbaum Associates Publishers.
- Das, Sudeepa., Sahu, Tirath., Janghel, Rekh & Sahu, Binod. (2022). Effective forecasting of stock market price by using extreme learning machine optimized by PSO-based group oriented crow search algorithm. *Neural Computing and Applications*. 34. 10.1007/s00521-021-06403-x. *Financial Issues* 3 (4) : 788–798
- El-Nader, G. (2018). Stock Liquidity And Free Float: Evidence From The UK. *Managerial Finance*, 44(10), 1227–1236. <https://doi.org/10.1108/MF-12-2017-0494>
- Fahd, B.A.R.A. (2007). *At-Takyif Al-Fiqhi Li as-Saham fi Ash-Sharikat Al-Musahamah Wa'Asruhu*, Daru Kunuji Isbilila: Riyadh.
- Fallon, A., & Engel, C. (2008). Hypertensive disorders of pregnancy. *The Practising Midwife*, 11(9), 1-27. Diakses 24 Juni 2016 dari <https://www.practisingmidwife.co.uk>
- Hajilee, Massomeh & Stringer, Donna & Hayes, Linda. (2021). On the link between the shadow economy and stock market development: An asymmetry analysis. *The Quarterly Review of Economics and Finance*. 80. 303-316. 10.1016/j.qref.2021.02.011.

- Hallman, J. (2019). A comparative study on Linear Regression and Neural Networks for estimating order quantities of powder blends.
- Heaton, Jeff. (2017). The number of hidden layers. Diakses 26 April 2024 dari <http://www.heatonresearch.com/2017/06/01/hidden-layers.html>.
- Hidayat, Taufik. (2010). Buku Pintar Investasi. Cetakan Pertama. Mediakita, Jakarta Selatan.
- Jethani, Laksh., Patil, Ratnesh., Sanghvi, Shubh., Singh, Raj & Sarode, Tanuja. (2023). Analysis of Machine Learning Models for Stock Market Prediction. 1-8. 10.1109/ICIICS59993.2023.10421609. Vijha et al. 2020. Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599-606.
- Kementerian Keuangan Republik Indonesia Badan Pengawas Pasar Modal Dan Lembaga Keuangan. (2011). Salinan Keputusan Ketua Badan Pengawas Pasar Modal Dan Lembaga Keuangan Nomor Kep-689/BI/2011 Tentang Pedoman Akuntansi Perusahaan Efek.
- Kumar., Jain, Sanjeev & Singh, Dr. Uday. (2021). Neuro-Fuzzy and Particle Swarm Optimization based Hybrid Approach for Stock Price Forecasting. 2021 International Conference on Emerging Smart Computing and Informatics (ESCI), 753-758.
- Lanbouri dan Achchab. 2019. A new approach for Trading based on Long-Short Term memory technique.
- Liu, Zixuan., Dang, Ziyuan & Yu, Jie. (2020). Stock Price Prediction Model Based on RBF-SVM Algorithm. 124-127. 10.1109/ICCEIC51584.2020.00032.
- Masoud, Najeb MH. (2017). The impact of stock market performance upon economic growth.
- Maulana & Kumalasari. (2019). Analisis Dan Perbandingan Algoritma Data Mining Dalam Prediksi Harga Saham GGRM. *Jurnal Informatika Kaputama (JIK)*, Vol 3 No 1, Januari 2019.
- Murkute, Amod & Sarode, Tanuja. (2015). Forecasting Market Price of Stock using Artificial Neural Network. *International Journal of Computer Applications*. 124. 11-15. 10.5120/ijca2015905681.
- Osmani, N.M. & Abdullah, M. F. (2009). Towards An Islamic Stock Market: A review of Classical and Modern Literatures, *International Review of Business Research Papers*, 5(5), 121-130.
- Puspitasari, Ardina. (2015). Analisis Integrasi Bursa Saham Asean, *Jurnal Ekonomi dan Kebijakan Pembangunan Edisi Desember 2015 Vol 4 No 2* 187 hlm. 187 - 206

- R. Soujanya, P. Akshith Goud, Abhishek Bhandwalkar, G. Anil Kumar. (2020). Evaluating future stock value asset using machine learning. *Materials Today: Proceedings*.
- Sharma, Deepak & Chandra, Pravin. (2018). A comparative analysis of soft computing techniques in software fault prediction model development. *International Journal of Information Technology*. 11. 1-10. 10.1007/s41870-018-0211-3.
- Shihab, M. Quraish. (2002). *Tafsir Al-Misbah: Pesan, Kesan dan Keserasian Al-Qur'an*, (Jakarta: Lentera Hati) Cet. 11, Vol. 15
- Sugiyono. (2012). *Metode Penelitian Kuantitatif Kualitatif dan R&D*. Bandung : CV Alfabeta Sugiyono. 2011. *Statistika Untuk Penelitian*. Bandung: Alfabeta.
- Thomas, A. J., Petridis, M., Walters, S. D., Gheytsi, S. M., & Morgan, R. E. (2017). Two hidden layers are usually better than one. *Engineering Applications of Neural Networks: 18th International Conference, EANN 2017, Athens, Greece, August 25–27, 2017, Proceedings*, 279–290.
- Tofallis, C. (2015). A better measure of relative prediction accuracy for model selection and model estimation. *Journal of the Operational Research Society*, 66(8), 1352–1362. <https://doi.org/10.1057/jors.2014.103>
- Walczak, Steven & Cerpa, Narciso. (2003). *Artificial Neural Networks*. 10.1016/B0-12-227410-5/00837-1.
- Xie & Jiang. (2019). *Stock Market Forecasting Based on Text Mining Technology: A Support Vector Machine Method*.
- Xin & Xiao. 2009. *Linear Regression Analysis: Theory and Computing*. 10.1142/6986.