

SKRIPSI

**PREDIKSI NILAI TUKAR BITCOIN TERHADAP DOLAR AS
DENGAN PENDEKATAN INDIKATOR TEKNIKAL
MENGUNAKAN METODE *EXTREME LEARNING
MACHINE***

Disusun dan diajukan oleh:

**AHMAD REZA SYAHBANA
D121 17 1006**



**PROGRAM STUDI SARJANA TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

LEMBAR PENGESAHAN SKRIPSI

PREDIKSI NILAI TUKAR BITCOIN TERHADAP DOLAR AS DENGAN PENDEKATAN INDIKATOR TEKNIKAL MENGUNAKAN METODE *EXTREME LEARNING MACHINE*

Disusun dan diajukan oleh

**Ahmad Reza Syahbana
D121 17 1006**

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian
Studi Program Sarjana Program Studi Teknik Informatika
Fakultas Teknik Universitas Hasanuddin
Pada tanggal 29 Januari 2024
dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

Pembimbing Utama,



Prof. Dr. Ir. Indrabayu, S.T., M.T.,
M.Bus.Sys., IPM., ASEAN.Eng.
NIP 19750716 2002121 004

Pembimbing Pendamping,



A. Ais Prayogi Alimuddin, S.T., M.Eng.
NIP 19830510 2014041 001



Ketua Program Studi,

Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM., ASEAN.Eng.
NIP 19750716 2002121 004

PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini ;

Nama : Ahmad Reza Syahbana

NIM : D121 17 1006

Program Studi : Teknik Informatika

Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Prediksi Nilai Tukar Bitcoin Terhadap Dolar AS dengan Pendekatan Indikator
Teknikal Menggunakan Metode *Extreme Learning Machine*

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Semua informasi yang ditulis dalam skripsi yang berasal dari penulis lain telah diberi penghargaan, yakni dengan mengutip sumber dan tahun penerbitannya. Oleh karena itu semua tulisan dalam skripsi ini sepenuhnya menjadi tanggung jawab penulis. Apabila ada pihak manapun yang merasa ada kesamaan judul dan atau hasil temuan dalam skripsi ini, maka penulis siap untuk diklarifikasi dan mempertanggungjawabkan segala resiko.

Segala data dan informasi yang diperoleh selama proses pembuatan skripsi, yang akan dipublikasi oleh Penulis di masa depan harus mendapat persetujuan dari Dosen Pembimbing.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Makassar, 30 Januari 2024

Yang Menyatakan



Ahmad Reza Syahbana

ABSTRAK

AHMAD REZA SYAHBANA. *Prediksi Nilai Tukar Bitcoin Terhadap Dolar AS dengan Pendekatan Indikator Teknikal Menggunakan Metode Extreme Learning Machine* (dibimbing oleh Indrabayu dan A. Ais Prayogi Alimuddin)

Bitcoin merupakan salah satu jenis mata uang digital *cryptocurrency* yang menawarkan *return* tinggi dalam investasi. Harga Bitcoin sangat fluktuatif, yang mana harganya bisa naik dan turun dengan cepat dalam waktu yang singkat. Untuk dapat meminimalisir hal tersebut diperlukan metode yang dapat membantu memprediksi harga Bitcoin agar memudahkan pengambilan keputusan dalam transaksi jual beli Bitcoin. Dengan kompleksitas pasar *cryptocurrency*, indikator teknikal dan metode *machine learning* telah digunakan sebagai pendekatan untuk memprediksi pergerakan harga Bitcoin.

Tujuan penelitian ini adalah untuk melihat korelasi antara indikator teknikal dengan harga Bitcoin dan menerapkan metode *Extreme Learning Machine* (ELM) untuk memprediksi nilai tukar Bitcoin terhadap Dolar AS dengan menggunakan data historis harga Bitcoin dan indikator teknikal.

Penelitian ini akan menggunakan data historis harga Bitcoin dan indikator teknikal dari platform Binance. Selanjutnya akan dilakukan uji korelasi Pearson antara indikator teknikal dengan harga Bitcoin, di mana indikator teknikal dengan korelasi tertinggi dan data historis harga Bitcoin akan digunakan sebagai *input* untuk model ELM. Setelah itu, dilakukan proses *training* dan *testing* dengan ELM untuk mendapatkan parameter optimal. Model akan dievaluasi menggunakan metrik evaluasi *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).

Berdasarkan hasil penelitian uji korelasi Pearson antara indikator teknikal dengan harga Bitcoin, indikator teknikal yang menunjukkan hubungan sangat tinggi yaitu *Simple Moving Average*, *Exponential Moving Average*, dan *Weighted Moving Average*. Hasil pengujian parameter ELM menghasilkan kombinasi terbaik yaitu *hidden neuron* sebanyak 20 *neuron*, jenis fungsi aktivasi adalah Sigmoid, dan rasio data *training* dan data *testing* sebesar 80% : 20%. Untuk harga Bitcoin *timeframe* 1 menit diperoleh MAPE dan RMSE terendah yaitu nilai rata-rata MAPE 5,455% dan RMSE 26,824. Hasil ini menunjukkan bahwa pendekatan indikator teknikal dan metode ELM dapat menjadi alat yang efektif dalam memprediksi harga Bitcoin.

Kata Kunci: Bitcoin, indikator teknikal, korelasi, *Extreme Learning Machine*, prediksi

ABSTRACT

AHMAD REZA SYAHBANA. *Prediction of Bitcoin Exchange Rate Towards American Dollar Using Extreme Learning Machine Method Combine with Technical Indicator Approach* (supervised by Indrabayu dan A. Ais Prayogi Alimuddin)

Bitcoin is one of the digital cryptocurrencies that offer high returns on investment. The price of Bitcoin is highly volatile, with its value fluctuating rapidly within short periods. To minimize this volatility, a method is needed to help predict Bitcoin prices, facilitating decision-making in buying and selling transactions. Given the complexity of the cryptocurrency market, technical indicators and machine learning methods have been employed as approaches to predict Bitcoin's price movements.

The aim of this research is to examine the correlation between technical indicators and Bitcoin prices and apply the Extreme Learning Machine (ELM) method to predict Bitcoin's exchange rate against the US Dollar using historical Bitcoin price data and technical indicators from the Binance platform.

This study will utilize historical Bitcoin price data and technical indicators from the Binance platform. Subsequently, a Pearson correlation test will be conducted between technical indicators and Bitcoin prices, with the technical indicators displaying the highest correlation being selected. These selected technical indicators, along with historical Bitcoin price data, will serve as inputs for the ELM model. The next steps involve training and testing the ELM model to obtain optimal parameters. The model's performance will be evaluated using the Mean Absolute Percentage Error (MAPE) and Root Mean Square Error (RMSE) evaluation metrics.

Based on the results of the Pearson correlation test between technical indicators and Bitcoin prices, technical indicators showing a very high relationship include the Simple Moving Average, Exponential Moving Average, and Weighted Moving Average. The ELM parameter testing yields the best combination, with 20 hidden neurons, a Sigmoid activation function, and an 80%:20% training-to-testing data ratio. For a 1-minute timeframe of Bitcoin prices, the lowest MAPE and RMSE values are obtained, with an average MAPE of 5.455% and an RMSE of 26.824. These results demonstrate that the combination of technical indicators and the ELM method can be an effective tool in predicting Bitcoin prices.

Keywords: Bitcoin, technical indicators, correlation, Extreme Learning Machine, predictions

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI.....	i
PERNYATAAN KEASLIAN.....	ii
ABSTRAK	iii
ABSTRACT	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR	vi
DAFTAR TABEL.....	vii
DAFTAR SINGKATAN DAN ARTI SIMBOL	viii
DAFTAR LAMPIRAN.....	ix
KATA PENGANTAR	x
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Ruang Lingkup.....	4
BAB II TINJAUAN PUSTAKA.....	5
2.1 <i>Cryptocurrency</i> Bitcoin.....	5
2.2 Analisa Teknikal	6
2.3 Uji Korelasi <i>Pearson</i>	14
2.4 Prediksi.....	15
2.5 Jaringan Saraf Tiruan (JST)	16
2.6 <i>Extreme Learning Machine (ELM)</i>	20
2.7 <i>Mean Average Percentage Error (MAPE)</i>	23
2.8 <i>Root Mean Square Error (RMSE)</i>	24
BAB III METODE PENELITIAN.....	25
3.1 Tahapan Penelitian	25
3.2 Waktu dan Lokasi Penelitian	26
3.3 Benda Uji dan Alat.....	26
3.4 Teknik Pengambilan Data	26
3.5 Perancangan Sistem	28
3.6 Implementasi Sistem Prediksi	45
3.7 <i>Dashboard</i> Sistem.....	46
BAB IV HASIL DAN PEMBAHASAN	48
4.1 Hasil Uji Korelasi Indikator Teknikal.....	48
4.2 Hasil Percobaan Parameter ELM.....	51
4.3 Hasil Percobaan Data dengan <i>Timeframe</i> 1 menit, 5 menit, 15 menit.....	58
4.4 Hasil Percobaan dengan Data <i>Realtime</i>	60
4.5 Hasil Percobaan Transaksi	62
BAB V KESIMPULAN DAN SARAN.....	65
5.1 Kesimpulan	65
5.2 Saran.....	66
DAFTAR PUSTAKA	67

DAFTAR GAMBAR

Gambar 1 Contoh grafik indikator SMA	8
Gambar 2 Contoh grafik indikator EMA	9
Gambar 3 Contoh grafik indikator WMA	10
Gambar 4 Contoh grafik indikator RSI	11
Gambar 5 Contoh grafik indikator MACD	12
Gambar 6 Contoh grafik indikator <i>Stochastic Oscillator</i>	13
Gambar 7 Struktur jaringan saraf tiruan	16
Gambar 8 Grafik fungsi <i>aktivasi Sigmoid</i>	17
Gambar 9 Grafik fungsi <i>aktivasi TanH</i>	18
Gambar 10 Grafik fungsi <i>aktivasi ReLU</i>	19
Gambar 11 Arsitektur algoritma <i>Extreme Learning Machine</i>	20
Gambar 12 Tahapan penelitian	25
Gambar 13 Grafik pergerakan harga Bitcoin	28
Gambar 14 <i>Flowchart</i> perancangan sistem	28
Gambar 15 Contoh hasil normalisasi	39
Gambar 16 Alur <i>training</i> ELM	41
Gambar 17 Alur <i>testing</i> ELM	42
Gambar 18 Implementasi sistem prediksi	45
Gambar 19 Tampilan <i>dashboard</i> sistem	46
Gambar 20 Korelasi Indikator Teknikal pada <i>Timeframe</i> 1 menit	49
Gambar 21 Korelasi Indikator Teknikal pada <i>Timeframe</i> 5 menit	50
Gambar 22 Korelasi Indikator Teknikal pada <i>Timeframe</i> 15 menit	50
Gambar 23 Rata-rata MAPE jumlah <i>hidden neuron</i>	53
Gambar 24 Rata-rata RMSE jumlah <i>hidden neuron</i>	53
Gambar 25 Rata-rata MAPE jenis fungsi aktivasi	55
Gambar 26 Rata-rata RMSE jenis fungsi aktivasi	55
Gambar 27 Rata-rata MAPE rasio pembagian data	57
Gambar 28 Rata-rata RMSE rasio pembagian data	57
Gambar 29 Rata-rata MAPE <i>timeframe</i> 1 menit, 5 menit, 15 menit	59
Gambar 30 Rata-rata RMSE <i>timeframe</i> 1 menit, 5 menit, 15 menit	59
Gambar 31 Visualisasi harga aktual dan prediksi <i>timeframe</i> 1 menit	61
Gambar 32 Visualisasi harga aktual dan prediksi <i>timeframe</i> 5 menit	61
Gambar 33 Visualisasi harga aktual dan prediksi <i>timeframe</i> 15 menit	61

DAFTAR TABEL

Tabel 1. <i>Range</i> nilai kekuatan korelasi	14
Tabel 2. <i>Range</i> nilai MAPE	23
Tabel 3. Sampel data	27
Tabel 4. Parameter indikator teknikal	30
Tabel 5. Nilai indikator SMA.....	31
Tabel 6. Nilai indikator EMA	32
Tabel 7. Nilai indikator WMA	34
Tabel 8. Nilai indikator RSI	35
Tabel 9. Nilai indikator MACD	36
Tabel 10. Nilai indikator <i>Stochastic Oscillator</i>	38
Tabel 11. Parameter model ELM	40
Tabel 12. Korelasi indikator teknikal terhadap pergerakan harga Bitcoin.....	48
Tabel 13. Hasil uji jumlah <i>Hidden Neuron</i>	52
Tabel 14. Hasil uji jenis fungsi aktivasi	54
Tabel 15. Hasil uji rasio data <i>training</i> dan <i>testing</i>	56
Tabel 16. Hasil Uji Pada <i>Timeframe</i> 1 menit, 5 menit, 15 menit.....	58
Tabel 17. Hasil percobaan <i>realtime</i>	60
Tabel 18. Hasil percobaan transaksi <i>timeframe</i> 1 menit	62
Tabel 19. Hasil percobaan transaksi <i>timeframe</i> 5 menit	63
Tabel 20. Hasil percobaan transaksi <i>timeframe</i> 15 menit	63

DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
BTC	Bitcoin
USD	Dolar United States (Amerika Serikat)
ELM	<i>Extreme Learning Machine</i>
SMA	<i>Simple Moving Average</i>
WMA	<i>Weighted Moving Average</i>
EMA	<i>Exponential Moving Average</i>
RSI	<i>Relative Strength Index</i>
MACD	<i>Moving Average Convergence Divergence</i>
MACDS	<i>MACD Signal</i>
RMSE	<i>Root Mean Square Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
JST	Jaringan Saraf Tiruan
SLFNs	<i>Single Layer Feedforward Neural Networks</i>
Stoch%D	<i>Stochastic %d atau slow stochastic</i>
Stoch%K	<i>Stochastic %k atau signal line</i>

DAFTAR LAMPIRAN

Lampiran 1 Sampel data harga Bitcoin.....	69
Lampiran 2 Hasil perhitungan indikator teknikal	72
Lampiran 3 Hasil normalisasi	73
Lampiran 4 <i>Source code Extreme Learning Machine</i>	74
Lampiran 5 <i>Source code dashboard</i> sistem	76
Lampiran 6 Lembar Perbaikan Skripsi	77

KATA PENGANTAR

Segala puji dan syukur penulis panjatkan kehadirat Allah SWT. karena atas berkat rahmat dan karunia-Nya sehingga Tugas Akhir yang berjudul “Prediksi Harga Bitcoin Terhadap Dolar AS dengan Pendekatan Indikator Teknikal Menggunakan Metode Extreme Learning Machine” dapat diselesaikan sebagai salah satu syarat dalam menyelesaikan jenjang Strata-1 di Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin.

Penulis Menyadari bahwa dalam proses penyusunan dan penulisan tugas akhir ini tidak dapat terselesaikan tanpa adanya bantuan, bimbingan, dukungan, serta doa dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT. atas semua karunia serta pertolongan-Nya yang tiada batas, yang telah diberikan kepada penulis di setiap langkah dalam penelitian hingga penulisan laporan ini.
2. Kedua orang tua penulis, Bapak H. Muh. Arsad dan Ibu Hj. Fatimah yang selalu mendoakan, memberikan dukungan dan semangat tiada henti, serta selalu sabar dalam menghadapi dan mendidik penulis.
3. Bapak Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM., ASEAN.Eng., selaku pembimbing 1 yang senantiasa meluangkan waktu, tenaga dan pikiran serta perhatian yang luar biasa untuk membimbing penulis dalam proses penyelesaian tugas akhir ini.
4. Bapak A. Ais Prayogi Alimuddin, S.T., M.Eng., selaku pembimbing 2 sekaligus dosen pembimbing akademik yang senantiasa meluangkan waktu, tenaga, dan pikiran dalam proses penyelesaian tugas akhir ini.
5. Segenap Dosen dan Staf Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin yang telah memberikan ilmu dan pengetahuan baru, serta bantuan kepada penulis selama menuntut ilmu di kampus.
6. Segenap keluarga AIMP Research Group Universitas Hasanuddin yang telah memberikan banyak bantuan selama penelitian dan memberikan suasana harmonis dan humoris pada saat di laboratorium.
7. Teman-teman RECOGN17ER yang banyak membantu selama kuliah dan dalam proses menyelesaikan tugas akhir ini.
8. Keluarga besar SN1PER yang telah membantu dari SMA hingga sekarang ini.
9. Serta pihak-pihak lain yang tidak sempat disebutkan dan tanpa sadar telah membantu penulis dalam menyelesaikan tugas akhir.

Dengan rasa syukur dan kerendahan hati, penulis memberikan rasa hormat yang tak terhingga, semoga Tuhan Yang Maha Esa membalas semua kebaikan

dari semua pihak yang telah banyak membantu penulis dalam menyelesaikan tugas akhir ini. Penulis menyadari tugas akhir ini masih banyak kekurangan dan jauh dari kata sempurna. Oleh karena itu, penulis mengharapkan segala masukan dan saran yang membangun sehingga tugas akhir ini dapat memberi manfaat bagi penulis dan pembaca. Akhir kata, semoga tugas akhir ini dapat dijadikan sebagai sumber ilmu pengetahuan dan bermanfaat bagi penulis dan pembaca pada umumnya.

Makassar, September 2023

Penulis

BAB I PENDAHULUAN

1.1 Latar Belakang

Bitcoin merupakan salah satu bentuk *cryptocurrency* yang dibuat oleh Satoshi Nakamoto pada tahun 2009 yang pengelolaannya tidak dipegang oleh suatu bank pusat, melainkan dikelola oleh pengguna Bitcoin yang identitasnya tidak diketahui. Dengan keadaan seperti itu membuat Bitcoin dilirik masyarakat karena kelebihan dalam pengelolaannya yang terdesentralisasi (tidak terpusat), kerahasiaan yang terjaga, serta prosesnya yang mudah (Faizal et al., 2019).

Sebagai aset *cryptocurrency* yang paling tertua, popularitas dari Bitcoin saat ini sangat tinggi karena banyak digunakan dan diminati oleh masyarakat dunia. Akan tetapi dibalik kepopuleran dan kelebihan yang dimiliki, Bitcoin juga memiliki kekurangan. Dimana kekurangan dari Bitcoin ini adalah perubahan harganya yang sangat fluktuatif, jika para investor dan pedagang finansial (*trader*) salah mengambil keputusan maka akan menyebabkan kerugian yang sangat signifikan (Juanda, 2018). Kerugian atau keuntungan yang diperoleh tergantung dari keahlian *trader* dalam memprediksi perubahan harga Bitcoin. Salah satu cara investasi pada *cryptocurrency* adalah dengan *trading*. *Trading* adalah membeli aset di harga terendah dan menjualnya di harga tertinggi. Dalam proses *trading* Bitcoin itu biasanya menggunakan analisis teknikal dan analisis fundamental dalam melihat dan memprediksi tren harga dari Bitcoin yang sangat fluktuatif.

Dalam *trading* Bitcoin, Analisis fundamental adalah suatu metode analisis yang dilakukan pada Bitcoin yang didasarkan pada penyebab kenaikan dan penurunan harga dengan memantau pergerakan dan sentimen pasar melalui berita maupun peristiwa penting hingga seseorang yang dapat mempengaruhi harga Bitcoin (Rahman Z., 2020). Melakukan analisis fundamental biasanya digunakan untuk menjawab apakah Bitcoin layak dijadikan sebagai salah satu aset investasi atau bahkan untuk mengetahui bagaimana harga Bitcoin kedepannya serta pertanyaan lain yang terkait dengan fundamental Bitcoin. Sedangkan Analisis teknikal adalah teknik analisis grafik yang dilakukan untuk

memprediksi arah pergerakan harga pada Bitcoin dengan mempelajari data historis yang kemudian di analisis menggunakan indikator teknikal maupun rumus matematis sebagai pendukung pengambilan keputusan (Rahman Z., 2020). Indikator teknikal yang biasanya digunakan antara lain *Moving Average*, *Relative Strength Index*, *Bollinger Band*, *Stochastic* dan masih banyak lagi indikator lainnya.

Analisis teknikal umumnya dilakukan dengan mengamati grafik pergerakan harga Bitcoin, dari situ biasanya dapat melihat beberapa pola tertentu dalam pergerakan harganya. Pola-pola pergerakan inilah yang biasanya dijadikan sebagai dasar analisis dengan bantuan indikator teknikal. Analisis teknikal diperuntukkan untuk investasi dengan jangka waktu pendek atau biasa disebut dengan *trading*, biasanya menggunakan *timeframe* M15, M5, bahkan M1. Maksud dari *timeframe* di sini merupakan sebuah periode waktu yang dipilih oleh seorang *trader* sebagai masa pengamatan pergerakan harga dengan pilihan seperti detik, menit, jam, hari, minggu dan bulan. M15 akan menggambarkan pergerakan harga selama 15 menit, M5 untuk 5 menit, dan M1 untuk 1 menit. Berbeda dengan analisis teknikal, analisis fundamental biasanya lebih mempertimbangkan banyak hal seperti keadaan global maupun berbagai macam asumsi yang dipakai di dalamnya. Analisis fundamental biasanya dipakai oleh investor yang ingin melakukan investasi dalam jangka waktu panjang.

Oleh karena itu, pada penelitian ini menggunakan analisis teknikal karena pada penelitian ini berfokus pada investasi jangka pendek atau dikenal dengan nama *trading* serta asumsi dasar bahwa pola harga mempunyai kecenderungan untuk berulang sehingga membuat analisa teknikal bisa digunakan untuk memprediksi potensi pergerakan harga dan analisa teknikal cenderung lebih mudah untuk menerapkannya pada model perhitungan matematis karena semua data dalam bentuk angka. Dimana dalam melakukan analisis teknikal digunakan indikator teknis yang dapat digunakan dalam membantu *trader* memprediksi harga Bitcoin. Indikator merupakan formula matematis untuk mengetahui kondisi pasar dan harga serta membantu memberikan sinyal jual atau beli. Dalam analisis teknikal terdapat banyak indikator, dari semua indikator teknikal tersebut akan

dipilih beberapa indikator dengan korelasi terbaik dan akan dijadikan acuan dalam memprediksi harga Bitcoin terhadap Dolar AS.

Algoritma *Extreme Learning Machine* (ELM) merupakan algoritma *feedforward* dan tergolong baru dalam jaringan saraf tiruan yang seringkali disebut sebagai *Single Layer Feedforward Neural Networks* (SLFNs). Kecepatan pembelajaran pada algoritma ini lebih cepat daripada algoritma *backpropagation* dan SVR serta algoritma ini cenderung menghasilkan nilai eror yang kecil (Huang et al., 2006). Pada sebuah penelitian yang dilakukan Huang et al. pada tahun 2012, performa ELM dibandingkan SVR menghasilkan nilai RMSE dari ELM mengungguli SVR dan ELM memiliki waktu pelatihan yang lebih cepat. Berdasarkan hal tersebut Metode ELM akan diimplementasikan untuk memprediksi harga Bitcoin karena telah mencapai kinerja terbaik dalam memprediksi dengan proses kecepatan pembelajaran yang cepat dan nilai eror yang kecil.

Oleh karena itu berdasarkan latar belakang yang telah dipaparkan, maka penulis mengusulkan judul “Prediksi Nilai Tukar Bitcoin Terhadap Dolar AS dengan Pendekatan Indikator Teknikal Menggunakan *Extreme Learning Machine*”.

1.2 Rumusan Masalah

1. Bagaimana korelasi antara indikator teknikal dengan harga Bitcoin menggunakan uji korelasi?
2. Bagaimana menerapkan indikator teknikal dalam memprediksi nilai tukar Bitcoin terhadap Dolar AS?
3. Bagaimana performa *Extreme Learning Machine* (ELM) dalam memprediksi nilai tukar Bitcoin terhadap Dolar AS?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Dapat melihat korelasi antara indikator teknikal terhadap harga Bitcoin.

2. Dapat menerapkan indikator teknikal dalam memprediksi nilai tukar Bitcoin terhadap Dolar AS.
3. Dapat mengetahui performa *Extreme Machine Learning* dalam memprediksi nilai tukar Bitcoin terhadap Dolar AS.

1.4 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Bagi *trader*, dapat menjadi alat bantu dalam melihat prediksi pergerakan harga Bitcoin.
2. Bagi peneliti, dapat menambah pengetahuan di bidang perdagangan *cryptocurrency* dan *time series forecasting*.
3. Bagi universitas, dapat menjadi referensi untuk penelitian selanjutnya.

1.5 Ruang Lingkup

1. Nilai tukar yang digunakan adalah BTC/USD.
2. Pergerakan harga BTC/USD menggunakan *timeframe* 1 menit, 5 menit, dan 15 menit.
3. Indikator teknikal yang akan digunakan yaitu *Simple Moving Average*, *Exponential Moving Average*, *Weighted Moving Average*, *Relative Strength Index*, *Moving Average Convergence Divergence*, *Stochastic Oscillator*.

BAB II

TINJAUAN PUSTAKA

2.1 *Cryptocurrency* Bitcoin

Cryptocurrency terdiri dari dua kata yaitu *crypto* berasal dari *cryptography* yang berarti bahasa pengkodean dalam dunia komputer dan *currency* yang berarti mata uang (Hambali, 2020). Dari pengertian tersebut dapat mendefinisikan bahwa *cryptocurrency* adalah mekanisme mata uang digital yang dapat digunakan untuk bertransaksi secara virtual. Menurut Syamsiah pada tahun 2017, *cryptocurrency* adalah sistem mata uang virtual yang bekerja seperti mata uang standar yang memungkinkan penggunaannya melakukan pembayaran virtual untuk transaksi bisnis yang berlangsung tanpa membayar biaya layanan tetapi tetap memiliki otoritas terpercaya yang terpusat.

Bitcoin pertama kali dikenal publik setelah terbitnya artikel yang ditulis oleh pendiri Bitcoin Satoshi Nakamoto pada tahun 2008. Artikel tersebut berjudul “Bitcoin: *A peer-to-peer electronic cash system*”, membahas algoritma dan teknologi yang digunakan oleh Bitcoin. Bitcoin adalah *cryptocurrency* yang memungkinkan transaksi online dilakukan langsung dari satu pihak ke pihak lain tanpa melalui lembaga keuangan dengan menggunakan konsep *peer-to-peer* (Nakamoto, 2008). Satoshi Nakamoto sendiri merupakan nama samaran, tidak diketahui apakah Satoshi Nakamoto adalah individu atau kelompok. Bitcoin adalah koin pertama yang beredar di antara banyaknya *cryptocurrency* saat ini. Bitcoin juga memiliki kapitalisasi pasar terbesar dibandingkan koin lainnya (CoinMarketCap, 2021), Bitcoin memiliki satuan yang biasa dikenal dengan BTC.

Bitcoin lahir dari kekecewaan Nakamoto terhadap krisis keuangan yang dimulai pada 2007-2008 dan reaksi pemerintah terhadap krisis tersebut. Dengan Bitcoin, Nakamoto berharap dapat menghilangkan pihak ketiga dalam transaksi yang dilakukan secara *online*. Karena menurut Nakamoto, selalu ada pihak ketiga yang diuntungkan dari setiap transaksi *online* yang dilakukan seseorang melalui PayPal, kartu kredit atau Western Union (Maurer et al., 2013). Bitcoin adalah mata uang seperti dolar atau rupiah, bedanya Bitcoin tidak seperti mata uang lain

yang dikendalikan oleh bank atau pemerintah. Bitcoin terdesentralisasi, artinya Bitcoin murni dikendalikan oleh pemiliknya, itulah sebabnya harga Bitcoin selalu fluktuatif karena sangat dipengaruhi oleh *supply* dan *demand* (Amjad et al., 2017). Bitcoin sangat fluktuatif karena sejumlah faktor, termasuk volume dan distribusi Bitcoin, penipuan yang mengatasnamakan Bitcoin, dan spekulasi pemilik aset.

2.2 Analisa Teknikal

2.2.1 Pengertian Analisa Teknikal

Analisis teknikal adalah teknik analisis yang digunakan untuk mengamati pola seperti data pasar, harga saham, dan volume perdagangan. Analisis teknikal digunakan untuk menganalisis harga berdasarkan data harga masa lalu. Hal ini dilakukan dalam hubungannya dengan berbagai indikator teknikal yang memberikan sebuah pandangan unik mengenai kekuatan dan arah pergerakan harga selama jangka waktu tertentu. Analisis teknikal adalah studi tentang perilaku harga di pasar keuangan untuk memprediksi pergerakan harga selanjutnya dan membantu membuat keputusan perdagangan yang lebih baik.

Secara umum, analisa teknikal digunakan untuk menentukan waktu yang tepat untuk membeli suatu aset, menentukan target harga yaitu titik untuk menjual atau keluar dari aset tersebut dan merealisasikan keuntungan yang dihasilkan (*take profit*), serta menentukan *stop loss* yaitu titik untuk menjual suatu aset dalam keadaan rugi adalah ketika pergerakan harganya tidak sesuai dengan analisa yang dibuat, sehingga risiko kerugian tetap terkendali sesuai rencana. Inilah yang disebut dengan *trading plan*. Kesalahan yang sering dilakukan oleh para pengguna analisis teknikal adalah tidak adanya *trading plan* saat membeli sebuah aset.

Dalam analisis teknikal terdapat formula matematis atau biasa disebut indikator teknikal, yang berfungsi untuk mengetahui bagaimana kondisi pasar dan juga untuk membantu memberikan sinyal beli atau jual dalam sebuah perdagangan. Saat ini ada ratusan atau bahkan ribuan indikator yang telah dibuat. Tiap indikator memiliki karakter dan cara

penggunaannya masing-masing. Data-data harga yang digunakan dalam analisa teknikal meliputi berbagai kombinasi dari harga *open*, *high*, *low* dan *close* selama periode waktu tertentu.

2.2.2 Simple Moving Average (SMA)

Simple Moving Average (SMA) merupakan salah satu indikator analisis teknikal yang digunakan untuk memprediksi suatu pergerakan nilai rata-rata instrumen investasi dengan rentang waktu tertentu. Indikator SMA dapat digunakan untuk mengetahui arah pergerakan harga, apakah sedang *uptrend*, *sideways*, atau *downtrend*. Selain itu SMA juga dapat digunakan untuk *support* dan *resistance* atau bahkan sinyal beli dan jual. SMA adalah rata-rata sederhana dari harga *close* (P) selama n periode. Ini memberikan gambaran umum tentang tren harga dalam jangka waktu tertentu. Metode SMA ini memiliki sifat khusus yaitu untuk membuat prediksi dibutuhkan data historis dengan kurun waktu tertentu, dimana semakin panjang *moving average* maka akan menghasilkan *moving average* yang semakin halus. Rumus dari *Simple Moving Average* ditunjukkan pada persamaan 1.

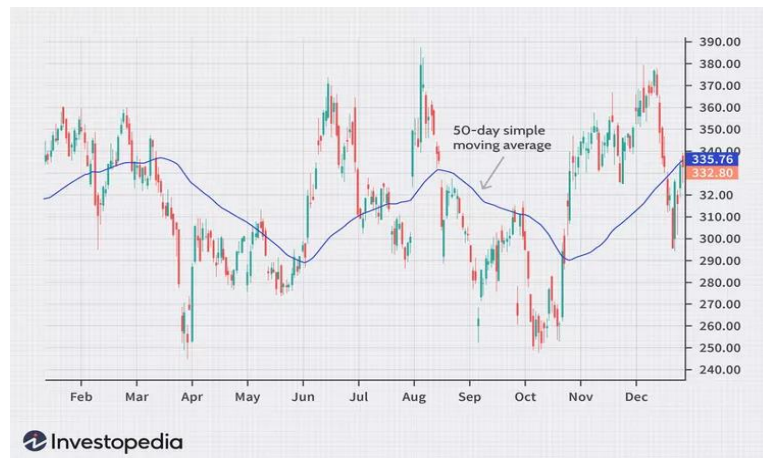
$$SMA = \frac{P_1 + P_2 + \dots + P_n}{n} \quad (1)$$

Di mana:

n = Jumlah periode

P_n = Harga *close* pada periode ke-n

Sinyal beli dalam indikator SMA ditunjukkan dengan grafik SMA berada dibawah grafik harga, kemudian sinyal jual ketika grafik SMA berada diatas grafik harga. Periode *Simple Moving Average* yang sering digunakan adalah periode 10, 20, 50, dan 200. Berikut grafik indikator SMA ditunjukkan pada Gambar 1.



Gambar 1 Contoh grafik indikator SMA
(Sumber: www.investopedia.com)

2.2.3 Exponential Moving Average (EMA)

Meskipun perhitungan EMA tidak sesederhana SMA, namun EMA memberikan bobot yang lebih dalam perhitungan harga rata-rata dengan rentang waktu tertentu. Dimana efek yang terjadi adalah EMA cenderung lebih sensitif terhadap pergerakan harga, sehingga EMA bergerak sedikit lebih agresif daripada SMA. Indikator ini tidak hanya membantu mengonfirmasi tren, tetapi juga dapat digunakan untuk memberikan sinyal *trading*. Indikator EMA merupakan indikator *lagging*. Karena menggunakan data masa lalu, harga akan selalu berada pada pergerakan sebelum EMA bereaksi. Rumus EMA dapat dilihat pada persamaan 2.

$$EMA = P_t \times k + EMA_{t-1} \times (1 - k) \quad (2)$$

Di mana:

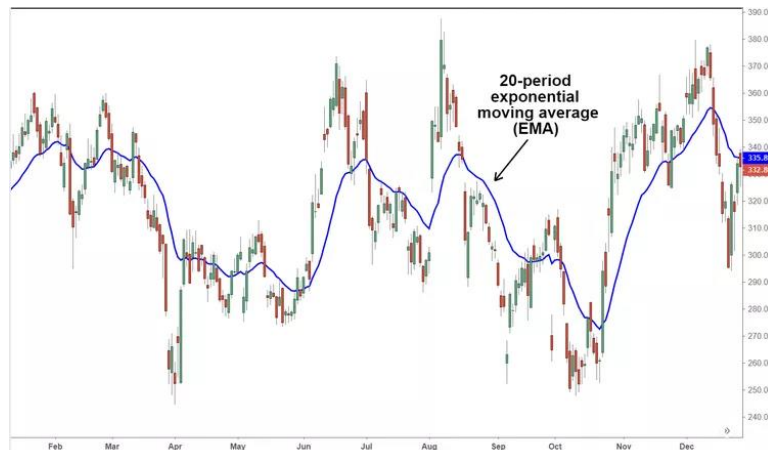
P_t = Harga *close* pada periode t

EMA_{t-1} = Nilai EMA pada periode sebelumnya

k = *Weighting factor* atau besar faktor pembobotan, dihitung dengan rumus $2 / (n + 1)$

n = Periode yang digunakan

Secara umum, *Exponential Moving Average* akan merespons lebih cepat dengan data yang lebih baru dibandingkan dengan SMA, karena memberikan bobot yang lebih pada harga yang lebih baru. Karakteristik kurva sebenarnya diatur oleh periode yang dipilih. Berikut grafik indikator EMA ditunjukkan Gambar 2.



Gambar 2 Contoh grafik indikator EMA
(Sumber: www.tradingview.com)

2.2.4 *Weighted Moving Average (WMA)*

Weighted Moving Average (WMA) bisa dibilang merupakan pengembangan dari *Simple Moving Average (SMA)*. Pada SMA setiap data harga diasumsikan memiliki bobot yang sama, berikut rumus WMA pada persamaan 3.

$$WMA = \frac{P_1 \times W_1 + P_2 \times W_2 + \dots + P_n \times W_n}{W_1 + W_2 + \dots + W_n} \quad (3)$$

Di mana:

P = Harga *close* sebelumnya

W = Bobot untuk harga *close*

n = Periode yang digunakan

Pada WMA data harga justru diberikan bobot yang berbeda dimana data harga terbaru memiliki bobot yang lebih besar dibandingkan data lama

sehingga mampu memberikan akurasi perhitungan yang lebih tinggi. Berikut gambaran indikator WMA pada Gambar 3.



Gambar 3 Contoh grafik indikator WMA
(Sumber: www.fidelity.com)

2.2.5 Relative Strength Index (RSI)

Relative Strength Index (RSI) adalah indikator yang digunakan untuk menghitung perbandingan antara daya tarik kenaikan dan penurunan harga, nilainya berkisar 0-100. Dengan RSI dapat mengetahui apakah suatu harga sudah *overbought* atau *oversold*. Rumus RSI dapat dilihat pada persamaan 4.

$$RSI = 100 - \left[\frac{100}{1 + \frac{\text{Average Gain}}{\text{Average Loss}}} \right] \quad (4)$$

Di mana:

$$\text{Average Gain} = \frac{\text{Total Gains}}{n}$$

$$\text{Average Loss} = \frac{\text{Total Losses}}{n}$$

Pada prinsipnya, penggunaan RSI sangat mudah. Jika RSI bernilai sangat tinggi (di atas 70) artinya pasar sudah *overbought* (jenuh beli) sehingga ada potensi turun, saatnya untuk jual. Sebaliknya jika RSI bernilai

sangat rendah (di bawah 30) artinya pasar sudah *oversold* (jenuh jual) sehingga ada potensi naik, saatnya untuk beli (Ariwibowo, 2022). Berikut gambaran indikator RSI ditunjukkan pada Gambar 4.



Gambar 4 Contoh grafik indikator RSI
(Sumber: www.investopedia.com)

2.2.6 Moving Average Convergence Divergence (MACD)

MACD digunakan untuk menentukan kekuatan tren saat ini dan untuk mengidentifikasi perubahan pada tren sekarang. Metode ini menggunakan perpotongan dua *Exponential Moving Average* (EMA). Kombinasi dari beberapa prinsip dari *Oscillator Indicator* dengan pendekatan *Moving Average Crossover* akan terlihat garis-garis di dalam grafik dan pergerakan garis EMA (*slow*) dengan EMA (*fast*). Garis dengan pergerakan lebih cepat (*fast*) disebut sebagai signal line atau garis indikasi yang biasanya menggunakan parameter 9 hari dari garis MACD, dapat juga digunakan garis indikasi parameter 14 hari. Untuk mendapatkan nilai MACD pertama hitung EMA periode 12 dan EMA periode 26, sedangkan untuk *Signal Line* dihitung menggunakan EMA periode 9 dari MACD. Berikut rumus untuk menghitung MACD ditunjukkan pada persamaan 5.

$$MACD = EMA_{12} - EMA_{26} \quad (5)$$

Di mana:

EMA_{12} = Nilai EMA untuk periode 12

EMA_{26} = Nilai EMA untuk periode 26

MACD mengidentifikasi *Moving Averages* yang berindikasi dimulainya trend baru, MACD dapat melihat 3 buah indikator. Pertama adalah garis EMA periode pendek (*fast*), kedua adalah garis EMA periode panjang (*slow*), dan ketiga adalah susunan *histogram* atau garis yang menggambarkan ukuran jarak antara kedua EMA tersebut (Soemapradja, 2010). Berikut contoh grafik MACD ditunjukkan pada Gambar 5.



Gambar 5 Contoh grafik indikator MACD
(Sumber: www.investopedia.com)

2.2.7 Stochastic Oscillator

Stochastic adalah indikator yang menunjukkan lokasi harga penutupan terakhir dibandingkan dengan *range* harga terendah/tertinggi selama periode waktu tertentu. *Stochastic* dikembangkan oleh George C. Lane di akhir 1950-an. Ada tiga macam tipe *Stochastic Oscillators*: *Fast*, *Slow*, dan *Full*. Biasanya ada dua garis di *Stochastic*, yaitu %K dan %D. Sinyal beli dan jual bisa dilihat dari garis %K dan %D. Jika %K memotong %D ke atas, berarti sinyal beli. Sedangkan bila %K memotong %D ke

bawah berarti sinyal jual (Ariwibowo, 2022). Dalam *Stochastic Oscillator* terdapat dua perhitungan yaitu:

Menghitung nilai K (*Stochastic %K*) menggunakan rumus pada persamaan 6.

$$\%K = 100 \times \frac{Price - L_n}{H_n - L_n} \quad (6)$$

Di mana:

C = Harga *close*

L_n = Harga *highest low* dalam kisaran harga selama n periode


H_n = Harga *highest high* dalam kisaran harga selama n periode

n = Periode yang digunakan

Kemudian menghitung nilai *Stochastic %D* dengan rata-rata dari %K selama 3 periode menggunakan rumus pada persamaan 7.

$$\%D = \frac{K1 + K2 + K3}{3} \quad (7)$$

Stochastic Oscillator adalah sebuah indikator momentum yang beresilasi di antara 0 dan 100 dengan pembacaan di bawah 20 dianggap *oversold* dan pembacaan di atas 80 dianggap *overbought*. Berikut gambaran dari indikator *Stochastic Oscillator* pada Gambar 6.



Gambar 6 Contoh grafik indikator *Stochastic Oscillator*
(Sumber: www.investopedia.com)

2.3 Uji Korelasi *Pearson*

Sarwono pada tahun 2012 menyatakan bahwa menggunakan statistik sebagai alat analisis dalam penelitian kuantitatif merupakan hal yang wajib, karena statistik merupakan alat ukur yang akurat dalam melihat hubungan antar variabel yang diteliti. Sekalipun demikian, peneliti sebaiknya hati-hati dalam memilih alat analisis statistik yang cocok dengan jenis data dan tujuan penelitiannya. Jika jenis datanya interval dan hipotesisnya bersifat asosiatif, maka teknik analisis statistik yang digunakan dalam mencari hubungan antara variabel untuk data numerik adalah teknik korelasi dengan *Pearson* atau dikenal dengan *Pearson Product Moment Correlation*.

Korelasi *Pearson* merupakan pengukuran *parametrik* yang berfungsi untuk menentukan hubungan antara dua variabel. Besarnya korelasi adalah 0 sampai 1. Korelasi dapat menghasilkan angka positif dan negatif. Korelasi positif artinya searah, jika variabel pertama besar maka variabel kedua semakin besar juga. Korelasi negatif artinya berlawanan arah, jika variabel pertama besar maka variabel kedua semakin mengecil (Sarwono, 2012). *Range* nilai hasil perhitungan korelasi ditunjukkan pada Tabel 1.

Tabel 1. *Range* nilai kekuatan korelasi

Korelasi	Kekuatan Korelasi
< 0,20	Hubungan dapat dianggap tidak ada
0,20 – 0,40	Hubungan ada tetapi rendah
> 0,40 – 0,70	Hubungan cukup
> 0,70 – 0,90	Hubungan tinggi
> 0,90 – 1,00	Hubungan sangat tinggi

Rumus uji korelasi *Pearson* dapat dituliskan pada persamaan 8.

$$r_{xy} = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{\{n \sum x^2 - (\sum x)^2\} \{n \sum y^2 - (\sum y)^2\}}} \quad (8)$$

Di mana:

r_{xy} = Nilai korelasi *r Pearson*

n	= Banyaknya data
x	= Variabel bebas/variabel pertama
y	= Variabel terikat/variabel kedua
$\sum x$	= Jumlah setiap variabel x
$\sum y$	= Jumlah setiap variabel y
$\sum xy$	= Jumlah hasil kali variabel x dan variabel y
$\sum x^2$	= Jumlah hasil kuadrat variabel x
$\sum y^2$	= Jumlah hasil kuadrat variabel y

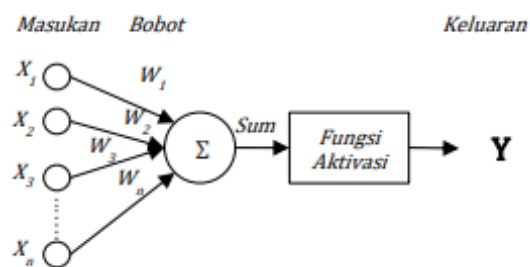
2.4 Prediksi

Prediksi adalah proses memperkirakan sesuatu secara sistematis, berdasarkan informasi yang ada atau tersimpan, untuk sesuatu yang akan terjadi atau belum diketahui. Prediksi berguna untuk membantu pengambilan keputusan dan perencanaan masa depan. Dengan begitu, risiko yang akan terjadi dapat ditangani dengan baik. Ada dua jenis prediksi, yaitu klasifikasi dan regresi. Klasifikasi adalah perkiraan kelompok atau kelas dari suatu entitas dengan aturan tertentu. Berbeda dengan klasifikasi, regresi merupakan perkiraan nilai suatu entitas berdasarkan karakteristik yang dimilikinya (Padhila et al., 2022).

Regresi dapat digunakan untuk membuat prediksi berdasarkan hubungan antara 2 parameter atau lebih. Regresi dapat membuat prediksi untuk mendapatkan nilai yang menggambarkan kondisi masa depan berdasarkan parameter yang mempengaruhi (Faizal et al., 2019). Pada penelitian ini penulis menggunakan regresi untuk mendapatkan nilai numerik yaitu harga Bitcoin.

2.5 Jaringan Saraf Tiruan (JST)

Jaringan Saraf Tiruan (JST) adalah model komputasi yang meniru fungsi saraf di otak atau mengadaptasi cara kerja otak manusia. JST memiliki kemiripan dengan *neuron* manusia yang berhubungan satu sama lain (Faizal et al., 2019). Berikut gambaran sederhana struktur *node* atau *neuron* jaringan saraf tiruan ditunjukkan pada Gambar 7.



Gambar 7 Struktur jaringan saraf tiruan

Dalam struktur jaringan saraf tiruan ini, terdapat lapisan masukan (*input layer*) sejumlah n yang terdiri dari beberapa *neuron* yaitu $X_1, X_2, X_3, \dots, X_n$. Kemudian, nilai masing-masing masukan akan dikalikan dengan bobot (*weight*) $W_1, W_2, W_3, \dots, W_n$ yang sudah diinisialisasi sebelumnya dengan rentang nilai yang sudah ditentukan. Setelah penjumlahan masing-masing masukan dan bobot dilakukan, maka proses selanjutnya adalah menjumlahkan seluruh *neuron* dari hasil penjumlahan tersebut dan dimasukkan ke dalam sebuah fungsi *aktivasi* untuk menentukan nilai ambang (*threshold*) neuron tersebut. Untuk meneruskan informasi yang didapatkan, nilai masukan hasil *aktivasi* harus dapat melewati nilai ambang tertentu sehingga dapat diteruskan menjadi keluaran untuk dikirim ke *neuron* lain (Faizal et al., 2019).

Fungsi *aktivasi* dalam jaringan saraf tiruan adalah fungsi matematis yang digunakan untuk menentukan apakah *neuron* dalam jaringan harus aktif atau non-aktif berdasarkan *input* yang diberikan. Jaringan saraf pada dasarnya merupakan kombinasi dari beberapa fungsi linier dan non-linier. Jika hanya memiliki fungsi linier pada jaringan di semua lapisan (*layer*) maka jaringan tersebut tidak akan bisa belajar banyak, itulah mengapa menggunakan fungsi *aktivasi* untuk

menghasilkan *output* dari setiap proses di setiap lapisan (*layer*). Non-linear mengacu pada sifat fungsi *aktivasi* yang memungkinkan jaringan saraf untuk memahami dan menangkap pola yang tidak linear dalam data (Nielsen, 2015). Dalam konteks fungsi *aktivasi*, *non-linear* sangat penting karena banyak masalah dalam dunia nyata melibatkan hubungan yang tidak sederhana antara *input* dan *output*. Tanpa fungsi *aktivasi* yang memperkenalkan *non-linearitas*, jaringan saraf hanya akan mampu memodelkan hubungan linear yang terbatas dalam data. Ada beberapa fungsi aktivasi dalam jaringan saraf tiruan antara lain:

1. Linear (*Identity Function*)

Fungsi *aktivasi* linear tidak mengubah nilai *input*. Ini berarti bahwa jika *neuron* menerima *input* x , maka akan mengirimkan *output* x tanpa perubahan apapun. Oleh karena itu, tidak memberikan elemen *non-linearitas* pada model. Fungsi ini berguna dalam tugas regresi sederhana di mana model menghasilkan nilai kontinu tanpa transformasi kompleks. Rumus fungsi ini dapat dituliskan pada persamaan 9.

$$f(x) = x \quad (9)$$


Di mana:

$f(x)$ = *Output aktivasi* linear

x = *Input aktivasi* linear

2. *Sigmoid*

Fungsi *aktivasi Sigmoid* mengubah *input* menjadi rentang nilai antara 0 dan 1. Berikut grafik fungsi *Sigmoid* ditunjukkan pada Gambar 8.



Gambar 8 Grafik fungsi *aktivasi Sigmoid*

Fungsi *aktivasi Sigmoid* sering juga digunakan dalam klasifikasi *biner* karena menghasilkan *output* yang dapat diinterpretasikan sebagai probabilitas. Namun, fungsi *Sigmoid* memiliki kelemahan "*vanishing gradient*" dalam jaringan yang sangat dalam, yang dapat menghambat pembelajaran. *Vanishing gradient* adalah masalah yang terjadi pada jaringan saraf tiruan ketika *gradient* (turunan) yang dihasilkan oleh fungsi aktivasi menjadi sangat kecil atau bahkan mendekati nol. Hal ini menyebabkan bobot (*weight*) pada layer yang lebih awal tidak diperbarui dengan baik, sehingga performa jaringan menjadi buruk. Rumus fungsi ini dapat dituliskan pada persamaan 10.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

Di mana:


$f(x)$ = *Output* fungsi *Sigmoid*

x = *Input* ke fungsi *Sigmoid*

e = Bilangan konstan *Euler* (2.71828...)

3. TanH (*Hyperbolic Tangent*)

Fungsi *aktivasi TanH* mengubah *input* menjadi rentang nilai antara -1 dan 1, dan memiliki simetri nol di tengahnya. Berikut grafik fungsi TanH ditunjukkan pada Gambar 9.



Gambar 9 Grafik fungsi *aktivasi TanH*

Fungsi *aktivasi* TanH memungkinkan model untuk memodelkan hubungan non-linear yang lebih kompleks dibandingkan dengan fungsi *aktivasi* linear atau sigmoid. Nilai positif dekat dengan 1, nilai negatif dekat dengan -1, dan nilai mendekati 0 di sekitar nol. Rumus fungsi ini dapat dituliskan pada persamaan 11.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

Di mana:


$f(x)$ = *Output* dari fungsi TanH

x = *Input* ke fungsi tanh

e = Bilangan konstan *Euler* (2.71828...)

4. ReLU (*Rectified Linear Unit*)

Fungsi *aktivasi* ReLU mengganti nilai *input* negatif menjadi 0 dan membiarkan nilai *input* positif tidak berubah. Ini membuatnya menjadi fungsi yang sangat efisien dalam pembelajaran jaringan saraf. Berikut grafik fungsi ReLU ditunjukkan pada Gambar 10.



Gambar 10 Grafik fungsi *aktivasi* ReLU

Fungsi *aktivasi* ReLU memberikan sifat non-linear pada model, memungkinkannya untuk memahami pola yang lebih kompleks dalam data. Contoh, jika *input* positif, maka *neuron* akan aktif; jika *input* negatif, maka *neuron* tidak aktif. Rumus fungsi ini dapat dituliskan pada persamaan 12.

$$f(x) = \max(0, x) \quad (12)$$

Di mana:

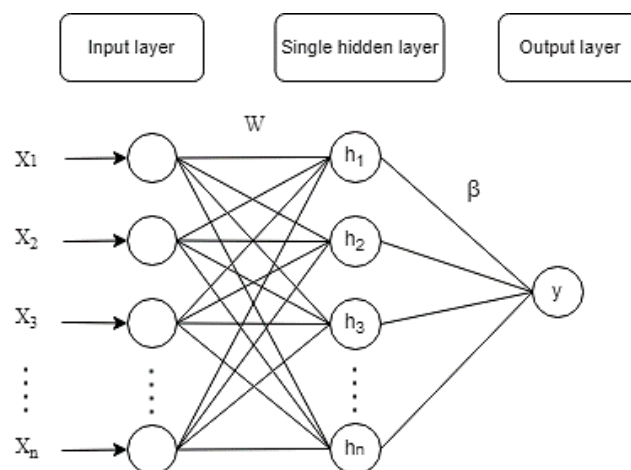
$f(x)$ = Output dari fungsi ReLU

x = Input ke fungsi ReLU

\max = Fungsi matematis yang mengembalikan nilai terbesar dari input

2.6 Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) merupakan metode jaringan saraf tiruan (JST) dengan hanya satu lapisan tersembunyi atau biasa dikenal dengan *Single Layer Feedforward Neural Networks* (SLFNs). Pada umumnya JST lain melakukan pembobotan dan menentukan nilai bias pada pelatihan, sedangkan ELM mengambil bobot dan bias secara acak. Oleh karena itu, *learning speed* yang dimiliki ELM sangat cepat dibandingkan metode JST konvensional lainnya serta adanya matriks *Moore-Penrose Generalized Inverse* yang meminimalkan nilai error (Huang et al., 2006). Pada algoritma ini terdapat *input layer*, *single hidden layer*, dan *output layer*, dimana setiap lapisan memiliki *neuron* yang saling berhubungan (Sun et al., 2008). Arsitektur dari *Extreme Learning Machine* ditunjukkan pada Gambar 11.



Gambar 11 Arsitektur algoritma *Extreme Learning Machine*

Algoritma ELM ini terdapat dua proses yaitu proses *training* dan proses *testing*. Namun perlu dilakukan normalisasi sebelum proses *training* dan *denormalisasi* setelah proses *testing*. Tujuannya agar data yang digunakan memiliki rentang data yang sama (Cholissodin et al., 2019).

Proses *training* dilakukan untuk melatih sistem agar bisa memprediksi secara akurat. Tahapan *training* pada metode ELM menurut (Huang et al., 2006):

1. Menginisialisasi nilai matriks *input* bobot dan nilai matriks bias dengan nilai acak. Kemudian membuat matriks *input weight* dengan ordo jumlah *hidden node* (k) \times jumlah *input node* (j) dan membuat matriks bias dengan ordo $1 \times k$ secara acak.
2. Melakukan perhitungan matriks *output hidden layer* dengan memakai rumus yang ada pada persamaan 13.

$$H_{init} = X_{training} \times w + b \quad (13)$$

Di mana:

H_{init} = Matriks *output hidden layer*

$X_{training}$ = Data *training*

w = Matriks *input weight* (bobot)

b = Bias matriks

3. Hitung matriks H_{init} dengan fungsi *aktivasi* yang digunakan sehingga menghasilkan matriks H .
4. Kemudian nilai matriks H ini diinverskan menggunakan *Moore Penrose Generalized Inverse*. Konsep *invers* matriks pada umumnya merupakan konsep *invers* matriks yang terbatas pada matriks persegi berordo $n \times n$ dan *non-singular*. Matriks yang berordo $m \times n$ yang *singular* tidak mempunyai *invers*. Akan tetapi, terdapat matriks yang seolah-olah menjadi *invers* untuk matriks yang berordo $m \times n$ yang *singular*. Matriks tersebut dinamakan *Moore Penrose Generalized Inverse* atau *pseudoinverse* yang ditemukan oleh E.H. Moore pada tahun 1920 dan Roger Penrose pada tahun 1955. Berikut rumusnya pada persamaan 14.

$$H^+ = (H^T \times H)^{-1} \times H^T \quad (14)$$

Di mana:

H^+ = *Moore Penrose Generalized Invers*

H^T = Matriks H *transpose*
 H = Nilai *output hidden layer*

5. Menghitung *output weight* matriks dengan menggunakan persamaan 15.

$$\beta = H^+ \times T \quad (15)$$

Di mana:

β = *Output weight* matriks
 T = Target

6. Langkah terakhir pada proses *training* adalah menghitung nilai *output layer*. Dapat dilihat pada persamaan 16.

$$Y = H \times \beta \quad (16)$$

Di mana:

Y = Matriks *output layer*
 H = Nilai *output hidden layer*
 β = *Output weight* matriks

Setelah melakukan proses *training* selanjutnya dilakukan proses *testing* agar dapat mengetahui hasil prediksi dengan menggunakan metode ELM. Tahapan *testing* dengan ELM adalah sebagai berikut:

1. Nilai matriks untuk *input weight*, bias dan *output weight* dari tahap pelatihan disimpan untuk melakukan pengujian.
2. Hitung *output hidden layer* (H_{init}) memakai rumus yang ada pada persamaan 13, namun data *training* diganti dengan data *testing*.
3. Hitung matriks H_{init} dengan fungsi *aktivasi* yang digunakan sehingga menghasilkan matriks H .
4. Menghitung hasil prediksi dengan menggunakan persamaan 17.

$$Y' = H \times \beta \quad (17)$$

Di mana:

Y' = Nilai prediksi dalam bentuk matriks *output layer*

2.7 Mean Average Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan salah satu metode evaluasi yang digunakan untuk mengukur tingkat kesalahan relatif dan keakuratan suatu model dalam melakukan prediksi. MAPE merupakan salah satu metrik evaluasi yang paling umum digunakan karena menampilkan keakuratan prediksi dalam bentuk persentase dan menyajikan nilai kesalahan yang mudah dipahami dibandingkan metode lainnya (Kim & Kim, 2016). Pada penelitian ini metode evaluasi yang digunakan adalah MAPE. Perhitungan MAPE menggunakan rumus pada persamaan 18.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - P_i}{A_i} \right| \times 100\% \quad (18)$$

Di mana:

n = Ukuran sampel

A_i = Nilai data aktual

P_i = Nilai data prediksi

Berdasarkan rumus tersebut, selisih antara data aktual dan data prediksi dibagi dengan data aktual, kemudian nilainya dimutlakkan (absolut). Artinya MAPE akan selalu positif. Semakin rendah nilai MAPE maka semakin baik model dalam melakukan prediksi. *Range* nilai MAPE ditunjukkan pada Tabel 2 (Hutasuhut et al., 2014).

Tabel 2. *Range* nilai MAPE

Nilai MAPE	Interpretasi
< 10%	Hasil prediksi sangat baik
10% – 20%	Hasil prediksi baik
20% – 50%	Hasil prediksi layak (cukup baik)
> 50%	Hasil prediksi buruk

2.8 Root Mean Square Error (RMSE)

Root Mean Square Error merupakan metrik evaluasi untuk mengukur besarnya kesalahan prediksi yang paling banyak digunakan dalam evaluasi hasil peramalan. RMSE didapat dari nilai rata-rata pangkat perbandingan antara nilai yang diprediksi dengan nilai sebenarnya. RMSE digunakan untuk mengukur deviasi absolut atau besarnya selisih antara nilai prediksi dan nilai sebenarnya. Persamaan untuk menghitung nilai RMSE ditunjukkan dalam persamaan 19.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - P_i)^2} \quad (19)$$

Di mana:

n = Jumlah data

A_i = Nilai aktual

P_i = Nilai prediksi