

**PERAMALAN HARGA ETHEREUM MENGGUNAKAN
METODE PSO-BACKPROPAGATION
NEURAL NETWORK**

SKRIPSI



Disusun Oleh:

CHANDRA INDIRA SEPTIARANI

NIM: H76217053

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA
2022**

PERNYATAAN KEASLIAN

Saya yang bertanda tangan dibawah ini:

Nama : Chandra Indira Septiarani
NIM : H76217053
Program Studi : Sistem Informasi
Angkatan : 2017

Menyatakan bahwa saya tidak melakukan plagiasi dalam penulisan skripsi saya yang berjudul: PERAMALAN HARGA ETHEREUM MENGGUNAKAN METODE PSO-BACKPROPAGATION NEURAL NETWORK. Apabila suatu saat nanti terbukti saya melakukan tindakan plagiasi, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Sidoarjo, 7 Januari 2022

Yang menyatakan,



4068AAJX014111699

(Chandra Indira Septiarani)

LEMBAR PERSETUJUAN PEMBIMBING SKRIPSI

Skripsi oleh

NAMA : Chandra Indira Septiarani

NIM : H76217053

JUDUL : **PERAMALAN HARGA ETHEREUM MENGGUNAKAN
METODE PSO – BACKPROPAGATION NEURAL
NETWORK**

Ini telah diperiksa dan disetujui untuk diujikan

Surabaya, 15 Juli 2021

Menyetujui,

Dosen pembimbing I



(Faris Mushlihul Amin, M. Kom)

NIP. 198808132014031001

Dosen pembimbing II



(Ahmad Yusuf M.Kom)

NIP. 199001202014031003

PERSETUJUAN TIM PENGUJI TUGAS AKHIR

Tugas Akhir Chandra Indira Septiarani telah dipertahankan

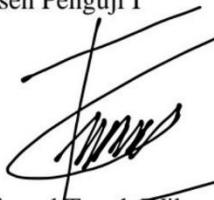
Di depan tim penguji tugas akhir

Surabaya, 15 Januari 2022

Mengesahkan,

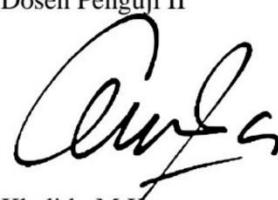
Dewan Penguji,

Dosen Penguji I



Achmad Teguh Wibowo, MT
NIP. 198810262014031003

Dosen Penguji II



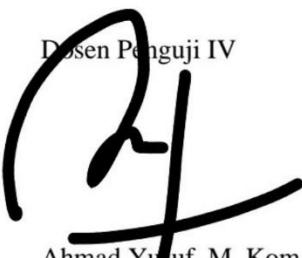
Khalid , M.Kom
NIP. 197906092014031002

Dosen Penguji III



Faris Mushlighul Amin, M. Kom
NIP. 198808132014031001

Dosen Penguji IV



Ahmad Yusuf, M. Kom
NIP. 199001202014031003

Mengetahui,

Dekan Fakultas Sains dan Teknologi

UIN Sunan Ampel Surabaya





KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

**LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : CHANDRA INDIRA SEPTIARANI
NIM : H76217053
Fakultas/Jurusan : SAINS DAN TEKNOLOGI / SISTEM INFORMASI
E-mail address : cistrani3@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Ekslusif atas karya ilmiah :

Sekripsi Tesis Desertasi Lain-lain (.....)
yang berjudul :

PERAMALAN HARGA ETHEREUM MENGGUNAKAN METODE PSO –

BACKPROPAGATION NEURAL NETWORK

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Ekslusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara **fulltext** untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 15 Januari 2022

Penulis

(*Chandra Indira Septiarani*)

ABSTRAK

PERAMALAN HARGA ETHEREUM MENGGUNAKAN METODE PSO-BACKPROPAGATION NEURAL NETWORK

Oleh :

Chandra Indira Septiarani

Perkembangan teknologi yang terus meningkat mempengaruhi berbagai bidang, termasuk bidang finansial. Bidang finansial terus mengalami inovasi , salah satu perkembangan teknologi dalam bidang finansial adalah *cryptocurrency*. Ethereum adalah salah satu *cryptocurrency* yang dapat digunakan untuk investasi, namun berinvestasi ethereum memiliki risiko yang tinggi dikarenakan harganya yang fluktuatif. Salah satu upaya untuk meminimalisir risiko tersebut adalah dengan melakukan peramalan harga ethereum di masa yang akan datang. Penelitian ini bertujuan untuk membuat model peramalan harga ethereum menggunakan metode *Backpropagation neural network* dan *Backpropagation neural network* yang dioptimasi dengan metode particle swarm optimization. Berdasarkan hasil pengujian, *particle swarm optimaztion* mampu untuk membantu metode *Backpropagation neural network* untuk meningkatkan akurasi peramalan harga ethereum. Model peramalan Backpropagation Neural Network menghasilkan MSE = 0,00077550 dan MAPE =31,829610. Sedangkan model peramalan PSO – Backpropagation Neural Network menghasilkan MSE = 0,000132 dan MAPE = 7,5965685. Model peramalan menggunakan PSO – Backpropagation masuk dalam kriteria sangat baik karena mape yang dihasilkan <10%

Kata kunci : ethereum, cryptocurrency, PSO, *Backpropagation Neural network*, peramalan

ABSTRACT

FORECASTING ETHEREUM PRICES USING PSO-BACKPROPAGATION NEURAL NETWORK METHOD

By :

Chandra Indira Septiarani

Technological developments that continue to increase affect various fields, including the financial sector. The financial sector continues to experience innovation, one of the technological developments in the financial sector is cryptocurrency. Ethereum is one of the cryptocurrencies that can be used for investment, but investing in ethereum has a high risk due to its volatile price. One of the efforts to minimize this risk is to forecast the price of Ethereum in the future. This study aims to create an ethereum price forecasting model using the Backpropagation neural network and Backpropagation neural network methods which are optimized by the particle swarm optimization method. Based on the test results, particle swarm optimization is able to help the Backpropagation neural network method to improve the accuracy of ethereum price forecasting. The Backpropagation Neural Network forecasting model produces $MSE = 0.00077550$ and $MAPE = 31.829610$. While the PSO - Backpropagation Neural Network forecasting model produces $MSE = 0.000132$ and $MAPE = 7.5965685$. Forecasting model using PSO – Backpropagation is included in very good criteria because the resulting mape is <10%

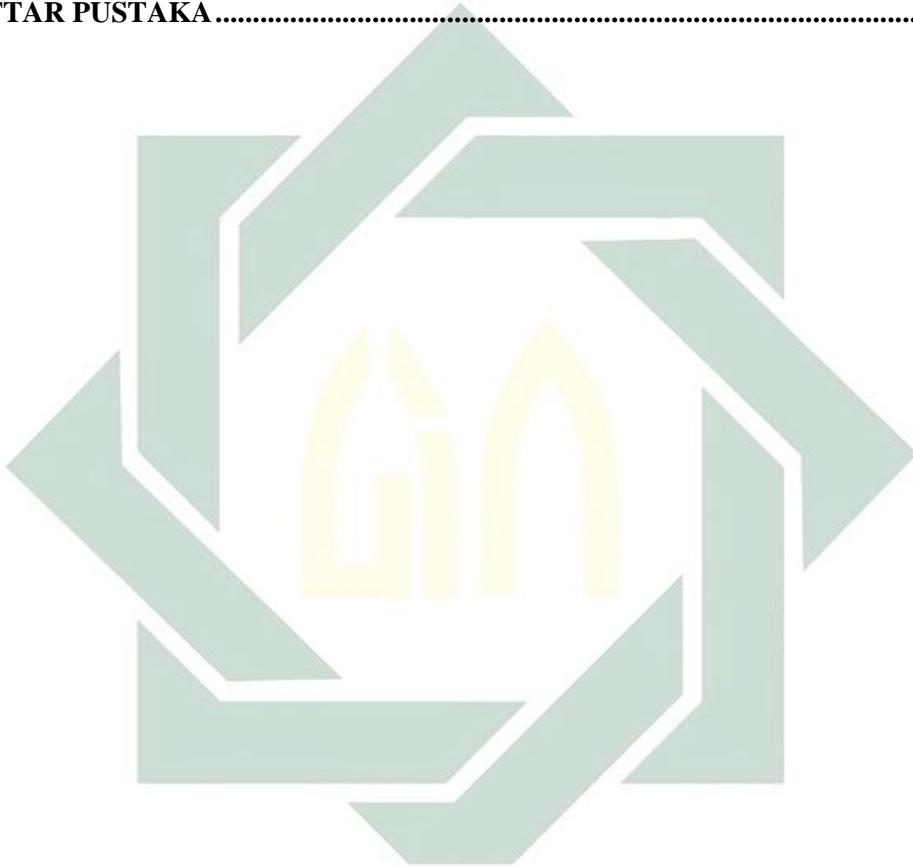
Keywords: *ethereum, cryptocurrency, PSO, Backpropagation Neural network, forecasting*

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN SAMPUL.....	ii
LEMBAR PERSETUJUAN PEMBIMBING.....	iii
LEMBAR PENGESAHAN.....	iv
LEMBAR PERNYATAAN KEASLIAN.....	v
LEMBAR PERSETUJUAN PUBLIKASI.....	vi
ABSTRAK.....	vii
ABSTRACT.....	viii
DAFTAR ISI	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	14
1.1 Latar Belakang	14
1.2 Perumusan Masalah	17
1.3 Batasan Masalah	18
1.4 Tujuan Penelitian	18
1.5 Manfaat Penelitian	18
1.6. Sistematika Penulisan.....	19
BAB II TINJAUAN PUSTAKA	21
2.1 Penelitian Terdahulu	21
2.2 Dasar Teori	24
2.2.1 Cryptocurrency.....	24
2.2.2 Ethereum	25
2.2.3 Data Mining	25
2.2.4 Forecasting	26

2.2.5 Backpropagation Neural network	26
2.2.6 Particle Swarm Optimization (PSO).....	28
2.2.7 Cross Validation.....	29
2.2.8 Python	29
2.2.9 Library.....	29
2.2.10 Evaluasi Model Peramalan	30
2.3 Integrasi Keilmuan	31
BAB III METODOLOGI PENELITIAN.....	33
3.1 Alur Penelitian	33
3.2 Perumusan Masalah	33
3.3 Studi Literatur	34
3.4 Pengumpulan Data	34
3.5 Persiapan data	34
3.6 Optimasi PSO – Backpropagation.....	36
BAB IV HASIL DAN PEMBAHASAN.....	44
4.1 Hasil Pengumpulan Data	44
4.2 Persiapan Data	45
4.2.1 Feature Selection	45
4.2.2 Windowing	46
4.2.3 Normalisasi	46
4.3 Peramalan Menggunakan Metode Backpropagation Neural Network.....	47
4.3.1 Proses Training Backpropagation Neural Network	47
4.3.2 Proses Testing Backpropagation Neural network	50
4.4 Peramalan Menggunakan PSO - BPNN	52
4.4.1 Proses Training PSO - BPNN.....	52
4.4.2 Proses Testing PSO – Backpropagation Neural network.....	55

4.4.3 Perbandingan Hasil Evaluasi Menggunakan Backpropagation Neural network dengan Backpropagation – PSO.....	57
BAB V PENUTUP.....	59
5.1 Kesimpulan	59
5.2 Saran.	60
DAFTAR PUSTAKA	61

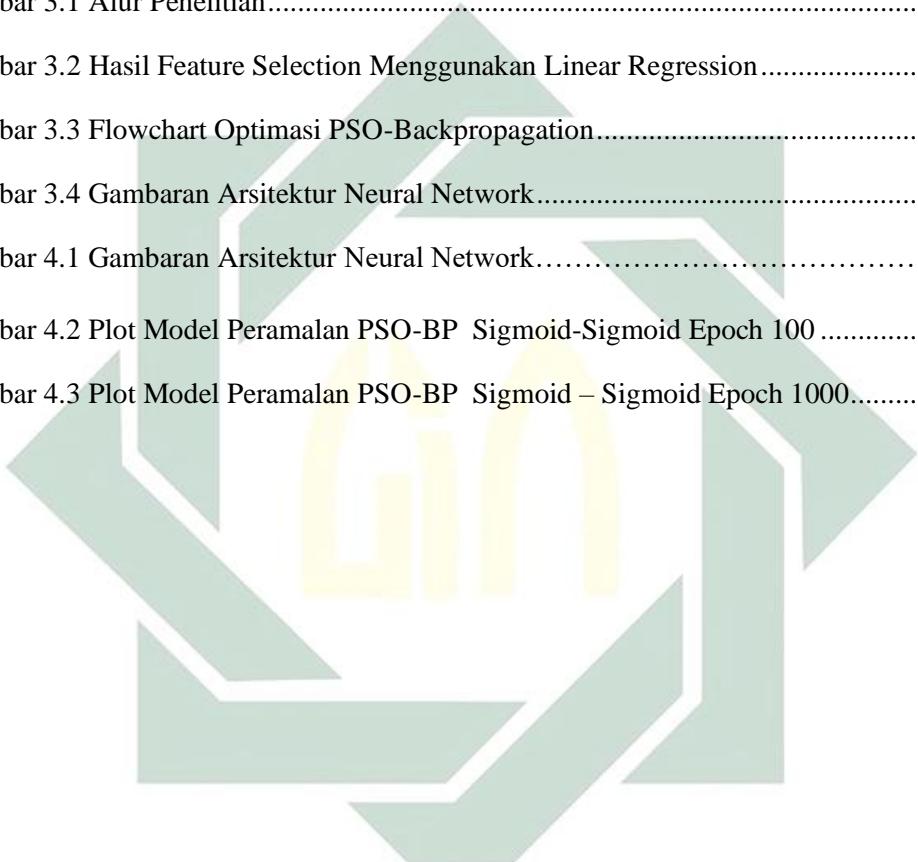


DAFTAR TABEL

Tabel 2.1 Tinjauan Penelitian Terdahulu	21
Tabel 2.2 Tabel Kriteria Nilai MAPE	30
Tabel 3.1 Parameter PSO	37
Tabel 3.2 Parameter Neural network	37
Tabel 3.3 Skenario Peramalan	43
Tabel 4.1 Kutipan Data Harga Ethereum	44
Tabel 4.2 Kutipan Data Harga High (Tertinggi) Ethereum	45
Tabel 4.3 Hasil Windowing	46
Tabel 4.4 Hasil Normalisasi	46
Tabel 4.5 Parameter Neural Network	47
Tabel 4.6 Alur Proses Training Backpropagation	47
Tabel 4.7 Source Code Training Backpropagation.....	49
Tabel 4.8 Source Code Denormalisasi	51
Tabel 4.9 Hasil Evaluasi Training dan Testing Backpropagation Neural Network	51
Tabel 4.10 Alur Training PSO - BPNN.....	52
Tabel 4.11 Parameter yang digunakan untuk training PSO	53
Tabel 4.12 Best Cost	54
Tabel 4.13 Contoh Best Pos	55
Tabel 4.14Alur proses Testing	55
Tabel 4.15 Hasil Evaluasi	56
Tabel 4.16 Perbandingan Hasil Evaluasi.....	57

DAFTAR GAMBAR

Gambar 1.1 Grafik Harga Ethereum Periode 25 Januari 2021 – 21 Juli 2021.....	15
Gambar 2.1 Struktur Jaringan Saraf Tiruan.....	27
Gambar 2.2 Timeseries Split.....	29
Gambar 3.1 Alur Penelitian.....	33
Gambar 3.2 Hasil Feature Selection Menggunakan Linear Regression.....	35
Gambar 3.3 Flowchart Optimasi PSO-Backpropagation.....	36
Gambar 3.4 Gambaran Arsitektur Neural Network.....	38
Gambar 4.1 Gambaran Arsitektur Neural Network.....	45
Gambar 4.2 Plot Model Peramalan PSO-BP Sigmoid-Sigmoid Epoch 100	57
Gambar 4.3 Plot Model Peramalan PSO-BP Sigmoid – Sigmoid Epoch 1000.....	57



BAB I

PENDAHULUAN

1.1 Latar Belakang

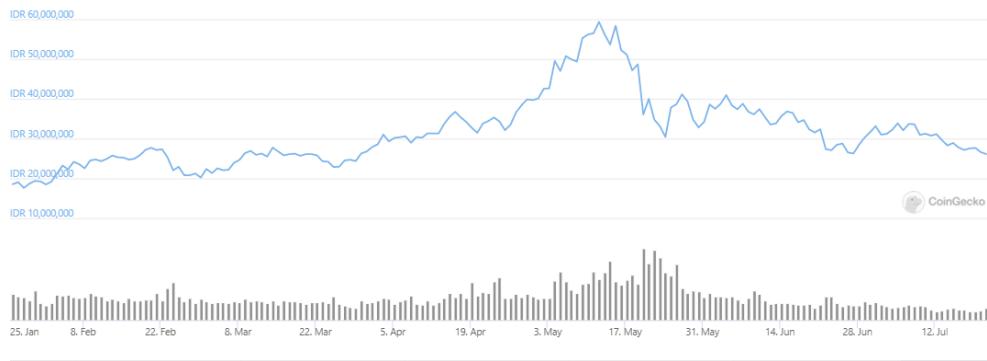
Perkembangan teknologi yang terus meningkat mempengaruhi berbagai bidang, termasuk bidang finansial. Bidang finansial terus mengalami inovasi selama uang dan keuangan masih melayani kehidupan manusia (Sukamulja and Sikora, 2018). Salah satu perkembangan teknologi dalam bidang finansial adalah *cryptocurrency*, yang dimana menawarkan transaksi global, dan transparansi dalam pembayaran (Abad-Segura *et al.*, 2020).

Cryptocurrency adalah penemuan pertama dalam sistem keuangan yang dikembangkan di luar lembaga keuangan, dan bahkan tanpa kerja sama lembaga keuangan (Miciuła and Kazojć, 2019). *Cryptocurrency* mampu mengisi kesenjangan dalam teknologi keuangan saat ini dan dapat membantu memecahkan masalah perbankan tradisional menjadi sistem *peer to peer* (Devries, 2016). Harga *cryptocurrency* sangat fluktuatif dan memiliki karakteristik non-linier (Yang, Sun and Wang, 2020). Saat ini ada ratusan jenis *cryptocurrency* yang masuk di bursa crypto (Islam *et al.*, 2018) dan *cryptocurrency* yang sukses setelah Bitcoin adalah Ethereum (Y. Li *et al.*, 2019).

Ethereum diciptakan oleh Vitalik Buterin dan ethereum dirilis pada tahun 2015 (Vujičić, Jagodić and Randić, 2018). Ethereum adalah *cryptocurrency* terbesar kedua berdasarkan *marketcap*. Ethereum menyediakan lapisan abstrak yang memungkinkan siapa saja membuat aturan mereka sendiri untuk kepemilikan, format transaksi, dan fungsi *state transition*. Hal ini melibatkan *smart contract*, yaitu seperangkat aturan kriptografi yang dijalankan hanya jika kondisi tertentu terpenuhi (Vujičić, Jagodić and Randić, 2018).

Para investor *cryptocurrency* di seluruh dunia telah memanfaatkan pertumbuhan *altcoin* (koin alternatif selain bitcoin) untuk berinvestasi dalam aset alternatif yang bebas dari intervensi langsung pemerintah (Elendner *et al.*, 2017). Salah satu *altcoin* adalah ethereum, menurut (Y. Li *et al.*, 2019) keuntungan berinvestasi ethereum sangat tinggi dan keuntungan yang diperoleh lebih dari 15 kali lebih tinggi dari yang diperoleh dari bitcoin. Ethereum

memiliki harga yang sangat fluktuatif, hal ini dapat dilihat dari grafik yang digambarkan pada gambar 1.1 .



Gambar 1.1 Grafik Harga Ethereum Periode 25 Januari 2021 – 21 Juli 2021

Sumber : <https://www.coingecko.com/en/coins/ethereum/usd>

Meskipun ethereum memiliki nilai yang sangat fluktuatif, permintaan akan ethereum terus meningkat tiap tahunnya. Permintaan akan ethereum dapat diketahui dari *supply* ethereum yang telah beredar. Berdasarkan data www.coingecko.com *supply* ethereum yang telah beredar per 21 Juli 2021 adalah 116.783.016 ETH. Meskipun ethereum berpotensi memiliki keuntungan yang tinggi, investor perlu meminimalisir risiko dalam berinvestasi ethereum dikarenakan harganya yang sangat fluktuatif dengan cara melakukan peramalan harga ethereum.

Peramalan adalah ilmu yang digunakan untuk memprediksi sesuatu atau nilai yang belum terjadi dan bertujuan untuk memprediksi sesuatu yang akan terjadi di masa depan (Maricar, Widiadnyana and Wijaya, 2018). Peramalan penting dilakukan karena prediksi akan kejadian masa depan merupakan *input* (masukan) yang penting ke dalam banyak jenis proses perencanaan dan pengambilan keputusan (Montgomery, Jennings and Kulahci, 2008). Peramalan *cryptocurrency* selain bitcoin untuk diversifikasi portofolio sangat perlu untuk dilakukan (Nakano, Takahashi and Takahashi, 2018). Pada peramalan harga ethereum dimasa yang akan datang, dibutuhkannya metode peramalan yang memiliki keakuratan yang tinggi. Menurut (Khashei and Bijari, 2010) *Neural network* atau jaringan saraf tiruan adalah salah satu model peramalan yang paling akurat. Jaringan saraf tiruan berbeda dengan metode

konvensional, jaringan saraf tiruan adalah metode yang *self-adaptive* berbasis data. Jaringan saraf tiruan dapat mempelajari data yang disajikan, dan dapat menyimpulkan dengan benar meskipun data tidak memiliki pengetahuan ahli. Metode *neural network* selalu dikaitkan dengan data non-linier (Narvekar and Fargose, 2015).

Pada penelitian ini akan menggunakan algoritma *Backpropagation neural network* untuk memprediksi harga ethereum. *Backpropagation* terdiri dari *input layer*, *hidden layer*, dan *output layer* (Radityo, Qorib and Budi, 2017). *Backpropagation* dilatih untuk melakukan tugas tertentu. Selama proses training *output* akan dievaluasi. Jika *output* benar, maka bobot diperkuat. Sedangkan jika *output* salah maka perlu untuk mengganti bobot. *Backpropagation neural network* telah terbukti lebih baik dari pada metode peramalan konvensional ARIMA pada penelitian (Du, 2018), peneliti memprediksi index harga saham *shanghai securities composition*. Metode *neural network* lebih akurat dengan RMSE 65,73 sedangkan RMSE yang didapat dengan metode ARIMA sebesar 89,21. Selanjutnya pada penelitian (Chen and Lai, 2011) peneliti membandingkan metode ARIMA dan *neural network* dalam memprediksi kecepatan angin dengan rentang waktu jangka pendek. ANN lebih unggul dikarenakan dalam beberapa kasus perbedaannya bahkan ANN memiliki 4% MAPE lebih rendah dari ARIMA.

Backpropagation cukup baik pada pemodelan data nonlinier (Verianto and Oetomo, 2021). Namun *Backpropagation* memiliki kelemahan yakni sensitif terhadap bobot dan bias yang acak, mudah terjebak dalam minimum lokal (H. Li *et al.*, 2019). Sehingga dibutuhkannya metode optimasi untuk meningkatkan kinerja dari *Backpropagation neural network*. Banyak sekali metode optimasi swarm intelligence yang mampu mengatasi kelemahan dari *Backpropagation neural network* seperti *genetic algorithm*, *ant colony*, *particle swarm optimization*, *bee colony*. Swarm intelligence adalah disiplin ilmu yang berhubungan dengan sistem alami dan buatan yang terdiri dari banyak individu yang berkoordinasi berdasarkan desentralisasi. Di dalam swarm adanya perilaku kooperatif , strategi pencarian yang lebih baik daripada pencarian acak.

Pada penelitian ini menggunakan salah satu metode swarm intellegence untuk optimasi, yakni *particle swarm optimization* pada *Backpropagation neural network*. Metode PSO (*Particle Swarm Optimization*) adalah metode yang terinspirasi dari sekelompok burung dalam mencari makanan. Setiap partikel mewakili solusi potensial dari masalah, Setiap partikel mencari solusi baru dengan terus menyesuaikan posisinya (Bo *et al.*, 2017). Kelebihan PSO dibandingkan dengan pendekatan lainnya adalah kemudahan dalam implementasi, konsistensi dalam kinerja, mampu mencapai konvergensi yang cepat dalam banyak masalah optimasi yang rumit (Shafiei Chafi and Afrakhte, 2021) . Particle swarm optimization digunakan untuk menghasilkan bobot untuk *Backpropagation neural network*, yang dapat mengatasi kelemahan *Backpropagation neural netwrok* mudah terjebak pada minimum lokal (Bo *et al.*, 2017). Berdasarkan hasil penelitian (H. Li *et al.*, 2019) penggunaan metode PSO pada *Backpropagation* mendapatkan nilai error yang lebih kecil dibandingkan dengan penggunaan *Backpropagation* saja.

Berdasarkan pemaparan sebelumnya penambahan PSO pada *Backpropagation* diharapkan dapat meminimalisir error dan mendapatkan hasil yang optimal pada peramalan harga ethereum. Sehingga penelitian ini bertujuan untuk meramalkan harga etherum menggunakan metode PSO - *Backpropagation Neural network*. Metode PSO - *Backpropagation Neural network* akan dievaluasi dengan melihat nilai MSE dan MAPE dalam meramalkan harga ethereum. Dengan adanya penelitian ini diharapkan metode PSO- *Backpropagation Neural network* dapat meramalkan harga ethereum dengan baik, serta hasil dari peramalan harga ethereum dapat menjadi bahan pertimbangan investor dalam hal membuat keputusan berinvestasi ethereum.

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan sebelumnya, maka dapat dirumuskan beberapa permasalahan yang akan dibahas dalam tugas akhir ini, berikut perumusan masalahnya

1. Bagaimana peramalan harga ethereum menggunakan metode *Backpropagation Neural network*?
 2. Bagaimana peramalan harga ethereum menggunakan metode PSO-*Backpropagation Neural network*?
 3. Bagaimana hasil perbandingan metode *Backpropagation Neural network* dan PSO-*Backpropagation Neural network* dalam meramalkan harga ethereum?

1.3 Batasan Masalah

Adapun beberapa batasan masalah pada penelitian tugas akhir ini antara lain:

1. *Dataset* yang digunakan adalah dataset harga ethereum dengan satuan rupiah yang diambil dari situs www.investing.com
 2. Penelitian ini meramalkan harga ethereum menggunakan data waktu harian.
 3. Data harga ethereum yang digunakan adalah data yang dimulai dari bulan 14 Januari 2018 – 21 Juli 2021
 4. Menggunakan bahasa pemrograman python
 5. Peramalan harga ethereum yang dilakukan tidak memiliki korelasi dengan efek geopolitik cina

1.4 Tujuan Penelitian

1. Untuk mendapatkan hasil peramalan harga ethereum menggunakan metode *Backpropagation Neural network*
 2. Untuk mendapatkan hasil peramalan harga ethereum menggunakan metode *PSO-Backpropagation Neural network*
 3. Untuk membandingkan metode *Backpropagation Neural network* dengan metode *PSO-Backpropagation Neural network* dalam meramalkan harga ethereum

1.5 Manfaat Penelitian

Manfaat penelitian dibagi menjadi beberapa berikut:

- ## 1. Manfaat Akademik

- a. Memanfaatkan metode PSO dan Backpropagation Neural Network untuk meramalkan harga ethereum
 - b. Memberikan hasil peramalan untuk rekomendasi berdasarkan hasil pengolahan data
 - c. Sebagai referensi dari penelitian yang nantinya dapat dipelajari oleh pembaca
 - d. Menambahkan wawasan dan pengetahuan khususnya dalam peramalan harga ethereum.

2. Manfaat Praktis

Diharapkan peramalan harga ethereum dapat memberikan manfaat untuk para investor dalam mengambil keputusan berinvestasi ethereum dan penelitian ini ikut berkontribusi dalam mengembangkan metode PSO Backpropagation Neural Network.

1.6. Sistematika Penulisan

Pada penulisan tugas akhir terdapat aturan penulisan serta penulisan harus secara sistematis melalui susunan berikut.

a. BAB 1 PENDAHULUAN

Pada bab 1 peneliti menjelaskan latar belakang , rumusan masalah, tujuan penelitian, batasan penelitian, manfaat yang diperoleh dari penelitian dan akademis serta penerapan sistematika penyusunan tugas akhir.

b. BAB 2 TINJAUAN PUSTAKA

Pada bab 2 peneliti menjelaskan secara singkat tentang teori-teori yang terkait dengan penelitian ini, seperti konsep peramalan, metode metode PSO, *Backpropagation*, teori pendukung, dan integrasi keilmuan antara nilai nilai keislaman berdasarkan Al-Quran yang berkaitan dengan penelitian tugas akhir ini.

c. BAB 3 METODOLOGI PENELITIAN

Pada bab 3 peneliti menjelaskan alur penelitian menggunakan flowchart yang terdiri dari beberapa tahap antara lain yaitu identifikasi masalah, studi

literatur, pengumpulan data, persiapan data, tahap peramalan dengan metode metode BPNN, tahap peramalan dengan metode PSO-BPNN, dan evaluasi.

d. BAB 4 HASIL DAN PEMBAHASAN

Pada bab 4 peneliti menjelaskan hasil – hasil dari semua tahapan penelitian yang telah dilakukan, mulai dari tahap persiapan data, hasil peramalan, hasil uji, dan hasil evaluasi peramalan.

e. BAB 5 PENUTUP

Pada bab 5 peneliti menjelaskan kesimpulan serta saran pengembangan. Kesimpulan berisi hasil pemaparan secara singkat pada masalah penelitian. Sedangkan saran pengembangan adalah pernyataan peneliti untuk melakukan sesuatu pada hal yang belum dapat ditempuh yang dapat dikembangkan oleh penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Pada proses penelitian ini penulis membutuhkan beberapa penelitian terdahulu. Terdapat beberapa penelitian terdahulu yang memiliki metode dan topik yang selaras yang digunakan sebagai acuan oleh penulis untuk mendapatkan pemahaman dan referensi penggunaan metode dan informasi baru. Sehingga penulis memperoleh inspirasi baru dalam melakukan penelitian. Beberapa penelitian terdahulu yang memiliki keterkaitan dengan penelitian yang akan dilakukan ditunjukkan pada Tabel 2.1 sebagai berikut.

Tabel 2.1 Tinjauan Penelitian Terdahulu

No	Peneliti & Tahun	Judul	Hasil	Korelasi Penelitian
1.	(Du, 2018)	Application and Analysis of <i>Forecasting Stock Price Index Based on Combination of ARIMA Model and BP Neural network</i>	Peneliti memprediksi saham Shanghai Securities Composition hasil yang didapat adalah metode <i>Backpropagation</i> lebih unggul dalam memprediksi dengan RMSE = 65,73 . Sedangkan metode ARIMA menghasilkan RMSE lebih banyak yaitu 89,21.	Metode <i>Backpropagation neural network</i> dapat mengatasi data non-linier dan <i>time series</i>
2.	(Chen and Lai, 2011)	Comparison Between ARIMA and ANN models Used in Short-term Wind Speed Forecasting	Peneliti memprediksi kecepatan angin per satu jam sampai empat jam kedepan menggunakan metode ARIMA dan ANN. Hasil yang diperoleh adalah metode ARIMA dan ANN dapat digunakan dalam memprediksi kecepatan angin. Namun peneliti merekomendasikan metode ANN	Jaringan saraf tiruan terdiri dari banyak unit pemrosesan yang saling terhubung. Setiap koneksi ke neuron memiliki bobot. Bobot disesuaikan selama training untuk mencapai hubungan <i>input / output</i> jaringan yang diinginkan.

			digunakan untuk memprediksi kecepatan angin, karena metode ANN menghasilkan MAPE 4% lebih rendah dari pada ARIMA	
3.	(Wartati and Masruroh, 2017)	Aplikasi Jaringan Saraf Tiruan dan Particle Swarm Optimization Untuk Peramalan Indeks Harga Saham Bursa Efek Indonesia	Peneliti menggunakan PSO untuk mengoptimalkan kinerja algoritma <i>Backpropagation</i> . Hasil peramalan dengan menggunakan metode PSOBPNN lebih baik dari pada menggunakan algoritma <i>Backpropagation</i> saja. PSOBPNN menghasilkan MSE pada proses training dan testing lebih kecil yaitu 0,0030 dan 0,0062. Sedangkan jika menggunakan algoritma BPNN hasil MSE pada proses training dan testing yaitu 0,0031 dan 0,0131.	PSO dapat digunakan untuk mengoptimalkan <i>Backpropagation</i> dalam peramalan <i>time series</i>
4.	(Bo <i>et al.</i> , 2017)	Hybrid PSO-BP Neural network Approach for Wind Power Forecasting	Peneliti memprediksi tenaga angin dengan skala 6 jam, 1 hari, dan 3 hari menggunakan PSO-BP. Peneliti juga membandingkan PSO-BP dengan <i>Backpropagation</i> , GA-BP, dan wavelet-BP. Berdasarkan hasil pengujian, metode PSO-BP lebih unggul dalam meramalkan tenaga angin untuk semua skala dengan RMSE terkecil yang dihasilkan sebesar 16.86% pada skala waktu 6 jam.	PSO pada <i>Backpropagation</i> digunakan untuk mendapatkan bobot dan bias yang optimal.
5.	(Guo <i>et al.</i> , 2020)	Short-Term Photovoltaic Power	Peneliti memprediksi daya fotovoltaik menggunakan metode	Penentuan dimensi dari PSO ditentukan oleh struktur

		Forecasting on PSO-BP Neural network	PSO-BP dan Backpropagation saja. Hasil pada penelitian PSO-BP jauh lebih baik dalam memprediksi daya fotovoltaik dengan MAPE yang jauh lebih kecil diandingkan dengan metode Backpropagation saja.	masalah target, yang mewakili jumlah fitur dalam masalah (bobot pada neural network) yang akan dioptimalkan.
6.	(Shafiei Chafi and Afrakhte, 2021)	Short-tem Load Forecasting Using Neural network and PSO Algorithm	Peneliti memprediksi muatan listrik untuk jangka pendek menggunakan metode PSO – Backpropagation. Hasil evaluasi prediksi MAPE = 0.03388, MSE = 1. 26268e–003 MAE = 0.02191	Jumlah layer yang digunakan untuk neural network berbeda, pada penelitian ini menggunakan 4 layer untuk neural network yang terdiri atas satu input layer, dua hidden layer, dan satu output layer
7.	(Wu et al., 2018)	Optimized BP Neural network for Dissolved Oxygen Prediction	Peneliti memprediksi kualitas air menggunakan 4 macam metode yaitu Backpropagation, PSO-Backpropagation, Sliding window – Backpropagation, Sliding window – BP PSO. Hasil penelitian menunjukkan prediksi menggunakan kombinasi metode Sliding Window – BP PSO menghasilkan akurasi tertinggi dengan MSE = 0,437 , MAE = 0,251	Melakukan windowing atau sliding window pada data sebelum melakukan training data dapat meningkatkan akurasi pada prediksi.

Dari beberapa penelitian terdahulu yang telah disajikan pada tabel 2.1 , maka dapat disimpulkan metode *Backpropagation neural network* banyak digunakan dalam peramalan *timeseries*. Penggunaan metode tambahan particle swarm optimization dapat membantu kinerja metode *Backpropagation neural network*. Pada penelitian terdahulu yang mengimplementasikan PSO-*Backpropagation*

neural network menghasilkan peramalan yang optimal. Hasil evaluasi yang dihasilkan lebih kecil dibandingkan dengan metode lainnya dan metode *Backpropagation* dapat melakukan proses training lebih cepat. Sehingga penulis tertarik melakukan penelitian dengan menggabungkan antara latar belakang masalah yang dihadapi diatas dengan metode PSO dan *Backpropagation neural network*, lalu penulis akan mengevaluasi metode PSO-*Backpropagation neural network* dalam meramalkan harga ethereum.

2.2 Dasar Teori

2.2.1 Cryptocurrency

Cryptocurrency adalah variasi modern dari uang elektronik dan virtual yang saat ini sebagian besar bergantung pada internet bahkan keberadaannya tanpa internet juga memungkinkan (Sichinava, 2019). *Cryptocurrency* adalah sistem pertukaran digital *peer to peer* dimana menggunakan teknologi kriptografi untuk menghasilkan dan mendistribusikan unit mata uang (Farell, 2015). Proses transaksi pada *cryptocurrency* membutuhkan verifikasi transaksi terdistribusi tanpa adanya otoritas pusat atau bank sentral. Pada proses verifikasi transaksi mengkonfirmasi jumlah transaksi, dan mengkonfirmasi apakah pembayar memiliki mata uang yang akan dibelanjakan sambil memastikan bahwa unit mata uang tidak dibelanjakan dua kali (Mukhopadhyay *et al.*, 2016).

Menurut (Nian et al., 2015, p. 10) minat masyarakat terhadap *cryptocurrency* semakin meningkat. Sejak tahun 1971 mengadopsi sistem mata uang fiat, bank sentral menggunakan kebijakan untuk mencetak uang sebanyak yang mereka inginkan selama krisis. Hal ini dapat menciptakan lingkungan inflasi aset dan memperburuk kesetaraan pendapatan. Sedangkan *cryptocurrency* memiliki pasokan yang mungkin atau mungkin tidak dibatasi, tetapi koin baru biasanya dibuat dengan aturan yang telah ditentukan oleh pencipta koin sebelumnya. Hilangnya kepercayaan pada sistem mata uang fiat, terutama disebabkan oleh pelonggaran kuantitatif dan hutang pemerintah yang besar, menarik perhatian pada *cryptocurrency* bagi masyarakat yang ingin melindungi posisi mereka dengan *cryptocurrency* yang memiliki pasokan terbatas.

2.2.2 Ethereum

Ethereum diciptakan oleh Vitalik Buterin dirilis pada tahun 2015. Ethereum (ether) menjadi *cryptocurrency* terbesar kedua setelah bitcoin berdasarkan marketcap (Vujičić, Jagodić and Randić, 2018). Seperti bitcoin, ethereum menggunakan blockchain dimana blok berisi salinan daftar transaksi dan status terbaru. Ethereum memiliki kemampuan menyimpan data, mendukung keputusan dan mengotomatiskan distribusi nilai yang dikelola dengan *smart contract* (Fairley, 2019). *Smart contract* (kontrak pintar) adalah program komputer yang secara langsung mengontrol aset digital. Kontrak memiliki alamatnya sendiri, sehingga dapat berfungsi sebagai pemilik aset digital. Pada kontrak hanya pelaksana kode kontrak yang dapat mengirim aset ke pihak lain dan setiap pihak yang melihat dan dapat memverifikasi blockchain mengetahui bahwa aset berada di bawah kontrol program (Buterin, 2016).

Transaksi pada Ethereum menentukan informasi yang dibutuhkan seperti alamat tujuan, jumlah ether untuk ditransaksikan dan data yang berisi informasi seperti alamat pengirim yang tersirat dalam tanda tangan dan tidak ditentukan secara eksplisit. Terdapat dua jenis transaksi pada ethereum yaitu EOA (*Externally Owned Account*) dan *Contract Account*. Jika transaksi dikirim ke EOA maka hanya berfungsi sebagai transfer ether. Namun, jika transaksi dikirim ke *contract account*, maka kode kontrak berjalan. Kode kontrak memiliki kemampuan untuk membaca data transaksi, membaca jumlah ether yang dikirim dalam transaksi, membaca dan menulis ke penyimpanan kontrak, membaca environment variabel (seperti: *timestamp*, kesulitan blok, dan blok sebelumnya) dan mengirim transaksi internal ke kontrak lain (Fairley, 2019).

2.2.3 Data Mining

Jumlah data di dunia dalam kehidupan terus mengalami peningkatan. Data yang besar dapat diolah menjadi informasi yang berguna. Bidang yang menemukan informasi baru dan berpotensi berguna dari sejumlah data yang besar disebut *data mining* (Baker, 2011) Pada *data mining* data disimpan secara elektronik dan pencarian dilakukan secara otomatis. *Data mining* adalah tentang memecahkan

masalah dengan menganalisis data yang sudah ada dalam *database* (Witten, Frank, & Hall, 2011, p. 5). Data mining modern menggabungkan statistik dengan ide, alat, dan metode dari ilmu komputer, pembelajaran mesin, teknologi database, dan teknologi analitik data klasik lainnya (Hand, 2007) .

2.2.4 Forecasting

Forecasting atau peramalan melibatkan prediksi masa depan berdasarkan analisis tren data sekarang dan masa lalu, yang terdiri dari tiga komponen utama: variabel *input* (data masa lalu dan sekarang), metode peramalan / estimasi (analisis tren) dan variabel *output* (prediksi masa depan) (Debnath and Mourshed, 2018). Metode peramalan (*forecasting*) menganalisis variabel yang akan diperkirakan dengan variabel waktu. Data yang digunakan pada metode *forecasting* adalah data deret waktu (*timeseries*) (Junaidi, 2014).

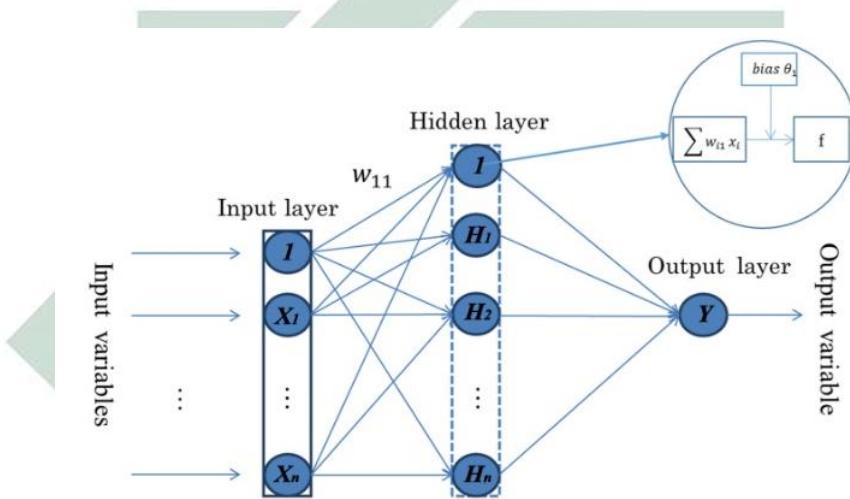
Timeseries forecasting memainkan peran penting dalam berbagai domain seperti, speech analysis, noise cancelation, dan financial market analysis (Liu *et al.*, 2016). Menurut (Larose and Larose, 2014) Prediksi serupa dengan klasifikasi dan estimasi namun prediksi memberikan hasil tentang masa depan. Setiap metode dan teknik yang digunakan untuk klasifikasi dan estimasi juga dapat digunakan dalam keadaan yang tepat untuk prediksi. Prediksi memiliki atribut dan label berupa numerik.

2.2.5 Backpropagation Neural Network

Neural network yang sangat efektif untuk mengumpulkan, menganalisis, dan memprediksi data yang telah digunakan untuk memecahkan sejumlah masalah yang kompleks (Vrbka and Rowland, 2017). Jaringan saraf tiruan terdiri dari unit pemrosesan yang disebut neuron. Jaringan saraf tiruan mencoba meniru struktur dan perilaku neuron alami. Sebuah neuron terdiri dari *input* (dendrit), dan satu *output* (sinapsis melalui akson) serta neuron memiliki fungsi yang menentukan aktivasi neuron (Sadaei *et al.*, 2016)

Struktur jaringan saraf tiruan (gambar 2.1) yang terdiri dari beberapa layer yaitu *input layer*, *hidden layer*, *output layer* (Wagena *et al.*, 2020). Jaringan saraf

tiruan terdiri dari node atau unit yang terhubung dengan tautan terarah. Pada setiap tautan memiliki bobot (w). Algoritma *Backpropagation* adalah algoritma learning yang paling luas diterapkan pada jaringan saraf. Cara kerjanya dengan menentukan bobot dan bias untuk proses data training. Bobot dan bias pada jaringan diberikan nilai awal terlebih dahulu, dan error antara nilai *output* yang diprediksi dan nilai *output* aktual disebarlu kembali melalui jaringan untuk memperbarui bobot dan bias berulang kali. Ketika kriteria terpenuhi, training dianggap selesai dan nilai bobot serta bias disimpan (Qiu and Song, 2016).



Gambar 2.1 Struktur Jaringan Saraf Tiruan

Sumber : (Qiu and Song, 2016)

Keterangan:

X_n = Variabel *input* / Jumlah variabel indepen

Hn = Jumlah hidden node

$$W_{11} = \text{bobot}$$

bias = *threshold*

Y= Variabel output / variabel dependen

Pada bagian *hidden layer* terdapat fungsi aktivasi atau fungsi sigmoid. Fungsi ini digunakan pada jaringan saraf tiruan untuk menghasilkan nilai *output*

pada interval 0 sampai 1. Fungsi sigmoid dirumuskan menggunakan persamaan 2.1 berikut (Najwa, Warsito and Ispriyanti, 2017)

$$y = f(x) \frac{1}{1+e^{-\sigma x}} \quad (2.1)$$

Dimana (Kukreja and Bharath N, 2016) :

$$-\sigma x = \sum_{i=0}^n X_i W_i$$

X_i = Variabel Input

$$W_i = \text{Bobot}$$

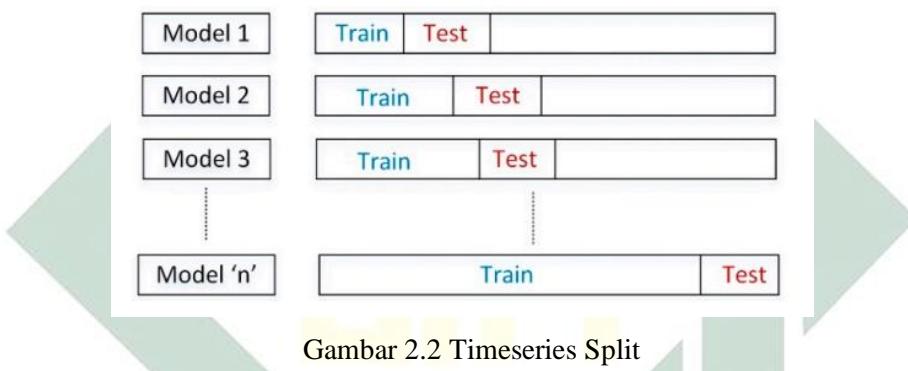
2.2.6 Particle Swarm Optimization (PSO)

Particle swarm optimization diciptakan oleh James Kennedy dan Russel C. Eberhart. Algoritma ini terinspirasi dari pengamatan perilaku sosial dari kawanan burung dalam mencari makanan. Dimana perilaku burung dipengaruhi oleh pengalamannya sendiri dan anggota kawanannya (Garro, Sossa and Vázquez, 2011). *Particle swarm optimization* memiliki kumpulan solusi potensial yang dikenal sebagai *swarm* dan setiap solusi potensial disebut dengan partikel (Bansal, 2019). Kumpulan partikel bergerak dalam ruang untuk mencari posisi yang tepat, posisi tersebut akan diinformasikan ke partikel lain dan setiap partikel akan menyesuaikan posisi dan kecepatan untuk mencapai tujuannya (Verianto and Oetomo, 2021).

Pada PSO pencarian dipengaruhi oleh dua jenis pembelajaran. Setiap partikel belajar dari partikel lain dan juga belajar dari pengalaman pergerakan yang telah dilewati oleh partikel itu sendiri. Pembelajaran partikel menyimpan memori solusi terbaik yang dilalui oleh setiap partikel kawanannya disebut *gbest*. Sedangkan pembelajaran dari partikel menyimpan memori solusi terbaik yang pernah dikunjunginya sendiri disebut *pbest* (Bansal, 2019). Pada setiap iterasi pencarian solusi, setiap partikel akan memperbarui posisi menggunakan informasi dari *pbest* dan *gbest*. Sehingga semua partikel akan dapat mencapai solusi yang optimal. Pada PSO untuk melakukan optimasi dilakukannya penambahan bobot atribut terhadap semua atribut yang digunakan (Salman, Lawi and Syarif, 2018).

2.2.7 Cross Validation

Cross Validation adalah teknik validasi dengan membagi data. Jika pada konvesional crossvalidation data dibagi secara acak menjadi k -bagian. Satu bagian digunakan sebagai data testing sedangkan bagian lainnya digunakan sebagai data training (Wang and Zhao, 2016). Namun untuk data timeseries jenis cross validation yang digunakan berbeda. Jenis crossvalidation yang digunakan adalah timeseries split. Timeseries split(gambar 2.2) adalah sebuah varian pembagian dari k -fold yang digunakan untuk membagi data timeseries. Pada setiap pengujian , indeks data test harus lebih tinggi dari sebelumnya. Pada timeseries split tidak ada pengambilan data secara acak (Bouktif *et al.*, 2019).



Gambar 2.2 Timeseries Split

2.2.8 Python

Python adalah bahasa pemrograman yang diciptakan oleh Guido Van Rossum. Python dirancang untuk *readable* dan *reusable*. Keseragaman kode pada python membuatnya mudah untuk dipahami. Python hadir dengan banyak koleksi fungsionalitas bawaan dan portabel, yang biasa dikenal sebagai standard *library*. Salah satu library pada python adalah Numpy yang digunakan untuk pemrograman numerik (Mark Lutz, 2008). Maka dari itu bahasa pemrograman untuk mengimplementasikan metode *Neural network* untuk meramalkan harga ethereum adalah python.

2.2.9 Library

Library yang digunakan untuk penelitian ini adalah keras dan pyswarm. Library Keras adalah library untuk *neural network* yang bersifat open source yang dirancang untuk mudah digunakan dan cepat. Library ini dikembangkan oleh

Francois Chollet, seorang Engineer Google. Sedangkan library PySwarm adalah library untuk mengimplementasikan particle swarm optimization.

2.2.10 Evaluasi Model Peramalan

Terdapat tiga macam pengukuran kesalahan (error) pada peramalan. Yaitu MSE (Mean Square Error), dan MAPE (Mean Absolute Presentase Error). Penggunaan ukuran ini mewakili sudut yang berbeda untuk mengevaluasi model peramalan. RMSE adalah ukuran kinerja absoult, sedangkan MAPE adalah ukuran relatif (Zhang and Qi, 2005).

a. Mean Square Error

Untuk mendapatkan nilai MSE melalui perhitungan selisih antara nilai aktual dengan nilai peramalan yang dikuadratkan, kemudian dibagi dengan banyaknya jumlah deret waktu pada peramalan. (Nugraha and Suletra, 2017). Menghitung MSE menggunakan persamaan 2.2 sebagai berikut

$$MSE = \sum \frac{(Aktual - Prediksi)^2}{n} \quad (2.2)$$

b. Mean Absolute Percentage Error

Nilai MAPE berfungsi untuk mengetahui sejauh mana bias pada metode peramalan yang digunakan (Nugraha and Suletra, 2017). Semakin kecil nilai MAPE maka akan semakin akurat hasil peramalan (Habibi and Riksakomara, 2017). Nilai MAPE dihitung menggunakan persamaan 2.4

$$MAPE = \sum \frac{\left| \frac{Prediksi - Aktual}{Aktual} \right|}{n} X 100 \quad (2.4)$$

Interpretasi nilai MAPE di tuliskan pada tabel 2.2

Tabel 2.2 Tabel Kriteria Nilai MAPE

Nilai MAPE	Interpretasi
<10%	Sangat baik
10% - 20%	Baik

20% - 50%	Cukup
>50%	Tidak akurat

2.3 Integrasi Keilmuan

Berinvestasi adalah menyisihkan sebagian dana yang dimiliki untuk menambah nilai guna dari dana yang disisihkan. Dengan berinvestasi investor mendapatkan keuntungan dalam jangka waktu tertentu. Didapatkannya integrasi keilmuan tentang investasi berdasarkan aspek agama. Integrasi keilmuan tersebut tertuang pada QS. Yusuf ayat 47 – 49 :

قَالَ تَزَرَّعُونَ سَبْعَ سِنِينَ دَأْبًا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُبْلِهِ إِلَّا قَلِيلًا مِمَّا تَأْكُلُونَ - ٧٤

ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَا كُلُّنَّ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِمَّا تُحْسِنُونَ - ٨٤

شُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ عَامٌ فِيهِ يُغَاثُ النَّاسُ وَفِيهِ يَعْصِرُونَ - ٤٩

Artj:

Dia (Yusuf) berkata, "Agar kamu bercocok tanam tujuh tahun (berturut-turut) sebagaimana biasa; kemudian apa yang kamu tuai hendaklah kamu biarkan di tangkainya kecuali sedikit untuk kamu makan. Kemudian setelah itu akan datang tujuh (tahun) yang sangat sulit, yang menghabiskan apa yang kamu simpan untuk menghadapinya (tahun sulit), kecuali sedikit dari apa (bibit gandum) yang kamu simpan. Setelah itu akan datang tahun, di mana manusia diberi hujan (dengan cukup) dan pada masa itu mereka memeras (anggur)."

Ayat diatas memberikan pelajaran bahwa manusia tidak dapat mengetahui apa yang akan terjadi di masa depan, maka dari itu manusia perlu berantisipasi jika ada sesuatu yang tidak diinginkan, sehingga investasi adalah jalan terbaik untuk menangani hal tersebut. Pada ayat tersebut dijelaskan bahwa nabi Yusuf as.

berinvestasi selama tujuh tahun lamanya untuk menghadapi masa sulit yang akan datang. Begitu pula manusia biasa yang tidak mengetahui sesuatu yang akan datang di masa depan. Sehingga kita perlu berinvestasi agar tetap tercukupi dan sejahtera saat menghadapi masa depan dengan hal yang baik seperti yang dicontohkan oleh nabi Yusuf as. Menurut Ibu Wiwin Luqna Hunaida, M.Pd.I, sebagai dosen Pendidikan Agama Islam UIN Sunan Ampel Surabaya, penelitian ini lebih cocok diintegrasikan dengan QS. An Nisa ayat 29 yang berhubungan dengan transaksi atau jual beli Ethereum.

QS An Nisa ayat 29 berisi penjelasan mengenai transaksi , yang berbunyi :

يَأَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَ كُمْ
بِالْبَطِلِ إِلَّا أَنْ تَكُونَ تِحْكَرَةً عَنْ تَرَاضٍ مِّنْكُمْ وَلَا نُقْتَلُو
أَنفُسَكُمْ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

Artinya :

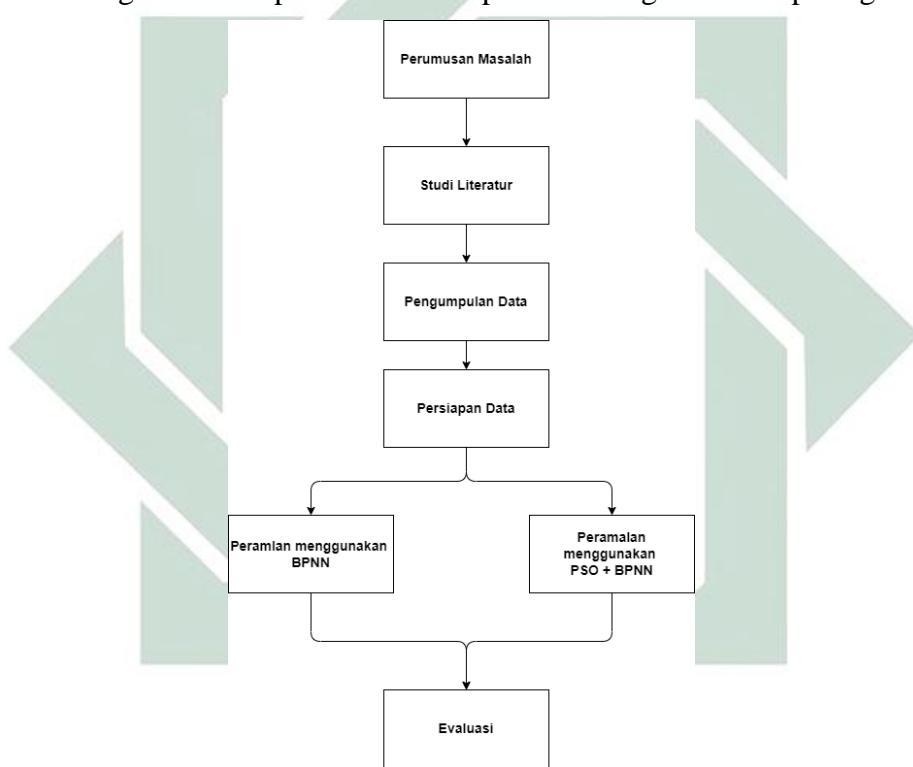
“Wahai orang-orang yang beriman! Janganlah kamu saling memakan harta sesamamu dengan jalan yang batil (tidak benar), kecuali dalam perdagangan yang berlaku atas dasar suka sama suka di antara kamu. Dan janganlah kamu membunuh dirimu. Sungguh, Allah Maha Penyayang kepadamu.”

QS An-Nisa ayat 29 memberikan pelajaran bahwa adanya larangan mencari harta dengan memakan harta orang lain atau mencari harta untuk diri sendiri dengan jalan yang salah. Kita sebagai umat muslim yang beriman kepada Allah dan RasulNya harus melaksanakan syariatnya dalam mencari harta yang halal. Ethereum adalah salah satu *cryptocurrency* yang halal berdasarkan data www.islamicfinanceguru.com dimana digunakan sebagai aset digital sebagai pengganti mata uang fiat yang dapat digunakan bertransaksi. Sedangkan menurut fatwa MUI hukum *cryptocurrency* apabila digunakan sebagai komoditi atau aset yang memenuhi sil'ah dan memiliki underlying serta memiliki manfaat yang jelas hukumnya sah untuk diperjualbelikan.

BAB III

3.1 Alur Penelitian

Jenis penelitian ini adalah penelitian kuantitatif, karena penelitian ini dilakukan berdasarkan data angka. Pada alur penelitian, peneliti menjelaskan langkah – langkah dalam penelitian. Alur penelitian digambarkan pada gambar 3.1



Gambar 3.1 Alur Penelitian

3.2 Perumusan Masalah

Perumusan masalah akan menjadi dasar pada penelitian ini. Masalah yang diangkat pada penelitian ini seperti yang tertera dalam latar belakang, yaitu mengenai peramalan harga ethereum. Peramalan bertujuan untuk memprediksi harga ethereum. Penelitian ini menggunakan metode peramalan PSO dan *Backpropagation Neural network* yang dimana hasilnya akan dievaluasi untuk diuji keakuratannya dalam meramalkan harga ethereum.

3.3 Studi Literatur

Pada tahap studi literatur dilakukannya pembelajaran untuk memahami konsep dengan membaca berbagai macam referensi pada jurnal, buku elektronik dan artikel internet terkait dengan penggunaan PSO dan *Backpropagation Neural network* untuk peramalan. Tahap studi literatur bertujuan untuk mendapatkan metode wawasan lebih luas tentang dasar – dasar teori yang berkaitan dengan permasalahan penelitian serta memberikan pemahaman dalam menggunakan metode mana yang tepat untuk diterapkan dalam penelitian ini.

3.4 Pengumpulan Data

Pada tahap pengumpulan data, peneliti menggunakan dataset harian ETH/IDR yang diunduh pada situs penyedia dataset *cryptocurrency* yaitu www.investing.com dengan rentang waktu 14 Januari 2018 – 21 Juli 2021. Dataset yang telah diunduh memiliki 1285 data.

1. *Date*, atribut ini berisi tanggal, bulan dan tahun
 2. *Open*, atribut ini berisi data harga pembukaan ETH dalam periode yang sama.
 3. *Price*, atribut ini berisi data harga penutupan ETH dalam periode yang sama.
 4. *High*, atribut ini berisi data harga tertinggi ETH dalam periode yang sama.
 5. *Low*, atribut ini berisi data harga terendah ETH dalam periode yang sama .
 6. *Vol*, atribut ini berisi data jumlah koin yang diperdagangkan (trading) dalam periode yang sama.
 7. *Change*, atribut ini berisi data persentase perubahan harga koin dalam periode yang sama.

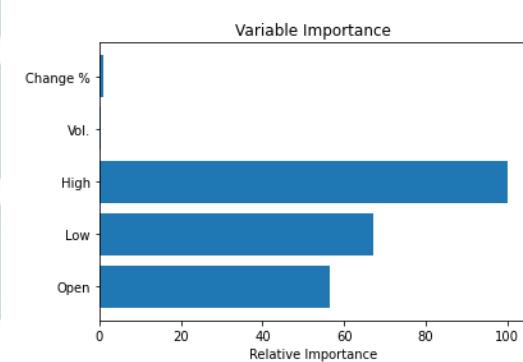
3.5 Persiapan data

1. Feature Selection

Pada penelitian peramalan harga ethereum terdapat banyak variabel yang mempengaruhi harga ethereum. Variabel-variabel tersebut mungkin

berkorelasi satu sama lain dan memiliki pengaruh yang berbeda terhadap hasil. Maka dari itu dibutuhkannya *feature selection* yang berfungsi untuk memfilter fitur (variabel) yang tidak relevan (Hsu, 2011). *Feature selection* memainkan peran penting dalam keakuratan dan efisiensi peramalan (Grigoryan, 2015). Metode yang digunakan untuk *feature selection* adalah *linear regression*.

Linear regression didefinisikan sebagai hubungan antara variabel bebas dan variabel terikat. Variabel bebas dianggap sebagai nilai *input* dan variabel terikat dianggap sebagai nilai *output*. Pada metode *linear regression* variabel – variabel menggunakan data numerik (Sathish Kumar and Raaza, 2018). Gambar 3.2 menunjukkan hasil feature selection menggunakan linear regression. Hasil yang didapatkan adalah variabel *high* memiliki nilai relative importance tertinggi sehingga variabel *high* akan digunakan sebagai *input* dalam penelitian ini



Gambar 3.2 Hasil Feature Selection Menggunakan Linear Regression

2. Windowing

Setelah melakukan *feature selection* akan didapatkan variabel yang sangat relevan yaitu *high*. Kemudian data yang telah melalui proses *feature selection* akan dilakukan *windowing*. *Windowing* adalah perkiraan sementara atas nilai sebenarnya dari data *timeseries* (Hota, Handa and Shrivastava, 2017). Variabel *input* pada windowing berasal dari data periode sebelumnya (Kotu and Deshpande, 2019). Pada tahap *windowing* digunakan 5 data *input* dan 1 *output*. Dimana data *input* diambil dari data variabel *high*

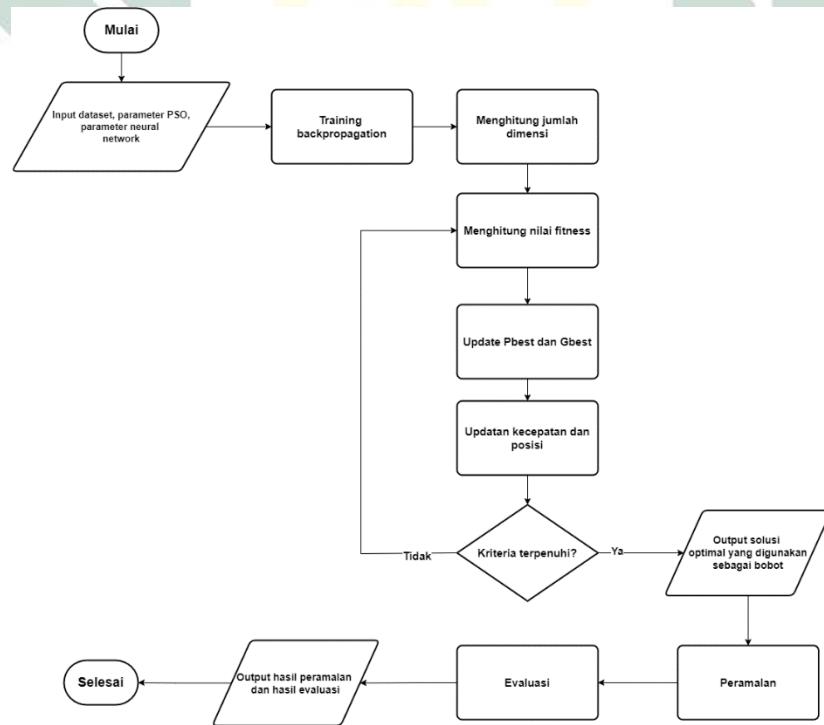
5 hari sebelumnya dan *windowing* akan mengubah variabel terakhir pada window menjadi label atau variabel target (Meesad and Rasel, 2013).

3. Normalisasi data

Sebelum melakukan training perlu dilakukannya normalisasi, karena *neural network* (jaringan saraf tiruan) mempunyai fungsi aktifasi sigmoid yang memiliki *output* pada range nilai 0 – 1, dan juga normalisasi digunakan untuk menghindari adanya dominasi variabel yang memiliki nilai besar terhadap variabel yang memiliki nilai kecil (Nugraha and Azhari, 2014).

3.6 Optimasi PSO – *Backpropagation*

Pada particle swarm optimization untuk mendapatkan bobot optimal (posisi partikel terbaik), beberapa partikel mencoba untuk bergerak untuk mendapatkan solusi terbaik. Alur pencarian bobot yang optimal ditunjukkan pada gambar 3.3:



Gambar 3.3 Flowchart Optimasi PSO-Backpropagation

- a. Inisialisasi parameter PSO dan *neural network*. Dalam menentukan nilai setiap parameter berdasarkan batasan pada penelitian terdahulu. Parameter PSO dituliskan dalam tabel 3.1 sedangkan parameter *neural network* dituliskan dalam tabel 3.2 :

Tabel 3.1 Parameter PSO

Parameter	Keterangan
Jumlah partikel	Secara umum jumlah partikel yang direkomendasikan adalah 20 – 50 partikel (Bansal, 2019). Pada penelitian ini menggunakan jumlah partikel 50
w (bobot <i>inertia</i>)	Menurut (Dai, Liu and Li, 2011) nilai dari bobot inertia adalah kurang dari 1. Dimana nilai w yang optimal adalah 0.5 – 0.75. Bobot inertia digunakan untuk mengontrol pengaruh kecepatan partikel.
c1, c2 (learning factors)	Menurut (Dai, Liu and Li, 2011) batasan nilai c1,c2 adalah 0 – 3. c1 adalah learning factor untuk kemampuan individu (kognitif) dan c2 adalah learning factor untuk kemampuan sosial (grup) (Budiman, 2016)
Iterasi	Jumlah iterasi yang digunakan untuk tahap PSO adalah 100

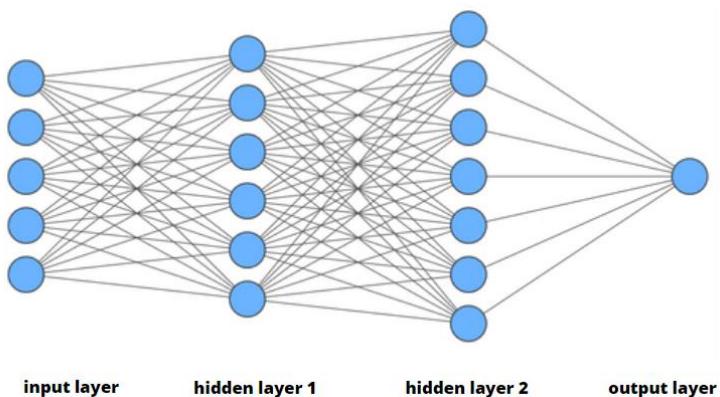
Tabel 3.2 Parameter Neural network

Parameter	Keterangan
Jumlah neuron <i>input layer</i>	Jumlah neuron <i>input</i> adalah 5 yang berasal dari hasil proses windowing
Bobot dan bias	Inisialisasi bobot awal dan bias menggunakan posisi partikel (Niu, Zhang and Xing, 2006).
Jumlah <i>hidden layer</i>	Jumlah hidden layer yang digunakan adalah 2

Jumlah neuron pada hidden layer	Jumlah neuron pada <i>hidden layer</i> ditentukan dengan cara <i>try and error forward approach</i> dimana memilih neuron dari jumlah terkecil yaitu 2 <i>hidden neuron</i> , lalu meningkatkan jumlah neuron hingga berhasil (Panchal and Panchal, 2014).
Jumlah neuron <i>output layer</i>	1 dimana mempresentasikan hasil peramalan
<i>Learning rate</i>	Penentuan <i>learning rate</i> merujuk pada penelitian (Nikentari et al., 2018) yakni : 0,3
Epoch	Jumlah epoch yang digunakan adalah berdasarkan trial error yakni 100, 500, 1000

Gambaran arsitektur *neural network* pada penelitian ini diilustrasikan pada gambar 3.4. Pada penelitian ini menggunakan 5 neuron pada input layer , jumlah neuron pada hidden layer 1 = 6, jumlah neuron pada hidden layer 2 = 7 dan 1 neuron pada output layer.

Jumlah hidden neuron nantinya akan ditingkatkan hingga menemukan model terbaik.



Gambar 3.4 Gambaran Arsitektur Neural Network

b. Training Backpropagation

Pada tahap training atau pelatihan *Backpropagation* terdapat dua tahap yakni:

1. Feedforward

Setiap *input* neuron (X_i) menerima sinyal dan melanjutkannya ke *hidden layer* dengan menggunakan fungsi aktivasi yang telah ditentukan. Output pada *hidden layer* (Z_j) diteruskan ke *hidden layer* diatasnya. Dilakukannya perhitungan pada *output* pada *hidden layer* dengan rumus pada persamaan (3.1), (3.2) dan (3.3) :

$$z_in_j = \theta_j + \sum W_{ij}X_i \quad (3.1)$$

$$z_j = f(z_{in_j}) \quad (3.2)$$

$$f(z_{in_j}) = \frac{1}{1+e^{-z_{in_j}}} \quad (3.3)$$

Dimana :

z_{in_j} = input hidden layer

Wij = bobot antara *input layer* dan *hidden layer*

X_i = nilai *input layer* ke-*i*

θ_j = bias pada *hidden layer*

Z_j = aktivasi pada *hidden layer* ke - j

Kemudian melakukan perhitungan *output* pada *output layer* (O_k), dengan rumus pada persamaan (3.4) , (3.5) , dan (3.6) .

$$O_in_k = \theta_k + \sum Z_j W_{jk} \quad (3.4)$$

$$y_k = f(O_{in_k}) \quad (3.5)$$

$$f(O_in_k) = \frac{1}{1+e^{-z_in_j}} \quad (3.6)$$

Dimana:

O_{in_k} = input output layer

W_{jk} = bobot antara *hidden layer* dan *output layer*

θ_k = bias pada *output layer*

Z_j = aktivasi *hidden layer* ke- j
 y_k = aktivasi pada *output layer* ke-

2. Backpropagation

Pada tahap *Backpropagation* dilakukannya koreksi *error* pada setiap unit *output layer* dengan persamaan (3.8),(3.9), dan (3.10).

$$\delta_k = (t_k - y_k) f'(O_{-in_k}) \quad (3.8)$$

$$\Delta W_{jk} = \alpha \delta_k z_j \quad (3.9)$$

$$\Delta W_{\theta k} = \alpha \delta_k \quad (3.10)$$

Dimana :

δ_k = faktor koreksi *error bobot*

t_k = target output

α = learning rate

ΔW_{jk} = koreksi *error* bobot W_{jk}

$\Delta W_{\theta k}$ = koreksi error bias

$f'(O_{-in_k})$ = fungsi derivatif dari *input* pada *output layer* ke - k

Kemudian melakukan koreksi bobot pada tiap unit pada setiap *hidden layer* dengan persamaan (3.11), (3.12), (3.13), dan (3.14)

$$\delta_{inj} = \sum \delta_k W_{jk} \quad (3.11)$$

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (3.12)$$

$$\Delta V_{ij} = \alpha \delta_j x_i \quad (3.13)$$

$$\Delta V_{\theta j} = \alpha \delta_j \quad (3.14)$$

Dimana :

δ_j = koreksi error pada aktivasi *hidden layer* (z_j)

ΔV_{ij} = perbedaan nilai error

$\Delta V_{\theta j}$ = koreksi bias

Lalu dilakukannya perubahan bobot lama menjadi bobot baru , yang pertama dilakukan perubahan bobot dari *hidden layer* menuju unit *output* dengan persamaan (3.15)

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (3.15)$$

Setelah itu merubah bobot *input* menuju *output* dengan persamaan (3.16)

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (3.16)$$

Dimana :

$W_{jk}(\text{baru})$ = nilai bobot W_{jk} yang baru

$W_{ik}(\text{lama})$ = nilai bobot W_{ik} pada perhitungan sebelumnya

ΔW_{ik} = koreksi error pada bobot W_{ik}

$V_{i,i}(baru)$ = nilai bobot $V_{i,i}$ yang baru

$V_{i,i}(lama)$ = nilai bobot $V_{i,i}$ pada perhitungan sebelumnya

ΔV_{ii} = koreksi error pada bobot V_{ii}

- c. Menentukan dimensi permasalahan didapatkan dari perhitungan jumlah bobot yang terhubung dari neuron input layer ke hidden layer 1, jumlah bobot neuron yang terhubung dari hidden layer 1 yang terhubung ke hidden layer 2, jumlah bobot yang terhubung dari hidden layer 2 ke output layer, serta jumlah bias pada hidden layer 1, hidden layer 2 dan output layer (Jin, Jin and Qin, 2012)
 - d. Untuk mempresentasikan nilai fitness dengan menghitung error dari tahap training *Backpropagation* (Jin and Qin, 2012). Nilai fitness menggambarkan hubungan antara posisi partikel saat ini dengan solusi optimal (Bo *et al.*, 2017). Rumus MSE ditulis pada persamaan 3.7

$$Fitness = \frac{\sum_{i=1}^k (p_i - q_i)^2}{k} \quad (3.7)$$

Dimana k adalah jumlah data, p_i adalah nilai target dan q_i adalah nilai aktual.

- e. Update Gbest dan Pbest didapatkan dari perhitungan nilai fitness. Nilai fitness terbaik pada sebuah partikel ditetapkan sebagai Pbest. Pbest dengan nilai terbaik ditetapkan sebagai Gbest. Dimana Gbest adalah partikel yang memiliki fitness terbaik secara keseluruhan dari semua partikel (Anand and Suganthi, 2017).
 - f. Setelah mendapatkan gbest, menghitung kecepatan setiap partikel. Rumus

$$V_i^{t+1} = \omega V_i^t + c_1 r_1 (pbest - X_i^t) + c_2 r_2 (gbest - X_i^t) \quad (3.7)$$

Dimana:

X_i^t = posisi partikel (i) pada iterasi (t)

$r_1 r_2$ = bilangan acak (0 – 1)

$c_1 c_2$ = learning factor

ω = bobot inersia

- g. Setelah menghitung kecepatan, menghitung posisi baru setiap partikel. Rumus menghitung posisi dituliskan pada persamaan (3.8)

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (3.8)$$

Dimana:

V_i^{t+1} = kecepatan

X_i^t = posisi partikel (i) pada iterasi (t)

- h. Apabila kriteria terpenuhi maka dihasilkannya solusi terbaik yang dijadikan sebagai bobot atribut. Jika kriteria tidak terpenuhi, maka kembali pada tahap perhitungan nilai fitness. Kriteria yang efisien didasarkan pada kapasitas pencarian. Jika suatu algoritma tidak memperbaiki solusi dengan jumlah

yang signifikan hingga sejumlah iterasi tertentu, maka pencarian dihentikan (Bansal, 2019). Selanjutnya hasil dari optimasi PSO-*Backpropagation* yaitu solusi terbaik atau bobot optimal akan digunakan untuk peramalan harga etherum.

Skenario peramalan dituliskan pada tabel 3.3

Tabel 3.3 Skenario Peramalan

No	Skenario	Keterangan
1	Peramalan harga ethereum menggunakan <i>Backpropagation Neural network</i>	Pada skenario ini dilakukannya training dan testing menggunakan <i>Backpropagation Neural network</i>
2.	Peramalan harga ethereum menggunakan <i>PSO+Backpropagation Neural network</i>	Pada skenario ini dilakukannya optimasi bobot dan bias menggunakan metode Particle Swarm Optimization (PSO). Kemudian bobot dan bias yang sudah optimal akan digunakan untuk peramalan menggunakan metode <i>Neural network</i>

BAB IV

HASIL DAN PEMBAHASAN

Pada bab ini peneliti memaparkan hasil berdasarkan alur penelitian yang telah ditulis pada bab 3 metodologi penelitian. Alur penelitian dimulai dari tahap pengumpulan data hingga tahap evaluasi data. Terdapat dua skenario dalam penelitian ini, yakni peramalan menggunakan metode *Backpropagation Neural network*, dan peramalan menggunakan metode PSO dan *Backpropagation*.

4.1 Hasil Pengumpulan Data

Penelitian ini menggunakan data harga Ethereum yang diunduh dari situs www.investing.com dengan rentang waktu 14 Januari 2018 – 21 Juli 2021. Dataset yang telah diunduh berbentuk file (.csv) dan memiliki 1285 data. Kutipan data ditampilkan pada tabel 4.1

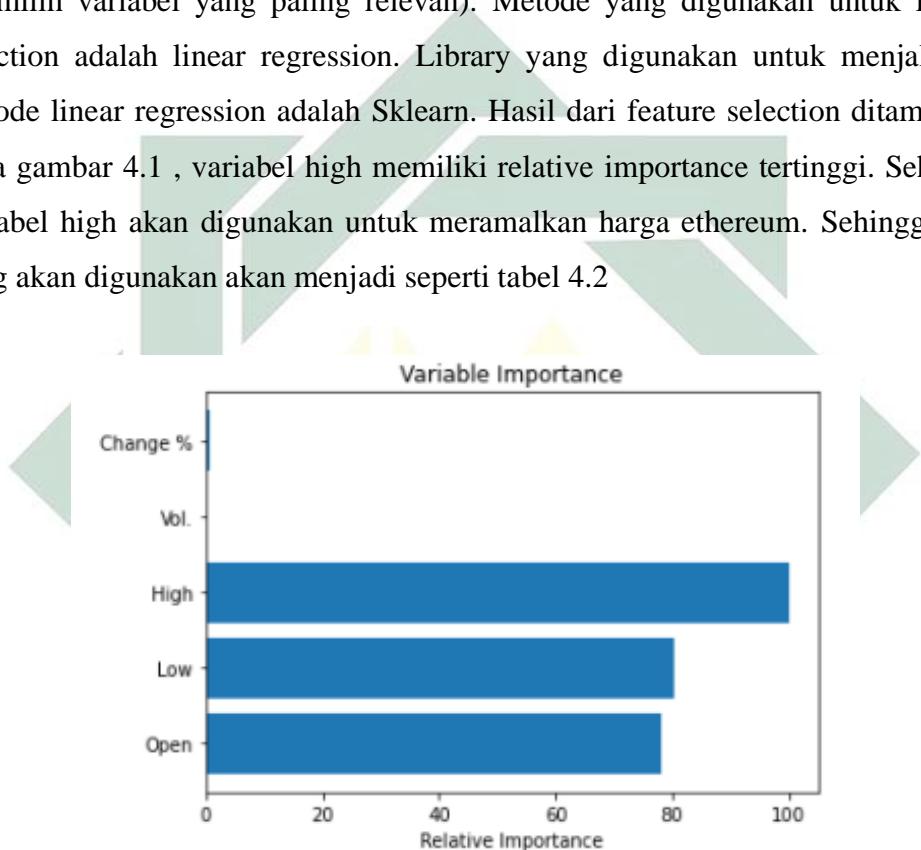
Tabel 4.1 Kutipan Data Harga Ethereum

Date	Price	Open	High	Low	Vol.	Change %
14/1/2018	19494000	20136000	20136000	17360000	2990	-3.19%
15/1/2018	19188000	19494000	20330000	18750000	1580	-1.57%
16/1/2018	13498000	19188000	19213000	11218000	4280	-29.65%
17/1/2018	14299000	13498000	14999000	10641000	4860	5.93%
18/1/2018	14651000	14299000	16750000	13520000	3400	2.46%
19/1/2018	14646000	14651000	15000000	14000000	1340	-0.03%
20/1/2018	16134000	14646000	16200000	14622000	1640	10.16%
21/1/2018	15000000	16134000	16200000	14683000	1790	-7.03%
22/1/2018	14295000	15000000	15300000	13529000	1660	-4.70%
23/1/2018	13453000	14295000	14485000	13024000	1420	-5.89%
24/1/2018	14373000	13453000	14500000	13270000	1320	6.84%
18/1/2018	14651000	14299000	16750000	13520000	3400	2.46%
.....
21/7/2021	27850000	25956000	27958000	25850000	1250	7.30%

4.2 Persiapan Data

4.2.1 Feature Selection

Data harga ethereum pada tabel 4.1 memiliki banyak variabel yaitu date, price, open, high, low, vol., dan change %. Namun tidak semua variabel ini akan digunakan untuk peramalan. Maka dari itu, dilakukannya feature selection (memilih variabel yang paling relevan). Metode yang digunakan untuk feature selection adalah linear regression. Library yang digunakan untuk menjalankan metode linear regression adalah Sklearn. Hasil dari feature selection ditampilkan pada gambar 4.1 , variabel high memiliki relative importance tertinggi. Sehingga variabel high akan digunakan untuk meramalkan harga ethereum. Sehingga data yang akan digunakan akan menjadi seperti tabel 4.2



Gambar 4.1 Hasil Feature Selection

Tabel 4.2 Kutipan Data Harga High (Tertinggi) Ethereum

Date	High
14/1/2018	20136000
15/1/2018	20330000
16/1/2018	19213000
.....
21/7/2021	27958000

4.2.2 Windowing

Data pada tabel 4.2 adalah data harian dari harga tertinggi ethereum. Selanjutnya data tersebut akan dilakukan windowing. Proses windowing dapat membantu meningkatkan akurasi peramalan dan proses windowing juga dapat membantu untuk menentukan input dan output. Pada penelitian ini diterapkannya proses windowing dengan 5 data input dan 1 data output. Data input diambil dari data High 5 hari sebelumnya dan data output adalah data 1 hari berikutnya. Hasil dari windowing ditampilkan pada tabel 4.3

Tabel 4.3 Hasil Windowing Data

Date	Input-1	Input-2	Input -3	Input-4	Input-5	label
14/1/2018	15000000	16750000	14999000	19213000	20330000	20136000
15/1/2018	16200000	15000000	16750000	14999000	19213000	20330000
16/1/2018	16200000	16200000	15000000	16750000	14999000	19213000
17/1/2018	15300000	16200000	16200000	15000000	16750000	14999000
18/1/2018	14485000	15300000	16200000	16200000	15000000	16750000
19/1/2018	14500000	14485000	15300000	16200000	16200000	15000000

4.2.3 Normalisasi

Proses preprocessing terakhir adalah normalisasi yang dimana mengubah nilai data bernominal besar menjadi rentang 0 – 1. Hal ini dikarenakan *neural network* memiliki fungsi aktivasi sigmoid yang memiliki rentang nilai 0 – 1. Pada penelitian proses normalisasi menggunakan library sklearn dengan modul MinMaxScaler(). Hasil dari proses normalisasi ditampilkan pada tabel 4.4

Tabel 4.4 Hasil Normalisasi

Input-1	Input-2	Input-3	Input-4	Input-5	label
0.219139	0.247028	0.219124	0.286279	0.30408	0.300988
0.238263	0.219139	0.247028	0.219124	0.286279	0.30408
0.238263	0.238263	0.219139	0.247028	0.219124	0.286279

0.22392	0.238263	0.238263	0.219139	0.247028	0.219124
---------	----------	----------	----------	----------	----------

4.3 Peramalan Menggunakan Metode Backpropagation Neural Network

4.3.1 Proses Training Backpropagation Neural Network

Pada proses training dibutuhkannya beberapa parameter(tabel 4.5) untuk membuat jaringan *neural network* parameter yang dibutuhkan adalah jumlah input dan output neuron yang diambil berdasarkan hasil windowing, *learning rate* yang ditentukan berdasarkan penelitian (Nikentari *et al.*, 2018), jumlah hidden neuron 1 jumlah hidden neuron 2, dan epoch yang ditentukan berdasarkan *trial – error*.

Tabel 4.5 Parameter *Neural network*

IL	LR	HL 1	HL 2	OL	Epoch
5	0,3	6	7	1	100,500,1000

Keterangan:

IL = Jumlah neuron pada input layer

LR = *learning rate*

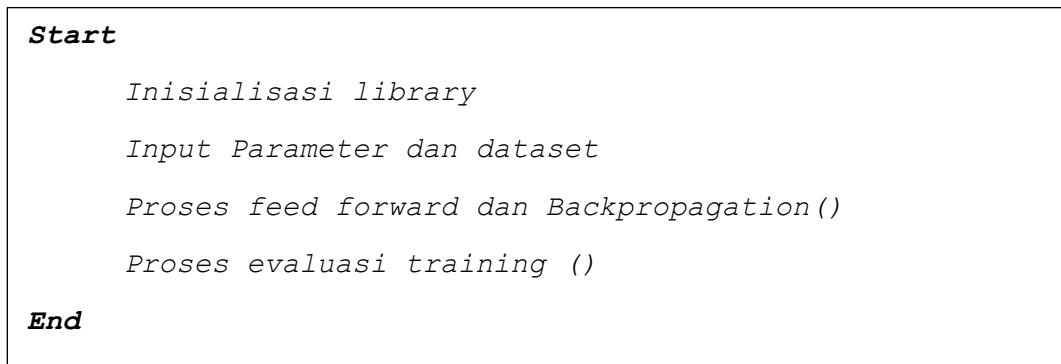
HL 1 = Jumlah neuron pada hidden layer 1

HL 2 = Jumlah neuron pada hidden layer 2

OL = Jumlah neuron pada output layer

Alur proses untuk training *Backpropagation neural network* dituliskan pada tabel 4.6

Tabel 4.6 Alur Proses Training *Backpropagation* Network



Peramalan harga ethereum pada penelitian ini menggunakan bahasa pemrograman python. Tahap awal pada proses trainingm *Backpropagation neural network* adalah inisialisasi library. Library yang digunakan untuk membentuk model *neural network* adalah Keras .Modul yang digunakan pada library Keras adalah Sequential, Dense, Activation, dan Optimizer.

Keras.models import Sequential digunakan untuk membuat model *neural network*. Kemudian keras.layers import Dense digunakan untuk menyediakan setiap layer yang terhubung pada *neural network*. Setiap neuron yang terhubung pada dense layer menerima input dari semua neuron pada layer sebelumnya. Dibelakang dense layer melakukan proses perkalian matriks vektor. Nilai yang digunakan adalah parameter yang dilatih dan diperbarui menggunakan *Backpropagation*.

Sedangkan keras.layers import Activation menyediakan fungsi aktivasi, jenis fungsi aktivasi yang digunakan adalah sigmoid dan softmax. Fungsi aktivasi sigmoid adalah salah satu fungsi non linear yang dapat memudahkan *neural network* untuk beradaptasi dengan beragam data. Selain itu, turunan dari fungsi aktivasi berperan sebagai penyesuai bobot dalam *Backpropagation neural network*. Peneliti melakukan beberapa percobaan untuk fungsi aktivasi yaitu softmax – softmax, sigmoid – softmax, softmax-sigmoid. Hal ini bertujuan untuk mengetahui fungsi aktivasi apa yang dapat menghasilkan model neural network yang terbaik. Selanjutnya keras.optimizers digunakan untuk membantu proses learning mengurangi loss atau error. Jenis optimizers yang digunakan adalah SGD (Stochastic Gradient Descent). SGD bekerja dengan mengubah nilai setelah mengevaluasi satu atau beberapa pasang data training(Verianto and Oetomo, 2021). Kemudian dilanjutkan inisialisasi dataset dan paramater seperti jumlah neuron, *learning rate*, jumlah epoch, fungsi aktivasi . Setelah melakukan inisialisasi library, paramater dan dataset dilakukannya tahap training *Backpropagation* (tabel 4.7)

Tabel 4.7 Source Code Training *Backpropagation*

```
tscv = TimeSeriesSplit(n_splits =10)

mse_per_fold = []
mape_per_fold = []

fold_no = 1
for train, test in tscv.split(inputs, targets):
    modelPSO = Sequential()
    modelPSO.add(Dense(3, activation = "sigmoid", input_dim = n_cols,
name = 'layer_1'))
    modelPSO.add(Dense(4, activation = "sigmoid", name = 'layer_2'))
    modelPSO.add(Dense(1, activation = "sigmoid", name = 'layer_3'))

    modelPSO.compile(loss='mse', optimizer = sgd,
metrics=['mse','mape'])
    modelPSO.fit(inputs[train], targets[train] , epochs = 1000, verbose
= 0)

    scores = modelPSO.evaluate(inputs[test],targets[test], verbose = 0)
    mse_per_fold.append(scores[1])
    mape_per_fold.append(scores[2])

    fold_no = fold_no + 1
```

Source code untuk training dituliskan pada tabel 4.9 . Pada penggunaan library keras, inisialisasi input neuron, hidden neuron, dan fungsi aktivasi ada pada Dense layer. Layer _1 mendeskripsikan atribut jumlah hidden neuron pada hidden layer 1 dan jumlah input layer . Layer_2 mendeskripsikan atribut jumlah hidden neuron pada hidden layer 2. Layer_3 mendeskripsikan atribut jumlah output neuron. Kemudian pada model.compile() mendefinisikan loss function, optimizer, dan metrics. Loss function berfungsi untuk menghitung error pada proses training, optimizer berfungsi mengubah atribut jaringan saraf seperti bobot dan kecepatan pembelajaran untuk mengurangi error.

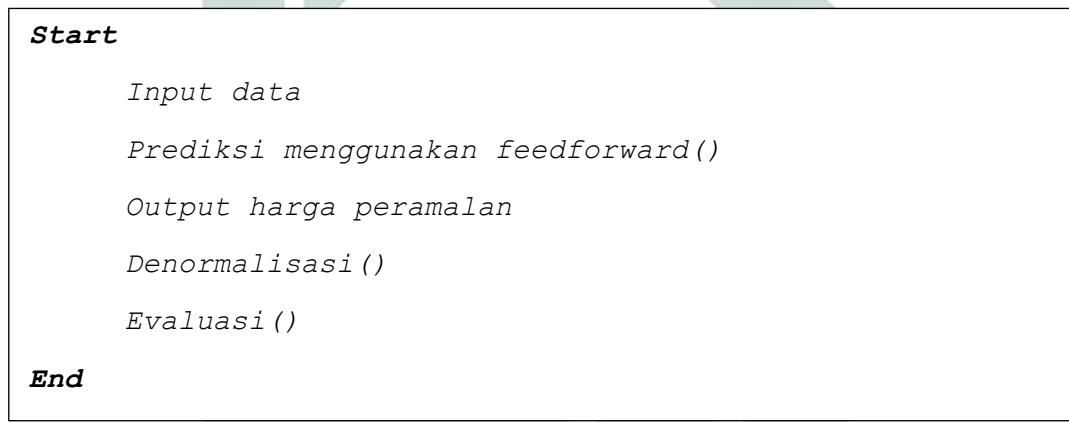
Selanjutnya metrics berfungsi untuk mengevaluasi hasil training. Lalu pada `model.fit()` digunakan untuk mengeksekusi training secara forward propagation dan *backpropagation*. Didalam `model.fit()` memerlukan input dan

output yang digunakan sebagai training dan jumlah epoch / iterasi. Selanjutnya `model.evaluate()` digunakan untuk mengevaluasi model *neural network*. Pada `model.evaluate()` memerlukan atribut input dan output yang digunakan untuk testing. Pembagian data menggunakan library Sklearn yaitu modul `TimeSeriesSplit()`. `TimeSeriesSplit()` adalah modul cross validation khusus data time series pada penelitian ini menggunakan pembagian data menjadi 10 fold.

4.3.2 Proses Testing Backpropagation Neural Network

Setelah dilakukan training, dilakukannya testing. Pada tahap testing dilakukannya peramalan dan evaluasi. Berikut adalah proses testing (tabel 4.8)

Tabel 4.8 Alur Proses Testing



Tahap pertama adalah input data, data yang digunakan sama dengan data yang digunakan pada proses training. Kemudian dilanjutkan dengan tahap prediksi menggunakan *feedforward* dikarenakan pada tahap prediksi tidak terjadinya pembaruan bobot. Untuk peramalan menggunakan Model.predict() yang berfungsi untuk memprediksi atau meramalkan harga ethereum. Model.predict() membutuhkan atribut input data dan jumlah data yang akan diprediksi. Selanjutnya setelah mendapatkan hasil peramalan, dilakukannya denormalisasi. Denormalisasi mengembalikan data yang sebelumnya memiliki range 0 – 1 menjadi data harga. Source code untuk denormalisasi ditampilkan pada tabel 4.8

Tabel 4.8 Source Code Denormalisasi

```
predict_rescaled =  
target_scaler.inverse_transform(predicted_high_price)
```

Untuk melakukan denormalisasi menggunakan method inverse_transform. Method inverse_transform berasal dari library sklearn.preprocessing.MinMaxScaler(). Untuk mengembalikan data, inverse_transform membutuhkan data hasil peramalan yang masih memiliki range 0 - 1. Terakhir adalah proses evaluasi, tahap evaluasi mengukur hasil testing menggunakan MSE dan MAPE yang ditunjukkan pada tabel 4.9.

Tabel 4.9 Hasil Evaluasi Training dan Testing *Backpropagation Neural network*

Fungsi	HL 1	HL 2	Epoch	MSE Training	MAPE Training	MSE Testing	MAPE Testing
Softmax-softmax	6	7	100	0,7941360	2200,99671	0,79142971	2073,58616
			500	0,7941360	2200,99671	0,79142974	2073,58616
			1000	0,7941360	2200,99671	0,79142974	2073,58616
Sigmoid-softmax	6	7	100	0,0328501	144,816463	0,02912151	144,026134
			500	0,0079245	96,0595633	0,00105252	36,6272497
			1000	0,0063311	93,5144615	0,00083029	33,6371211
Softmax-sigmoid	6	7	100	0,0318538	144,488730	0,00102807	35,649908
			500	0,0076284	99,401798	0,00112453	41,440179
			1000	0,0072567	94,091382	0,00077550	31,829610
Sigmoid-Sigmoid	6	7	100	0,0178064	121,18413	0,00116307	51,085497
			500	0,0077969	95,156010	0,00093245	35,543863
			1000	0,00546291	89,578009	0,00083194	33,180193

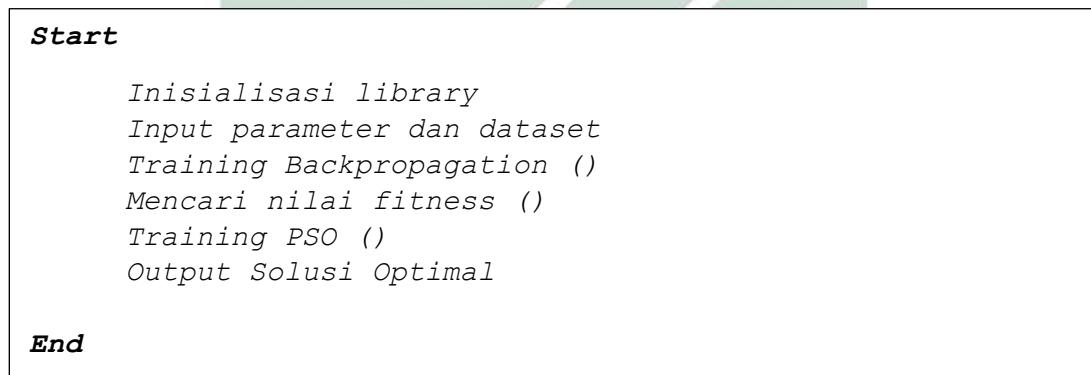
Berdasarkan hasil evaluasi (tabel 4.9) pemilihan fungsi aktivasi dan penentuan jumlah epoch berperan penting dalam menghasilkan nilai error. Pada skenario penggunaan fungsi aktivasi softmax – softmax menghasilkan nilai error yang tinggi dan tidak adanya perubahan nilai error ketika menaikkan jumlah epoch. Namun berbeda dengan penggunaan fungsi aktivasi softmax – sigmoid, sigmoid – softmax, dan sigmoid-sigmoid pada skenario tersebut menghasilkan nilai error yang semakin kecil ketika menaikkan jumlah epoch. Model neural network terbaik saat training adalah model neural network dengan parameter fungsi sigmoid – sigmoid dan jumlah epoch 1000. Hasil MSE dan MAPE yang dihasilkan adalah 0,00546291 dan 89,578009. Sedangkan hasil evaluasi model neural network terbaik saat testing adalah model neural network dengan parameter fungsi softmax – sigmoid dan jumlah epoch 1000. Hasil MSE dan MAPE yang dihasilkan adalah 0,00077550 dan 31,829610. Pemilihan fungsi aktivasi

4.4 Peramalan Menggunakan PSO - BPNN

4.4.1 Proses Training PSO - BPNN

Sebelum melakukan peramalan, dilakukannya training *backpropagation neural network* terlebih dahulu. Alur proses training *backpropagation* dan PSO dituliskan pada tabel 4.11

Tabel 4.10 Alur Training PSO - BPNN



Pertama dilakukannya import library. Library yang digunakan untuk training backpropagation sama seperti sebelumnya yaitu Keras dengan modul Sequential, Dense, Activation, dan Optimizer. Sedangkan library yang digunakan

untuk training PSO menggunakan library pyswarms. Kemudian dilakukannya inisialisasi parameter *neural network* (tabel 4.5) dan dataset. Selanjutnya dilakukan training *Backpropagation* sama seperti pada sub bab 4.3.1 . Setelah melakukan training *Backpropagation* dilakukannya pencarian nilai fitness menggunakan MSE.

Setelah mencari nilai fitness dilakukannya training PSO. Training PSO menggunakan library pyswarm dan membutuhkan beberapa parameter yaitu, jumlah partikel yang ditentukan berdasarkan penelitian (Bansal, 2019) , jumlah dimensi(dimensions) yang ditentukan berdasarkan jumlah bobot dan bias pada *neural network*, bobot inersia (w), cognitive learning (c_1), social learning (c_2) berdasarkan (Dai, Liu and Li, 2011) , dan jumlah iterasi yang dipilih berdasarkan trial dan error. Berikut (tabel 4.11) daftar parameter PSO yang digunakan untuk melakukan training PSO-*Backpropagation*.

Tabel 4.11 Parameter yang digunakan untuk training PSO

w	C1	C2	Jumlah iterasi	Jumlah partikel
0,55	1	2	100	50

Dibutuhkannya perhitungan dimensi sebelum melakukan pencarian bobot optimal. Besar dimensi berasal dari jumlah bobot dan bias pada *neural network*. Pada penelitian ini menggunakan 5 input dan 1 output dari hasil windowing. jumlah neuron pada hidden layer 1 dan hidden layer 2 adalah 6 dan 7, maka

perhitungan dimensi sebagai berikut :

$$dimensions = (5 \times 6) + (6) + (6 \times 7) + (7) + (7 \times 1) + (1)$$

dimensions = 93

Setelah melakukan perhitungan dimensi, dilakukannya pencarian bobot optimal menggunakan particle swarm optimization. Untuk mengeksekusi pencarian bobot optimal menggunakan modul `ps.singleGlobalBestPSO()` dan method `optimize` yang berisi fungsi fitness dan iterasi. Modul ini bekerja dengan mengambil

kandidat solusi dan mencoba untuk menemukan solusi terbaik dengan melakukan update kecepatan dan posisi (Ferdousi, 2021).

Output dari perhitungan menggunakan library pyswarm adalah best position dan best cost. Pada penelitian ini melakukan 12 percobaan. Setiap skenario kombinasi fungsi aktivasi dilakukannya tiga kali percobaan sesuai dengan parameter yang telah ditentukan. Parameter PSO yang digunakan sesuai dengan yang telah ditulis pada tabel 4.11, yaitu $c_1 = 1$; $c_2 = 2$; $w = 0,55$. Percobaan ini dilakukan untuk mendapatkan output best cost dan best post . Output best cost ditulis pada tabel 4.12. Berdasarkan hasil training PSO, model PSO-BPNN dengan fungsi aktivasi sigmoid-sigmoid dan jumlah epoch 1000 menghasilkan best cost minimum. Best cost yang dihasilkan adalah 0,000169327

Tabel 4.12 Best Cost

Fungsi	HL1	HL2	Epoch	Best Cost
Softmax	-	6	100	0,833321548
			500	0,833321548
			1000	0,833321548
Sigmoid	-	6	100	0,000213437
			500	0,000337808
			1000	0,000308285
Softmax	-	6	100	0,000193439
			500	0,000203610
			1000	0,000198946
Sigmoid	-	6	100	0,000169327
			500	0,000223791
			1000	0,000204810

Pada training PSO – *Backpropagation* selain didapatkannya best cost, juga didapatkannya best pos. Best pos adalah posisi terbaik dari partikel atau solusi terbaik. Jumlah dari best pos sesuai dengan jumlah dimensi, sehingga best pos dapat dijadikan sebagai bobot untuk *neural network*. Berikut ini (tabel 4.13) adalah salah

satu hasil best pos dengan jumlah dimensi 93. Best pos yang dihasilkan berbentuk array.

Tabel 4.13 Contoh Best Pos

[-0.12941024	0.20587451	18.23289864	-0.84947722	0.22970483	1.48115629
0.08543414	-0.09424861	0.88688215	0.1342024	-0.74400138	1.38544585
0.28899885	1.25040322	0.02124146	0.82957458	0.9566162	-4.63768672
0.40001656	1.65033571	1.35137284	0.73393651	3.7154146	0.43657007
0.26908038	4.52001821	1.13296112	1.30588022	1.25221099	-2.44141823
0.55427371	7.35982123	-0.55099784	-1.63939812	3.77160218	1.79811982
1.4930724	-1.13429216	0.46619751	-1.34521879	1.54498715	2.73433306
-0.85473046	-2.47473916	-0.15530312	1.2459629	0.12788816	1.12557116
1.28259808	-0.32839464	0.38038675	-0.5075952	-3.57613146	2.09136209
-1.38758329	0.06192048	-2.67567431	4.06698353	1.25286631	0.133636
3.72733425	0.92006402	0.1740823	-1.19213095	0.0584582	0.89151458
-0.93481267	-1.9744961	1.23480763	-0.83284178	-0.53150383	-1.46784779
-0.246285	-0.96444862	-3.80563263	5.14638236	1.50234328	2.55095431
0.2515522	-3.08967573	1.90292103	0.35983614	0.5714756	-0.23214484
1.00293519	3.21551109	6.13459989	0.1661319	0.43361346	-1.61280108
0.6457993	-5.12880538	-0.57125579]			

4.4.2 Proses Testing PSO – Backpropagation Neural network

Pada proses testing akan dilakukannya proses peramalan dan evaluasi. Alur proses testing dituliskan pada tabel 4.14.

Tabel 4.14 Alur proses Testing

Start

Load model neural network

Input dataset

Reshape solusi optimal

Set bobot ()

Peramalan ()

Output hasil peramalan

Denormalisasi ()

Evaluasi ()

Output hasil evaluasi

Sebelum dilakukannya peramalan, tahap pertama dalam proses testing adalah mengunggah kembali model *neural network* yang telah dilakukan training sebelumnya menggunakan `load_model()`. Kemudian penulis mencari tahu jumlah bobot yang ada pada setiap lapisan *neural network* dengan menggunakan `model.get_weights()`.

Lalu dilanjutkan dengan tahap input solusi optimal dan reshape solusi optimal. Solusi optimal adalah best pos yang telah dihasilkan pada proses training.

Best pos yang akan digunakan pada proses testing adalah best pos yang mempunyai nilai best cost minimum (tabel 4.14). Kemudian dilakukannya reshape best pos disesuaikan dengan jumlah bobot yang ada pada setiap layer *neural network*.

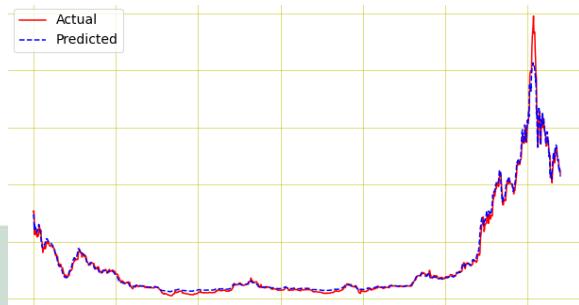
Setelah melakukan reshape bentuk best pos, dilakukannya tahap set bobot atau penggantian bobot hasil training *Backpropagation* dengan best post menggunakan model.set_weights(). Sehingga bobot yang lama diganti dengan bobot yang telah dioptimasi menggunakan PSO. Kemudian untuk meramalkan menggunakan library keras yang menyediakan function untuk prediksi yaitu model.predict(). Setelah dilakukannya peramalan, dilakukan evaluasi dengan mencari nilai MSE dan MAPE . Hasil evaluasi di tuliskan pada tabel 4.15

Tabel 4.15 Hasil Evaluasi

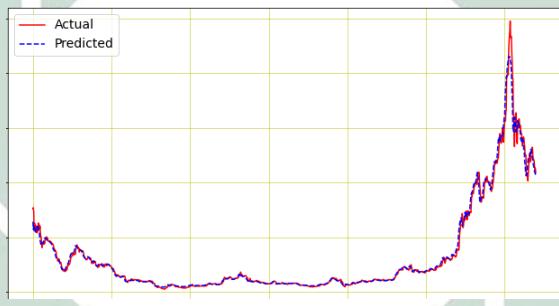
Fungsi	HL1	HL2	Epoch	MSE	MAPE
Softmax -	6	7	100	0.395714870500	2073.58616575
			500	0.395714870500	2073.58616575
			1000	0.395714870500	2073.58616575
Sigmoid -	6	7	100	0.000165929842	16.82139531930
			500	0.000265982380	16.03270184422
			1000	0.000237528148	22.02124865583
Softmax - Sigmoid	6	7	100	0.000158916924	10.20111013970
			500	0.000145474155	19.69349662585
			1000	0.114455483989	1105.941770362
Sigmoid - Sigmoid	6	7	100	0.000132189715	14.32161477833
			500	0.000177402050	14.14769055239
			1000	0.000168178550	7.596568539831

Setelah melakukan 12 skenario pengujian didapatkan hasil evaluasi. Model peramalan PSO – Backpropagation yang menghasilkan MSE dan MAPE tertinggi adalah model PSO – Backpropagation yang menggunakan fungsi aktivasi softmax – softmax. Selanjutnya model peramalan PSO – Backpropagation terbaik pertama(gambar 4.2) dalam meramalkan harga ethereum adalah model PSO –

Backpropagation dengan parameter fungsi sigmoid – sigmoid dan epoch 100, dengan MSE = 0.000132189715. Model peramalan PSO – Backpropagation terbaik kedua (gambar 4.3) adalah model dengan parameter fungsi sigmoid – sigmoid dan epoch 1000. MAPE yang dihasilkan adalah 7,596568539831.



Gambar 4.2 Plot Model Peramalan PSO-BP Sigmoid-Sigmoid Epoch 100



Gambar 4.3 Plot Model Peramalan PSO-BP Sigmoid – Sigmoid Epoch 1000

4.4.3 Perbandingan Hasil Evaluasi Menggunakan Backpropagation Neural network dengan Backpropagation – PSO

Perbandingan hasil peramalan menggunakan *backpropagation neural network* dituliskan pada tabel 4.16

Tabel 4.16 Perbandingan Hasil Evaluasi

Fungsi	HL 1	HL 2	Epoc h	BPNN		PSO - BPNN	
				MSE	MAPE	MSE	MAPE
Softmax – Softmax	6	7	100	0,79142	2073,58		
				971	616	0.395714	2073.586
			500	0,79142	2073,58		
				974	616	0.395714	2073.586

			1000	0,79142 974	2073,58 616	0.395714	2073.586
Sigmoid - Softmax	6	7	100	0,02912 151	144,026 134	0.000165	16.82139
			500	0,00105 252	36,6272 497	0.000265	16.03270
			1000	0,00083 029	33,6371 211	0.000237	22.02124
Softmax - Sigmoid	6	7	100	0,00102 807	35,6499 08	0.000158	10.20111
			500	0,00112 453	41,4401 79	0.000145	19.693496
			1000	0,00077 550	31,8296 10	0.114455	1105.9417
Sigmoi d - Sigmoi d	6	7	100	0,00116 307	51,0854 97	0.000132	14.321614
			500	0,00093 245	35,5438 63	0.000177	14.1476905
			1000	0,00083 194	33,1801 93	0.00016817 8550	7.5965685

Berdasarkan perbandingan hasil evaluasi (tabel 4.30) model peramalan menggunakan metode optimasi PSO dapat membantu *Backpropagation* dalam menghasilkan peramalan yang lebih akurat. Hal ini dilihat dari metode PSO – *Backpropagation* menghasilkan nilai MSE dan MAPE yang lebih kecil dibandingkan dengan peramalan menggunakan metode *Backpropagation* saja. Model peramalan PSO-*Backpropagation* dengan parameter fungsi sigmoid – sigmoid dan epoch 1000 masuk dalam kriteria model peramalan yang sangat baik, karena MAPE yang dihasilkan <10%.

BAB V

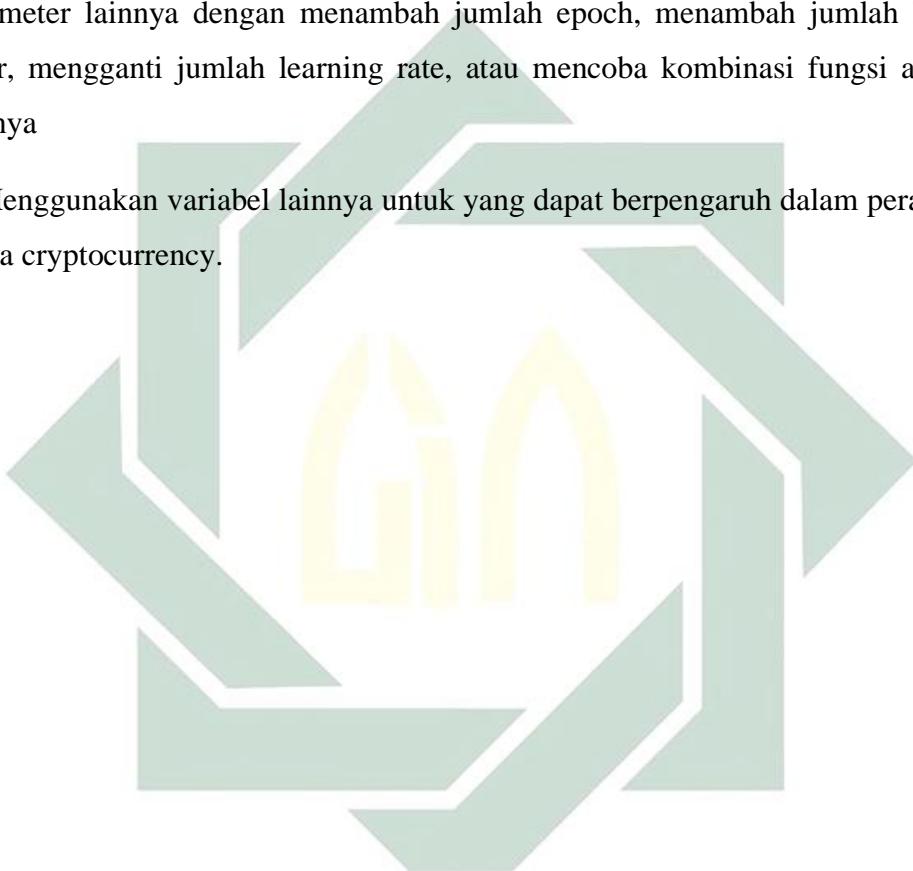
PENUTUP

5.1 Kesimpulan

1. Setelah dilakukannya 12 skenario pengujian didapatkan hasil evaluasi model neural network terbaik saat training adalah model neural network dengan parameter fungsi sigmoid – sigmoid dan jumlah epoch 1000. Hasil MSE dan MAPE yang dihasilkan adalah 0,00546291 dan 89,578009. Sedangkan hasil evaluasi model neural network terbaik saat testing adalah model neural network dengan parameter fungsi softmax – sigmoid dan jumlah epoch 1000. Hasil MSE dan MAPE yang dihasilkan adalah 0,00077550 dan 31,829610.
 - 2 Setelah melakukan 12 skenario pengujian didapatkan hasil evaluasi. Model peramalan PSO – Backpropagation terbaik pertama dalam meramalkan harga ethereum adalah model PSO – Backpropagation dengan parameter fungsi sigmoid – sigmoid dan epoch 100, dengan $MSE = 0.000132189715$. Model peramalan PSO – Backpropagation terbaik kedua adalah model dengan parameter fungsi sigmoid – sigmoid dan epoch 1000. MAPE yang dihasilkan adalah 7,596568539831.
 3. Model peramalan menggunakan metode optimasi PSO dapat membantu *Backpropagation* dalam menghasilkan peramalan yang lebih akurat. Hal ini dilihat dari metode PSO – *Backpropagation* menghasilkan nilai MSE dan MAPE yang lebih kecil dibandingkan dengan peramalan menggunakan metode *Backpropagation* saja. Model peramalan PSO-*Backpropagation* dengan parameter fungsi sigmoid – sigmoid dan epoch 1000. Masuk dalam kriteria model peramalan yang sangat baik, karena MAPE yang dihasilkan $<10\%$.
 4. Berdasarkan penelitian yang telah dilakukan, selain optimasi menggunakan PSO, penentuan parameter untuk neural network perlu diperhatikan seperti jenis fungsi aktivasi yang digunakan dan jumlah epoch karena penentuan tersebut berpengaruh dalam keakurasiannya peramalan.

5.2 Saran

1. Saran untuk penelitian mendatang dapat menggunakan metode optimasi lainnya untuk *Backpropagation neural network* agar mendapatkan hasil yang lebih optimal seperti genetic algorithm dan bee colony.
 2. Pada penelitian selanjutnya dapat mencoba membuat model peramalan dengan parameter lainnya dengan menambah jumlah epoch, menambah jumlah hidden layer, mengganti jumlah learning rate, atau mencoba kombinasi fungsi aktivasi lainnya
 3. Menggunakan variabel lainnya untuk yang dapat berpengaruh dalam peramalan harga cryptocurrency.



DAFTAR PUSTAKA

- Abad-Segura, E. et al. (2020) ‘Financial Technology: Review of Trends , Approaches and Management’, Mathematics, 8(6). doi: 10.3390/math8060951.

Anand, A. and Suganthi, L. (2017) ‘Forecasting of Electricity Demand by Hybrid ANN-PSO Models’, International Journal of Energy Optimization and Engineering, 6(4), pp. 66–83. doi: 10.4018/ijoe.2017100105.

Ayodele Ariyo Adebiyi, Aderemi Oluyinka Adewumi, and C. K. A. (2014) ‘Comparison of ARIMA and Artificial Neural networks Models for Stock Price Prediction’, Journal of Applied Mathematics, 2014, p. 3. doi: <http://dx.doi.org/10.1155/2014/614342>.

Baker, R. S. J. (2011) ‘Encyclopedia of Data Warehousing and Mining’, International Encyclopedia of Education (3rd edition). doi: 10.4018/978-1-59140-557-3.

Bansal, J. C. (2019) ‘Particle Swarm Optimizatione’, in Evolutionary and Swarm Intelligence Algorithms. Springer International Publishing, pp. 11–23. doi: 10.1007/978-3-319-91341-4.

Bo, G. et al. (2017) ‘Hybrid PSO-BP neural network approach for wind power forecasting’, International Energy Journal, 17(4), pp. 211–222.

Bouktif, S. et al. (2019) ‘Single and multi-sequence deep learning models for short and medium term electric load forecasting’, Energies, 12(1). doi: 10.3390/en12010149.

Budiman, H. (2016) ‘Analisis Dan Perbandingan Akurasi Model Prediksi Rentet Waktu Support Vector Machines Dengan Support Vector Machines Particle Swarm Optimization Untuk Arus Lalu Lintas Jangka Pendek’, Systemic: Information System and Informatics Journal, 2(1), pp. 19–24. doi: 10.29080/systemic.v2i1.103.

Buterin, V. (2016) Ethereum: Platform Review. Available at:

https://static1.squarespace.com/static/55f73743e4b051cfcc0b02cf/t/57506f387da24ff6bdecb3c1/1464889147417/Ethereum_Paper.pdf%0Ar3cev.com/s/Etherium_Paper-97k4.pdf

- Chen, L. and Lai, X. (2011) ‘Comparison between ARIMA and ANN models used in short-term wind speed forecasting’, in Asia-Pacific Power and Energy Engineering Conference, APPEEC. doi: 10.1109/APPEEC.2011.5748446.

Dai, Y., Liu, L. and Li, Y. (2011) ‘An intelligent parameter selection method for particle swarm optimization algorithm’, in Proceedings - 4th International Joint Conference on Computational Sciences and Optimization, CSO 2011, pp. 960–964. doi: 10.1109/CSO.2011.79.

Debnath, K. B. and Mourshed, M. (2018) ‘Forecasting methods in energy planning models’, Renewable and Sustainable Energy Reviews, 88, pp. 297–325. doi: 10.1016/j.rser.2018.02.002.

Devries, P. D. (2016) ‘An Analysis of Cryptocurrency , Bitcoin , and the Future An Analysis of Cryptocurrency , Bitcoin , and the Future’, International Journal of Business Management and Commerce, 1(2).

Du, Y. (2018) ‘Application and analysis of forecasting stock price index based on combination of ARIMA model and BP neural network’, in Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018. IEEE, pp. 2854–2857. doi: 10.1109/CCDC.2018.8407611.

Elendner, H. et al. (2017) ‘The Cross-Section of Crypto-Currencies as Financial Assets: Investing in Crypto-Currencies Beyond Bitcoin’, in Handbook of Blockchain, Digital Finance, and Inclusion, Volume 1: Cryptocurrency, FinTech, InsurTech, and Regulation. 1st edn. Elsevier Inc., p. 146. doi: 10.1016/B978-0-12-810441-5.00007-5.

Fairley, P. (2019) ‘Ethereum will cut back its absurd energy use’, IEEE Spectrum, 56(1), pp. 29–32. doi: 10.1109/MSPEC.2019.8594790.

Farell, R. (2015) ‘An Analysis of the Cryptocurrency Industry’, Wharton Research

Scholars Journal. Paper, 130(5). Available at:
http://repository.upenn.edu/wharton_research_scholars%0Ahttp://repository.upenn.edu/wharton_research_scholars/130.

Ferdousi, N. (2021) COMPARISON OF GLOBAL AND LOCAL PARTICLE SWARM OPTIMIZATION North Dakota State University.

Garro, B. A., Sossa, H. and Vázquez, R. A. (2011) ‘Back-propagation vs particle swarm optimization algorithm: Which algorithm is better to adjust the synaptic weights of a feed-forward ANN?’, International Journal of Artificial Intelligence, 7(11 A), pp. 208–218.

GRIGORYAN, H. (2015) ‘Stock Market Prediction using Artificial Neural networks. Case Study of TAL1T, Nasdaq OMX Baltic Stock’, Database Systems Journal, VI(2), pp. 14–23.

Guo, K. et al. (2020) ‘Short-Term Photovoltaic Power Forecasting Based on PSO-BP Neural network’, in 2020 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia), pp. 303–309. doi: <https://doi.org/10.1109/ICPSAsia48933.2020.9208390>.

Habibi, M. Y. and Riksakomara, E. (2017) ‘Peramalan Harga Garam Konsumsi Menggunakan Artificial Neural network Feedforward-Backpropagation (Studi Kasus : PT. Garam Mas, Rembang, Jawa Tengah)’, Jurnal Teknik ITS, 6(2). doi: 10.12962/j23373539.v6i2.23200.

Hand, D. J. (2007) 'Principles of data mining', *Drug Safety*, 30(7), pp. 621–622.
doi: 10.2165/00002018-200730070-00010.

Hota, H. S., Handa, R. and Shrivastava, A. K. (2017) ‘Time Series Data Prediction Using Sliding Window Based RBF Neural network’, International Journal of Computational Intelligence Research, 13(5), pp. 1145–1156. Available at: <http://www.ripublication.com>.

Hsu, C. M. (2011) ‘Forecasting stock/futures prices by using neural networks with feature selection’, in Proceedings - 2011 6th IEEE Joint International

Information Technology and Artificial Intelligence Conference, ITAIC 2011,
pp. 1–7. doi: 10.1109/ITAIC.2011.6030137.

Islam, M. R. et al. (2018) 'Algorithm , Cashflow & Ledger Technology on', in 2018 International Conference on Information and Communication Technology for the Muslim World (ICT4M). IEEE, pp. 69–73. doi: 10.1109/ICT4M.2018.00022.

Jin, C., Jin, S. W. and Qin, L. N. (2012) 'Attribute selection method based on a hybrid BPNN and PSO algorithms', Applied Soft Computing Journal. Elsevier B.V., 12(8), pp. 2147–2155. doi: 10.1016/j.asoc.2012.03.015.

Junaidi (2014) ‘Analisis Hubungan Deret Waktu Untuk Peramalan’, Repository Universitas Jambi, pp. 1–5.

Khashei, M. and Bijari, M. (2010) 'An artificial neural network (p, d, q) model for timeseries forecasting', Expert Systems with Applications. Elsevier Ltd, 37(1), pp. 479–489. doi: 10.1016/j.eswa.2009.05.044.

Kotu, V. and Deshpande, B. (2019) Data Science Concepts and Practice, Data Handling in Science and Technology.

Kukreja, H. and Bharath N (2016) ‘An introduction to artificial intelligence’, IJARIIE, 1(5). doi: 10.2514/6.1994-294.

Larose, D. T. and Larose, C. D. (2014) Discovering Knowledge in Data: An Introduction to Data Mining: Second Edition, Discovering Knowledge in Data: An Introduction to Data Mining: Second Edition. doi: 10.1002/9781118874059.

Li, H. et al. (2019) 'Ground water level prediction for the arid oasis of Northwest China based on the artificial bee colony algorithm and a back-propagation neural network with double hidden layers', Water (Switzerland), 11(4), pp. 1–20. doi: 10.3390/w11040860.

Li, Y. et al. (2019) 'Does size matter in the cryptocurrency market?', *Applied Economics Letters*, 27(14). doi: 10.1080/13504851.2019.1673298.

- Liu, C. et al. (2016) ‘Online ARIMA algorithms for time series prediction’, 30th AAAI Conference on Artificial Intelligence, AAAI 2016, pp. 1867–1873.
- Maricar, M. A., Widiadnyana, P. and Wijaya, W. A. (2018) ‘Analysis of Data Mining for Forecasting Total Goods Delivery with Moving Average Method Study (Case Study: Agent “X” Expedition “Z”) M.’, International Journal of Engineering and Emerging Technology, 2(1). doi: 10.24843/IJEET.2017.v02.i01.p02.
- Mark Lutz (2008) Learning Python. 3rd edn, O’reilly. 3rd edn. Sebastopol: O’REILLY.
- Meesad, P. and Rasel, R. I. (2013) ‘Dhaka stock exchange trend analysis using support vector regression’, Advances in Intelligent Systems and Computing, 209 AISC, pp. 135–143. doi: 10.1007/978-3-642-37371-8_17.
- Miciuła, I. and Kazojć, K. (2019) ‘The global development of cryptocurrencies’, RESEARCH PAPERS OF WROCŁAW UNIVERSITY OF ECONOMIC, 63(2). doi: 10.15611/pn.2019.2.16.
- Montgomery, D. C., Jennings, C. L. and Kulahci, M. (2008) Introduction to Time Series Analysis and Forecasting. Edited by D. J. Balding. Canada: John Wiley & Sons.
- Mukhopadhyay, U. et al. (2016) ‘A brief survey of Cryptocurrency systems’, 2016 14th Annual Conference on Privacy, Security and Trust, PST 2016, pp. 745–752. doi: 10.1109/PST.2016.7906988.
- Najwa, M., Warsito, B. and Ispriyanti, D. (2017) ‘Pemodelan Jaringan Syaraf Tiruan Dengan Algoritma One Step Secant Backpropagation Dalam Return Kurs Rupiah Terhadap Dolar Amerika Serikat’, JURNAL GAUSSIAN, 6(1), pp. 61–70.
- Nakano, M., Takahashi, A. and Takahashi, S. (2018) ‘Bitcoin technical trading with artificial neural network’, Physica A: Statistical Mechanics and its Applications. Elsevier B.V., 510, pp. 587–609. doi: 10.1016/j.physa.2018.07.017.

- Narvekar, M. and Fargose, P. (2015) ‘Daily Weather Forecasting using Artificial Neural network’, International Journal of Computer Applications, 121(22), pp. 9–13. doi: 10.5120/21830-5088.
- Nian, L. P., Lee, D. and Chuen, K. (2015) ‘Introduction to Bitcoin’, in Chuen, D. L. K. (ed.) Handbook of Digital Currency. 1st Editio. Academic Press. doi: 10.1016/B978-0-12-802117-0.00001-1.
- Nikentari, N. et al. (2018) ‘Particle Swarm Optimization Untuk Prediksi Pasang Surut Air Optimization of Backpropagation Artificial Neural network With Particle Swarm Optimization To Predict Tide Level’, Jurnal Teknologi Informasi dan Ilmu Komputer, 5(5), pp. 605–612. doi: 10.25126/jtiik2018551055.
- Niu, D. X., Zhang, B. and Xing, M. (2006) ‘Application of neural network based on particle swarm optimization in short-term load forecasting’, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 3972 LNCS, pp. 1269–1276. doi: 10.1007/11760023_184.
- Nugraha, E. Y. and Suletra, I. W. (2017) ‘Analisis Metode Peramalan Permintaan Terbaik Produk Oxycan pada PT. Samator Gresik’, in Seminar dan Konferensi Nasional IDEC 2017, pp. 2579–6429. Available at: https://www.google.com/search?rlz=1C1CHBF_enID883ID884&ei=4cpdXt6OD47RrQHjm5jIDA&q=jurnal+tentang+metode+peramalan&oq=jurnal+tentang+peramalan&gs_l=psy-ab.3.4.0l3j0i22i30l7.1592741.1598642..1602835...1.2..0.203.2703.14j10j1.....0....1..gws-wiz.....0i71.
- Nugraha, H. G. and Azhari (2014) ‘Pelatihan Bobot Jaringan Syaraf Tiruan Menggunakan Particle Swarm Optimization untuk Peramalan Tingkat Inflasi’, Berkala MIPA, 24(4), pp. 292–302.
- Panchal, F. S. and Panchal, M. (2014) ‘Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural network’, International Journal of

- Computer Science and Mobile Computing, 3(11), pp. 455–464.
- Qiu, M. and Song, Y. (2016) ‘Predicting the direction of stock market index movement using an optimized artificial neural network model’, PLoS ONE, 11(5), pp. 1–11. doi: 10.1371/journal.pone.0155133.
- Radityo, A., Qorib, M. and Budi, I. (2017) ‘Prediction of Bitcoin Exchange Rate to American Dollar Using Artificial Neural network Methods’, in ICACSIS 2017, p. 434.
- Sadaei, H. J. et al. (2016) ‘Combining ARFIMA models and fuzzy time series for the forecast of long memory time series’, Neurocomputing. Elsevier, 175, pp. 782–796. doi: 10.1016/j.neucom.2015.10.079.
- Salman, N., Lawi, A. and Syarif, S. (2018) ‘Artificial Neural network Backpropagation with Particle Swarm Optimization for Crude Palm Oil Price Prediction’, Journal of Physics: Conference Series, 1114(1). doi: 10.1088/1742-6596/1114/1/012088.
- Sathish Kumar, P. and Raaza, A. (2018) ‘Study and analysis of intrusion detection system using random forest and linear regression’, Periodicals of Engineering and Natural Sciences, 6(1), pp. 197–200. doi: 10.21533/pen.v6i1.289.
- Shafiei Chafi, Z. and Afrakhte, H. (2021) ‘Short-Term Load Forecasting Using Neural network and Particle Swarm Optimization (PSO) Algorithm’, Mathematical Problems in Engineering, 2021. doi: 10.1155/2021/5598267.
- Sichinava, D. (2019) ‘Cryptocurrency and Prospects of Its Development’, Ecoforum Journal, 8(2).
- Sukamulja, S. and Sikora, C. O. (2018) ‘THE NEW ERA OF FINANCIAL INNOVATION : THE DETERMINANTS OF BITCOIN’S PRICE’, Journal of Indonesian Economy and Business Volume, 33(1).
- Verianto, E. and Oetomo, B. S. D. (2021) ‘Artificial Neural network Model with PSO as a Learning Method to Predict Movement of the Rupiah Exchange Rate

- against the US Dollar', IJAIT (International Journal of Applied Information Technology), 04(02), p. 81. doi: 10.25124/ijait.v4i02.3381.
- Vrbka, J. and Rowland, Z. (2017) 'Stock price development forecasting using neural networks', in SHS Web of Conferences 39, p. 01032. doi: 10.1051/shsconf/20173901032.
- Vujičić, D., Jagodić, D. and Randić, S. (2018) 'Blockchain technology, bitcoin, and Ethereum: A brief overview', in 2018 17th International Symposium on INFOTEH-JAHORINA, INFOTEH 2018 - Proceedings, pp. 1–6. doi: 10.1109/INFOTEH.2018.8345547.
- Wagena, M. B. et al. (2020) 'Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models', Environmental Modelling and Software. Elsevier Ltd, 126(February), p. 104669. doi: 10.1016/j.envsoft.2020.104669.
- Wang, P. and Zhao, G. (2016) 'Applying Back - propagation Neural network to Predict Bus Traffic', in 12th International Conference on Natural Computation, Fuzzy System and Knowledge Discovery, pp. 752–756.
- Witten, I. H., Frank, E. and Hall, M. A. (2011) Data Mining Practical Machine Learning Tools and Techniques Fourth Edition, Data Mining. doi: 10.1016/C2009-0-19715-5.
- Wu, J. et al. (2018) 'Optimized BP neural network for Dissolved Oxygen prediction', IFAC-PapersOnLine. Elsevier B.V., 51(17), pp. 596–601. doi: 10.1016/j.ifacol.2018.08.132.
- Yang, B., Sun, Y. and Wang, S. (2020) 'A novel two-stage approach for cryptocurrency analysis', International Review of Financial Analysis. Elsevier Inc, 72. doi: 10.1016/j.irfa.2020.101567.
- Zhang, G. P. and Qi, M. (2005) 'Neural network forecasting for seasonal and trend time series', European Journal of Operational Research, 160(2). doi: 10.1016/j.ejor.2003.08.037.