

**TUGAS AKHIR - KA 184801**

**PEMBENTUKAN PORTOFOLIO OPTIMAL  
*HIERARCHICAL RISK PARITY DAN NESTED  
CLUSTERED OPIMIZATION TERHADAP FORECASTING  
LSTM HARGA CRYPTOCURRENCY TRENDING  
TWITTER***

**Nathanael Satria Nugraha**

NRP 06311840000032

Dosen Pembimbing

**Ulil Azmi, S.Si, M.Si**

NIP 1990201912069

**Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc**

NIP 1991202012059

**PROGRAM STUDI SARJANA SAINS AKTUARIA**

DEPARTEMEN AKTUARIA

FAKULTAS SAINS DAN ANALITIKA

DATA INSTITUT TEKNOLOGI SEPULUH

NOPEMBER SURABAYA

2022



TUGAS AKHIR - KA 184801

**PEMBENTUKAN PORTOFOLIO OPTIMAL  
HIERARCHICAL RISK PARITY DAN NESTED  
CLUSTERED OPIMIZATION TERHADAP FORECASTING  
LSTM HARGA CRYPTOCURRENCY TRENDING  
TWITTER**

Nathanael Satria Nugraha

NRP 06311840000032

Dosen Pembimbing

Ulil Azmi, S.Si, M.Si

NIP 1990201912069

Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc

NIP 1991202012059

PROGRAM STUDI SARJANA SAINS AKTUARIA

DEPARTEMEN AKTUARIA

FAKULTAS SAINS DAN ANALITIKA

DATA INSTITUT TEKNOLOGI SEPULUH

NOPEMBER SURABAYA

2022



**FINAL PROJECT - KA 184801**

**ESTABLISHMENT OF OPTIMAL PORTFOLIO USING HRP  
AND NCO BASED ON LSTM FORECASTED  
CRYPTOCURRENCY PRICE TRENDING ON TWITTER**

**Nathanael Satria Nugraha**

**NRP 06311840000032**

**Advisor**

**Ulil Azmi, S.Si, M.Si**

**NIP 1990201912069**

**Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc**

**NIP 1991202012059**

**STUDY PROGRAM BACHELOR OF ACTUARIAL SCIENCE  
DEPARTMENT OF ACTUARIAL SCIENCE  
FACULTY OF SCIENCE AND DATA ANALYTICS  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2022**

## **LEMBAR PENGESAHAN**

### **PEMBENTUKAN PORTOFOLIO OPTIMAL *HIERARCHICAL RISK PARITY* DAN *NESTED CLUSTERED OPIMIZATION* TERHADAP *FORECASTING LSTM* *HARGA CRYPTOCURRENCY TRENDING TWITTER***

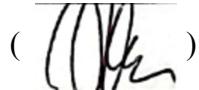
#### **TUGAS AKHIR**

Diajukan untuk memenuhi salah satu syarat  
memperoleh gelar Sarjana Ilmu Aktuaria pada  
Program Studi Sarjana Sains Aktuaria  
Departemen Aktuaria  
Fakultas Sains dan Analitika Data  
Institut Teknologi Sepuluh Nopember

Oleh: **Nathanael Satria Nugraha**

NRP. 063118 4000 0032

Disetujui oleh Tim Penguji Tugas Akhir:

- |  |               |   |
|--|---------------|---|
| 1. Ulil Azmi, S.Si, M.Si                       | Pembimbing    | (  |
| 2. Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc | Ko-Pembimbing | (  |
| 3. Dr. R. Mohamad Atok, S.Si., M.Si            | Penguji       | (  |
| 4. Imam Safawi Ahmad, S.Si., M.Si              | Penguji       | (  |

SURABAYA

Juli, 2022

(“*Halaman ini sengaja dikosongkan*”)

## **APPROVAL SHEET**

### **ESTABLISHMENT OF OPTIMAL PORTFOLIO USING HRP AND NCO BASED ON LSTM FORECASTED CRYPTOCURRENCY PRICE TRENDING ON TWITTER**

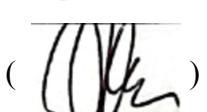
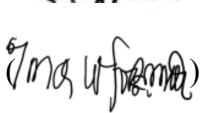
#### **FINAL PROJECT**

Submitted to fulfill one of the requirement  
for obtaining a degree Bachelor of Actuarial Science at  
Undergraduate Study Program of Actuarial Science  
Department of Actuarial Science  
Faculty of Science and Data Analytics  
Institut Teknologi Sepuluh Nopember

By: **Nathanael Satria Nugraha**

NRP. 063118 4000 0032

Approved by Final Project Examiner Team:

- |  |            |   |
|--|------------|---|
| 1. Ulil Azmi, S.Si, M.Si                       | Advisor    | (  |
| 2. Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc | Co-Advisor | (  |
| 3. Dr. R. Mohamad Atok, S.Si., M.Si            | Examiner   | (  |
| 4. Imam Safawi Ahmad, S.Si., M.Si              | Examiner   | (  |

SURABAYA

July, 2022

(“*Halaman ini sengaja dikosongkan*”)

## **PERNYATAAN ORISINALITAS**

Yang Bertanda tangan di bawah ini:

Nama mahasiswa / NRP : Nathanael Satria Nugraha / 06311840000032

Departemen : Aktuaria

Dosen Pembimbing : Ulil Azmi, S.Si, M.Si / 1990201912069

Galuh O. S. , S.Si, M.Si, M.Act.Sc / 1991202012059

Dengan ini menyatakan bahwa Tugas Akhir dengan judul “Pembentukan Portofolio Optimal *Hierarchical Risk Parity* dan *Nested Clustered Optimization* Terhadap Forecasting *LSTM Cryptocurrency Trending Twitter*” adalah hasil karya sendiri, bersifat orisinal, dan ditulis dengan mengikuti kaidah penulisan ilmiah.

Bilamana di kemudian hari ditemukan ketidaksesuaian dengan pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku di Institut Teknologi Sepuluh Nopember.

Surabaya, Juli 2022

Mengetahui

Dosen Pembimbing



(Ulil Azmi, S.Si, M.Si)

NIP. 1990201912069

Mahasiswa,



(Nathanael Satria Nugraha)

NRP. 06311840000032

Dosen Ko-Pembimbing



(Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc)

NIP 1991202012059

(“Halaman ini sengaja dikosongkan”)

## STATEMENT OF ORIGINALITY

Yang Bertanda tangan di bawah ini:

Nama mahasiswa / NRP : Nathanael Satria Nugraha / 06311840000032

Departemen : Aktuaria

Dosen Pembimbing : Ulil Azmi, S.Si, M.Si / 1990201912069

Galuh O. S. , S.Si, M.Si, M.Act.Sc / 1991202012059

Hereby declare that the Final Project with the title of “Formation of Optimal Portfolio Using HRP and NCO Based on LSTM Forecasted Cryptocurrency Price Trending on *Twitter*” is the result of my own work, is original, and is written by following the rules of scientific writing.

If in the future there is a discrepancy with statement then I am willing to accept sanctions in accordance with the provisions that apply at Institut Teknologi Sepuluh Nopember.

Surabaya, July 2022

Acknowledge

Advisor

Student,



(Ulil Azmi, S.Si, M.Si)

NIP. 1990201912069



(Nathanael Satria Nugraha)

NRP. 06311840000032

Co-Advisor



(Galuh Oktavia Siswono, S.Si, M.Si, M.Act.Sc)

NIP 1991202012059

(“Halaman ini sengaja dikosongkan”)

**PEMBENTUKAN PORTOFOLIO OPTIMAL *HIERARCHICAL RISK PARITY* DAN *NESTED CLUSTERED OPIMIZATION* TERHADAP FORECASTING LSTM HARGA CRYPTOCURRENCY TRENDING TWITTER**

**Nama Mahasiswa** : Nathanael Satria Nugraha  
**NRP** : 06311840000032  
**Departemen** : Aktuaria  
**Dosen Pembimbing** : Ulil Azmi, S.Si, M.Si  
Galuh O. S. , S.Si, M.Si, M.Act.Sc

### **Abstrak**

Investasi meningkat di era pandemi, dimana tercatat kenaikan sebesar 2 juta investor menurut data *Single Investor Identification* dari 4 juta menjadi 6 juta. Salah satu investasi yang sedang ramai adalah investasi *cryptocurrencies*. *Cryptocurrencies* adalah mata uang digital yang bisa digunakan untuk bertransaksi. Banyak orang tertarik dengan investasi ini karena memberikan *return* yang besar. Hal itu semakin ramai dengan adanya media sosial yang sering membagikan hal-hal manis dari investasi *cryptocurrencies*. Namun *cryptocurrencies* memiliki volatilitas yang tinggi. Karena itu diperlukan analisis yang tepat untuk bisa berinvestasi di *cryptocurrencies*. *Forecasting* adalah salah satu metode yang bisa meramalkan harga di masa yang akan datang. Penelitian ini memanfaatkan data yang didapat dari *Twitter* yang membahas *cryptocurrencies*. Didapatkan 10 *crypto* yang sedang trending di *Twitter* pada periode 2021. *Cryptocurrencies* tersebut adalah Arweave (AR-USD), REN (REN-USD), ThunderCore (TT-USD), Bitcoin (BTC-USD), TerraUSD (UST-USD), Amp (AMP-USD), Ethereum (ETH-USD), Aragon (ANT-USD), Kin (KIN-USD), Huobi Token (HT-USD). Kemudian dilakukan *forecasting* menggunakan metode *Long Short-Term Memory* (LSTM) terhadap harga *closing cryptocurrencies* terpilih untuk 30 hari pertama bulan 2022. Setelah didapatkan hasil *forecasting* tersebut disusunlah portofolio optimal menggunakan *machine learning algorithm* yakni metode *Hierarchical Risk Parity* (HRP) dan *Nested Clustered Optimization* (NCO). Pada optimasi menggunakan metode HRP didapatkan bahwa portofolio tidak terdiversifikasi dengan satu *crypto* yang mendominasi portofolio yaitu UST-USD, sehingga dibentuk alternatif portofolio HRP dengan menghilangkan UST-USD. Pada portofolio menggunakan metode NCO portofolio cukup terdiversifikasi dikarenakan portofolio tersusun dari beberapa *crypto*. Berdasarkan nilai *sharpe ratio* dan *sortino ratio* portofolio menggunakan NCO lebih baik dibanding portofolio dengan menggunakan metode HRP maupun alternatif HRP dengan nilai *sharpe ratio* 0,105 dan nilai *sortino ratio* 3,744 dibandingkan dengan portofolio HRP dan alternatif HRP dengan *sharpe ratio* sebesar 0,008 dan 0,075 serta *sortino ratio* sebesar 2,592 dan 2,973. Dapat disimpulkan bahwa pembentukan portofolio optimal menggunakan metode NCO lebih optimal dibandingkan dengan HRP maupun alternatif HRP.

**Kata Kunci :** *Cryptocurrencies*, *Long Short-Term Memory*, Portofolio Optimal, *Hierarchical Risk Parity*, *Nested Clustered Optimization*, *Sharpe Ratio*, *Sortino Ratio*

(“Halaman ini sengaja dikosongkan”)

# **ESTABLISHMENT OF OPTIMAL PORTFOLIO USING HRP AND NCO BASED ON LSTM FORECASTED CRYPTOCURRENCY PRICE TRENDING ON TWITTER**

**Nama Mahasiswa : Nathanael Satria Nugraha**  
**NRP : 0631184000032**  
**Departemen : Aktuaria**  
**Dosen Pembimbing : Ulil Azmi, S.Si, M.Si**  
**Galuh O. S. , S.Si, M.Si, M.Act.Sc**

## **Abstract**

There was an increase in investment in the pandemic era, which recorded an increase of 2 million investors according to Single Investor Identification data from the previous 4 million to 6 million. One of the investment that is currently trending is invest in the cryptocurrencies. Cryptocurrencies are digital currencies that can be used for transactions. Many people are interested in this investment because it promises a large return. This is exacerbated by the existence of social media which often shares good things from investing in cryptocurrencies. But on the other hand cryptocurrencies have very high volatility. Therefore, proper analysis is needed to be able to invest in cryptocurrencies. Forecasting is one method that can predict future prices. This study utilizes data obtained from *Twitter* which discusses cryptocurrencies. There are 10 cryptos that are trending on *Twitter* in the 2021 period. The cryptos are Arweave(AR-USD), REN(REN-USD), ThunderCore(TT-USD), Bitcoin(BTC-USD), TerraUSD(UST-USD), Amp(AMP-USD), Ethereum(ETH-USD), Aragon(ANT-USD), Kin(KIN-USD), Huobi Token(HT-USD). Then forecasting is carried out using the Long Short-Term Memory (LSTM) method on the closing prices of selected cryptocurrencies for the first 30 days of 2022. After obtaining the value from the forecasting results, an optimal portfolio is formed using a machine learning algorithm using the Hierarchical Risk Parity (HRP) method and Nested Clustered Optimization (NCO). In optimization using the HRP method, it was found that the portfolio was not diversified with one crypto that dominates the portfolio, namely UST-USD, so an alternative HRP portfolio was formed by eliminating UST-USD. In the portfolio using the NCO method the portfolio is quite diversified because the portfolio is composed of several cryptocurrencies. Based on the sharpe ratio and sortino ratio values, the portfolio using NCO is better than the portfolio using the HRP method or alternative HRP with a sharpe ratio value of 0,105 and a sortino ratio value of 3,744 compared to the HRP portfolio and alternative HRP with a sharpe ratio of 0,008 and 0,0747 and sortino ratio of 2,592 and 2,973. It can be concluded that the formation of an optimal portfolio using the NCO method is more optimal than the HRP or alternative HRP.

**Keyword:** Cryptocurrencies, *Twitter*, Long Short-Term Memory, Optimal Portfolio, Hierarchical Risk Parity, Nested Clustered Optimization, Sharpe Ratio, Sortino Ratio

(“*Halaman ini sengaja dikosongkan*”)

## KATA PENGANTAR

Puji Syukur penulis panjatkan kehadirat Tuhan Yesus Kristus atas berkat, kasih dan penyertaan-Nya penulis bisa menyelesaikan tugas akhir yang berjudul “Pembentukan Portofolio Optimal *Hierarchical Risk Parity* dan *Nested Clustered Optimization* Terhadap *Forecasting LSTM Harga Cryptocurrency Trending Twitter*”.

Tugas akhir ini dapat selesai tidak terlepas dari bantuan dan *support* dari berbagai pihak. Karena hal tersebut penulis ingin menyampaikan terima kasih kepada:

1. Tuhan Yesus yang selalu menyertai dan memberikan pengharapan dan petunjuk selama proses penggerjaan Tugas Akhir ini.
2. Bapak Dr. Drs. Soehardjoepri, M.Si., selaku Kepala Departemen Aktuaria Fakultas Sains dan Analitika Data Institut Teknologi Sepuluh Nopember.
3. Ibu Ulil Azmi, S.Si, M.Si selaku dosen pembimbing sekaligus dosen wali dari pernulis dan Ibu Galuh Oktavia Siswono S.Si, M.Si, M.Act.Sc selaku dosen pembimbing yang selalu memberikan bimbingan, saran serta motivasi selama penyusunan Tugas Akhir ini dan kepada Bapak R. Mohamad Atok, M.Si, Ph.D dan Bapak Imam Safawi Ahmad, S.Si, M.Si selaku dosen penguji yang telah memberikan masukan kepada penulis mengenai Tugas Akhir.
4. Ibu Pratnya Paramitha Oktaviana, S.Si, M.Si dan Bapak Wawan Hafid Syaifuddin, S.Si, M.Si, M.Act.Sc selaku dosen Departemen Aktuaria FSAD ITS yang telah memberikan ilmu yang bermanfaat kepada penulis.
5. Kedua orang tua penulis yang selalu memberikan dukungan baik moral maupun materi yang selalu berkelanjutan sehingga penulis bisa sampai pada titik ini.
6. Ivan, Eric, Kelvin, dan Rayhan yang telah membantu penulis menyusun Tugas Akhir ini ketika penulis masih magang dan tidak lupa untuk bersenang-senang serta bermain caps di malam hari dengan tetap saling mengingatkan untuk menyelesaikan TA.
7. Rachel Cahyani Ardhika Wiyata yang terus memberikan support dan semangat kepada penulis selama penyusunan Tugas Akhir ini serta selalu ada bagi penulis baik di saat tertinggi maupun terendah, serta kepada pihak lainnya yang telah berjasa kepada penulis selama melakukan penyusunan Tugas Akhir ini tetapi tidak dapat disebutkan satu per satu dalam tulisan ini.

Penulis juga menyadari bahwa penyusunan Tugas Akhir ini banyak kekurangan. Maka dari itu, penulis sangat menerima kritik dan saran yang membangun demi hasil yang lebih baik kedepannya dan semoga Tugas Akhir ini dapat bermanfaat bagi semua pihak.

Surabaya, 20 Juli 2022  
Hormat Kami,

Penulis

(“*Halaman ini sengaja dikosongkan*”)

## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	iii
<b>APPROVAL SHEET .....</b>	v
<b>PERNYATAAN ORISINALITAS .....</b>	vii
<b>STATEMENT OF ORIGINALITY .....</b>	ix
<b>Abstrak .....</b>	xi
<b>Abstract .....</b>	xiii
<b>KATA PENGANTAR .....</b>	xv
<b>DAFTAR ISI .....</b>	xvii
<b>DAFTAR GAMBAR .....</b>	xix
<b>DAFTAR TABEL .....</b>	xxi
<b>DAFTAR LAMPIRAN .....</b>	xxiii
<b>BAB I PENDAHULUAN .....</b>	1
1.1    Latar Belakang .....	1
1.2    Rumusan Masalah .....	3
1.3    Tujuan Penelitian.....	4
1.4    Manfaat Penelitian.....	4
1.5    Batasan Masalah.....	4
<b>BAB II TINJAUAN PUSTAKA .....</b>	5
2.1    Hasil Penelitian Terdahulu .....	5
2.2    Investasi.....	5
2.3 <i>Cryptocurrencies</i> .....	6
2.4    Data Mining .....	6
2.5    Machine Learning .....	8
2.6    Recurrent Neural Network (RNN) .....	9
2.7    Statistika Deskriptif.....	10
2.8 <i>Long Short-term Memory (LSTM)</i> .....	10
2.9    Evaluasi Hasil <i>Forecasting</i> .....	13
2.9.1    Mean Squared Error (MSE) .....	13
2.9.2    Mean Absolute Percentage Error (MAPE) .....	13
2.10 <i>Optimasi Portofolio</i> .....	14
2.10.1    Hierarchical Risk Parity (HRP).....	14
2.10.2 <i>Nested Clustered Optimization (NCO)</i> .....	16
2.11    Analisis Kinerja Portofolio.....	17
2.11.1 <i>Sharpe Ratio</i> .....	17
2.11.2 <i>Sortino Ratio</i> .....	17
<b>BAB III METODOLOGI PENELITIAN .....</b>	19
3.1    Sumber Data dan Variabel Penelitian .....	19
3.2    Langkah Analisis.....	19

<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	23
4.1    Pengumpulan Data.....	23
4.1.1    Pengambilan Data pada <i>Twitter</i> .....	23
4.1.2    Praproses Data .....	23
4.1.3    Data <i>Cryptocurrency Trending Twitter</i> .....	25
4.2    Statistika Deskriptif .....	26
4.3 <i>Forecasting</i> menggunakan <i>Stacked LSTM</i> .....	28
4.3.1    Pelatihan data <i>Training</i> dan <i>Testing</i> .....	28
4.3.2    Hasil Peramalan Menggunakan <i>Stacked LSTM</i> .....	31
4.4    Pembentukan Portofolio Optimal menggunakan <i>Machine Learning</i> .....	33
4.4.1 <i>Hierarchical Risk Parity</i> .....	33
4.4.2    Alternatif <i>Hierarchical Risk Parity</i> .....	36
4.4.3 <i>Nested Clustered Optimization</i> .....	38
4.5    Perhitungan <i>Sharpe</i> dan <i>Sortino Ratio</i> .....	39
4.5.1 <i>Sharpe Ratio</i> .....	41
4.5.2 <i>Sortino Ratio</i> .....	41
<b>BAB V KESIMPULAN DAN SARAN .....</b>	43
5.1    Kesimpulan.....	43
5.2    Saran .....	43
<b>DAFTAR PUSTAKA .....</b>	45
<b>LAMPIRAN .....</b>	47
<b>BIODATA PENULIS .....</b>	75

## DAFTAR TABEL

<b>Tabel 4.1</b>	Perbedaan <i>Tweet</i> Sebelum dan Sesudah Dilakukan Praproses Data .....	24
<b>Tabel 4.2</b>	Perbedaan <i>Tweet</i> Sebelum dan Sesudah Dilakukan <i>Filtering</i> .....	24
<b>Tabel 4.3</b>	Hasil Tokenisasi yang Dilakukan .....	25
<b>Tabel 4.4</b>	Sepuluh <i>Crypto</i> yang Masuk ke <i>Trending Twitter</i> pada Tahun 2021.....	25
<b>Tabel 4.5</b>	Hasil Statistika Deskriptif untuk tiap <i>Crypto</i> yang Digunakan .....	26
<b>Tabel 4.6</b>	Nilai MAPE dan MSE <i>trial and error</i> pada BTC.....	28
<b>Tabel 4.7</b>	Kombinasi Parameter <i>Forecasting</i> yang Digunakan.....	28
<b>Tabel 4.8</b>	Range Nilai MAPE .....	29
<b>Tabel 4.9</b>	Hasil MAPE dan MSE dari fitting yang telah dilakukan .....	29
<b>Tabel 4.10</b>	Korelasi dari Tiap Aset yang Digunakan Dalam Pembentukkan Portofolio .....	33
<b>Tabel 4.11</b>	Hasil Pembobotan pada tiap <i>Crypto</i> Menggunakan Metode <i>Hierarchical Risk Parity</i> (HRP).....	34
<b>Tabel 4.12</b>	Hasil Pembobotan Alternatif pada tiap <i>Crypto</i> Menggunakan Metode <i>Hierarchical Risk Parity</i> .....	37
<b>Tabel 4.13</b>	Hasil Pembobotan pada tiap <i>Crypto</i> menggunakan Metode <i>Nested Clustered Optimization</i> (NCO) .....	38
<b>Tabel 4.14</b>	Alokasi untuk Masing-masing Aset dalam Portofolio.....	39
<b>Tabel 4.15</b>	Perkembangan dari tiap portofolio .....	40
<b>Tabel 4.16</b>	Nilai <i>Sharpe Ratio</i> dari tiap portofolio .....	41
<b>Tabel 4.17</b>	Nilai <i>Sortino Ratio</i> dari tiap Portofolio .....	41

(“Halaman ini sengaja dikosongkan”)

## DAFTAR GAMBAR

<b>Gambar 2.1</b>	Proses filtering .....	7
<b>Gambar 2.2</b>	Proses tokenizing .....	8
<b>Gambar 2.3</b>	Arsitektur RNN .....	9
<b>Gambar 2.4</b>	Looping pada Arsitektur RNN .....	10
<b>Gambar 2.5</b>	Arsitektur looping pada LSTM (Christopher 2015).....	11
<b>Gambar 2.6</b>	Arsitektur dari Stacked LSTM .....	13
<b>Gambar 2.7</b>	Contoh Ilustrasi Urutan <i>Tree Clustering</i> .....	15
<b>Gambar 3.1</b>	Diagram Analisis Data .....	21
<b>Gambar 4.1</b>	Contoh Hasil Pengambilan Data pada Twitter .....	21
<b>Gambar 4.2</b>	Plot Harga <i>Historical</i> pada: (a) Arweave, (b) Ren .....	26
<b>Gambar 4.3</b>	Plot Hasil Peramalan <i>Long Short-Term Memory</i> pada Data <i>Testing</i> (a) Arweave, (b) Ren, (c) Thundercoin, (d) Bitcoin, (e) Terra, (f) AMP, (g) Ethereum .....	30
<b>Gambar 4.4</b>	Plot Hasil Peramalan <i>Long Short-Term Memory</i> untuk 30 hari pada bulan januari 2022: (a) Arweave, (b) Ren, (c) Thundercoin, (d) Bitcoin.....	31
<b>Gambar 4.5</b>	Hasil <i>Tree Clustering</i> Masing-Masing <i>Crypto</i> Menggunakan HRP .....	33
<b>Gambar 4.6</b>	Hasil Diagonalisasi Kuasi menggunakan Metode HRP .....	34
<b>Gambar 4.7</b>	Visualisasi Bobot tiap Crypto pada Portofolio HRP .....	35
<b>Gambar 4.8</b>	Kontribusi Risiko tiap Aset terhadap Portofolio HRP .....	35
<b>Gambar 4.9</b>	Hasil <i>Tree Clustering</i> Masing-masing <i>Crypto</i> menggunakan Metode Alternatif HRP ..	36
<b>Gambar 4.10</b>	Hasil Diagonalisasi Kuasi menggunakan Metode Alternatif HRP .....	36
<b>Gambar 4.11</b>	Visualisasi Bobot tiap <i>Crypto</i> pada Portofolio Alternatif HRP .....	37
<b>Gambar 4.12</b>	Kontribusi Risiko tiap Aset terhadap Portofolio Alternatif HRP .....	38
<b>Gambar 4.13</b>	Visualisasi Bobot tiap <i>Crypto</i> pada Portofolio NCO .....	39
<b>Gambar 4.14</b>	Kontribusi Risiko Tiap Aset terhadap Portofolio NCO .....	39
<b>Gambar 4.15</b>	Perkembangan tiap <i>Crypto</i> dalam Portofolio HRP .....	40
<b>Gambar 4.16</b>	Perkembangan Portofolio HRP .....	40
<b>Gambar 4.17</b>	Perkembangan tiap <i>Crypto</i> dalam Portofolio Alternatif HRP .....	40
<b>Gambar 4.18</b>	Perkembangan Portofolio Alternatif HRP .....	40
<b>Gambar 4.19</b>	Perkembangan tiap <i>Crypto</i> dalam Portofolio NCO .....	40
<b>Gambar 4.20</b>	Perkembangan Portofolio NCO .....	40

(“*Halaman ini sengaja dikosongkan*”)

## DAFTAR LAMPIRAN

<b>Lampiran 1</b>	Syntax Mining Data Twitter pada <i>python Jupyter Notebook</i> .....	47
<b>Lampiran 2</b>	Syntax Forecasting LSTM pada <i>software Jupyter Notebook</i> .....	50
<b>Lampiran 3</b>	Syntax Pembentukan Portofolio Optimal Menggunakan Metode HRP .....	54
<b>Lampiran 4</b>	Syntax Pembentukan Portofolio Optimal Menggunakan Metode NCO .....	56
<b>Lampiran 5</b>	Harga <i>Closing Cryptocurrency</i> (USD) .....	58
<b>Lampiran 6</b>	Nilai MAPE dan MSE setiap kombinasi.....	62
<b>Lampiran 7</b>	Hasil Pengujian Data <i>Testing</i> pada tiap <i>Crypto</i> .....	63
<b>Lampiran 8</b>	Hasil Forecasting Cryptocurrency (USD).....	67
<b>Lampiran 9</b>	HasilPerkembangan Portofolio HRP (USD).....	69
<b>Lampiran 10</b>	HasilPerkembangan Portofolio Alternatif HRP (USD) .....	71
<b>Lampiran 11</b>	HasilPerkembangan Portofolio NCO (USD) .....	73

(“Halaman ini sengaja dikosongkan”)

## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Investasi merupakan kegiatan menyisihkan uang di masa sekarang dengan harapan menjadi jumlah yang lebih besar lagi di masa depan. Banyak orang berinvestasi saat ini agar mereka bisa memiliki kehidupan bebas finansial di usia yang mereka inginkan. Investasi memiliki beberapa jenis ataupun bentuk. Contoh yang sering masyarakat ketahui adalah properti, saham, surat berharga, emas atau *cryptocurrencies*. Kecenderungan dari jenis investasi adalah semakin besar risiko maka semakin besar pula ekspektasi *return* yang didapat. Begitu pula sebaliknya semakin kecil risiko maka ekspektasi *return* yang didapatkan akan semakin kecil. Orang-orang yang akan berinvestasi terkadang mengabaikan bagaimana mengelola risiko tersebut.

Di era pandemi ini investasi pada saham meningkat pesat dimana sebelumnya terdapat kurang lebih 4 juta orang investor menurut *Single Investor Identification* (SID) menjadi sekitar 6 juta investor. Menurut Dosen dan Direktur Eksekutif Pendidikan SBM ITB Donald, peningkatan jumlah investor saham di Indonesia mencapai sekitar 50 persen sejak 2020. Di era pandemi ini terdapat instrumen investasi yang ramai diperbincangkan di masyarakat yaitu *cryptocurrencies*. Hal itu diakibatkan oleh besarnya *return* yang akan didapatkan dibanding instrumen investasi biasa. Ditambah lagi di saat pandemi kebanyakan instrumen investasi cenderung bergerak lambat.

*Cryptocurrencies* sendiri dapat diartikan sebagai sebuah mata uang digital. Karena sifat digitalnya, maka ia tidak memiliki bentuk fisik. Konsep uang elektronik ini sendiri telah diperkenalkan sejak 1998 oleh Wei Dai. Mata uang crypto pertama yang diluncurkan adalah bitcoin pada tahun 2009 oleh Satoshi Nakamoto. Terdapat banyak jenis *cryptocurrencies* yang saat ini beredar, contohnya adalah Bitcoin, Ethereum, Solana, Dogecoin dan masih banyak lagi.

Salah satu hal yang membuat *cryptocurrencies* ramai di masyarakat adalah ketika bitcoin menembus nilai tukar tertingginya yaitu USD 10000 per koin pada tahun 2017. Tetapi tidak lama kemudian nilainya kembali jatuh ke angka USD 3000 untuk satu koin. Karena nilainya yang bisa berubah dengan cepat hal itu mengakibatkan *cryptocurrencies* memiliki risiko yang sangat tinggi. Karena *cryptocurrencies* adalah aset yang memiliki risiko tinggi, maka investor perlu untuk memahami dan mengerti cara kerja dari investasi ini. Ketika investor hanya ikut membeli karena sedang terjadi tren, hal itu bisa mengakibatkan investor tersebut rugi dan bukan malah mendapatkan keuntungan yang didambakan di awal. Salah satu pemicu munculnya keinginan untuk tidak ketinggalan investasi crypto adalah media sosial seperti *Twitter*.

*Twitter* adalah media sosial yang berasal dari Amerika dimana pengguna memposting dan berinteraksi dengan pesan yang disebut sebagai “*tweet*”. Salah satu fitur yang menarik dari *Twitter* adalah fitur *trending*. *Trending* di *Twitter* didapatkan ketika banyak orang menggunakan tagar yang terkait, tak terkecuali *cryptocurrencies*. Banyak orang yang tertarik dengan *cryptocurrencies* melakukan update di *Twitter*. Menurut Eren dkk (2021), harga *crypto* bisa tiba-tiba meningkat ketika ia menjadi *trending* di *Twitter* atau orang berpengaruh melakukan *tweet* mengenai *crypto* tersebut. Karena itu orang berharap mendapatkan keuntungan dengan selalu memantau pergerakan trending *crypto* di *Twitter*. Namun untuk mendapatkan keuntungan yang bagus tidak cukup hanya dengan mengandalkan perilaku di media sosial.

Diperlukan suatu metode untuk mengetahui trending *cryptocurrencies* di *Twitter*. Metode yang bisa digunakan adalah *data mining*. *Data mining* dapat menarik data dari

*Twitter*, menyimpan dan mengolah untuk mendapatkan informasi yang diinginkan. Menurut Beck (2020) modul yang dapat digunakan untuk pengambilan data dari *Twitter* adalah modul snscreape pada python. Modul ini memiliki keuntungan yaitu tidak dikenai batasan *tweepy*. Setelah didapatkan *trending* dari *crypto*, diperlukan analisis yang tepat untuk dapat menghasilkan keuntungan yang maksimal dari data yang sudah diperoleh.

Salah satu analisis yang dapat dilakukan adalah dengan melakukan analisis *forecasting* atau memprediksi harga di masa depan. *Forecasting* sendiri menggunakan data historis sebagai acuan. Terdapat beberapa faktor dalam melakukan *forecasting*. Yang pertama adalah waktu, lalu berdasarkan fungsi dan tujuan dan yang ketiga adalah berdasarkan ketersediaan data. Saat ini terdapat beberapa metode dalam melakukan *forecasting*. Dalam melakukan *forecasting* untuk harga di masa yang akan datang metode yang paling sering digunakan adalah metode *time series analysis*. Terdapat dua cara untuk melakukan *time series analysis*, yaitu cara tradisional yaitu menggunakan *Autoregressive Integrated Moving Average* (ARIMA) dan menggunakan *machine learning* dengan *neural network* dan *Support Vector Machine* (SVM) (Arissinta dkk, 2022). Pada penelitian ini metode yang akan digunakan adalah dengan menggunakan *machine learning* dengan *artificial neural network*.

*Neural network* adalah kecerdasan buatan untuk melakukan proses dan memberikan output. Banyak sekali hal yang dapat dapat dilakukan oleh *neural network* salah satunya adalah *forecasting*. Salah satu metode untuk melakukan *forecasting* dengan menggunakan *artificial neural network* adalah metode *Long Short-term Memory* (LSTM). LSTM adalah sebuah algoritma yang berkaitan dengan *deep learning*. Menurut Kamal dkk (2020) metode LSTM memiliki kemampuan untuk menyimpan memori jangka panjang bersamaan dengan pemahaman korelasi antara data. Dimana jenis yang akan dipergunakan adalah model *stacked LSTM* dikarenakan menurut Azzam dkk (2021) memiliki keuntungan dalam menangani *error* dengan lebih baik.

Setelah kita bisa memprediksi harga dari *crypto* di masa yang akan datang hal selanjutnya yang dilakukan adalah berinvestasi. Ketika kita berinvestasi dan membeli asset *cryptocurrencies* maka kita akan membentuk suatu portofolio. Portofolio sendiri adalah sekumpulan aset investasi yang dimiliki, dalam penelitian ini berarti portofolio adalah sekumpulan asset *crypto* yang dimiliki investor. Tentu semua orang menginginkan agar portofolionya selalu mendapatkan *return* atau imbal hasil yang positif. Tetapi tentu dalam pembuatan portofolio diperlukan analisis terhadap risiko dan *return* yang akan didapatkan dari portofolio tersebut. Dikarenakan *crypto* memiliki volatilitas yang sangat tinggi dibutuhkan bantuan *machine learning* untuk menyusun portofolio yang optimal. Metode yang dapat digunakan untuk pembentukan portofolio optimal dengan *machine learning algorithm* adalah dengan menggunakan metode *Hierarchical Risk Parity* dan *Nested Clustered Optimization*.

*Hierarchical Risk Parity* (HRP) adalah sebuah metode yang memanfaatkan *machine learning* dalam pembentukannya. Menurut Prayut (2019) Dalam pembentukannya metode HRP akan menggunakan hubungan *hierarchical* antara aset yang akan digunakan dan membuat diversifikasi portofolio yang sesuai. Metode ini berbeda dengan pembentukan portofolio dengan cara tradisional dimana harus menggunakan *inverse covariance matrix* yang terkadang menambah *error* yang didapat, metode ini justru menghindari hal tersebut.

*Nested Clustered Optimization* (NCO) adalah metode optimasi yang menawarkan penyelesaian terhadap data yang memiliki volatilitas yang tinggi. Sama dengan HRP, NCO berusaha menyelesaikan permasalahan terhadap ketidakstabilan kovarians yang ada pada optimasi modern seperti Markowitz (Sjostrand, 2020). Setelah portofolio dapat terbentuk, diperlukan sebuah pengukuran untuk membandingkan hasil dari dua portofolio yang telah dibentuk.

Kinerja portofolio merupakan salah satu hal yang harus dipertimbangkan ketika ingin melakukan investasi. Kinerja portofolio dapat dilihat dengan menggunakan beberapa pengukuran seperti ukuran *Sharpe*, dan *Sortino*. Indeks pengukuran tersebut ditujukan untuk mengetahui bagaimana kinerja dari tiap saham yang ada pada portofolio. Pada penelitian ini pengukuran kinerja akan menggunakan rasio sharpe dan sortino. *Sharpe ratio* adalah pengukuran kinerja portofolio berdasarkan imbal hasil terhadap volatilitasnya. Sedangkan *Sortino ratio* adalah alternatif dari *sharpe ratio* karena adanya fluktuasi harga yang terjadi. (Luca, 2020).

Pada studi oleh Zrara (2020). Pada penelitian ini, dilakukan analisis *forecasting* terhadap harga saham di pasar Maroko. Saham yang digunakan merupakan enam saham pilihan penulis. Analisis *forecasting* dilakukan dengan menggunakan metode *Long Short-Term Memory* (LSTM). Hasil *forecasting* menunjukkan bahwa LSTM bisa memprediksi harga dengan baik. Hal tersebut ditunjukkan dengan nilai akurasi *forecasting* dari tiap aset yang lebih dari 93%.

Pada studi lainnya oleh Hrytsiuk, Babych, dan Bachyshyna (2019) dilakukan pembentukan portofolio optimal pada *cryptocurrency* dengan menggunakan Metode *Value-At-Risk*. *Crypto* yang akan digunakan adalah enam crypto paling umum yaitu Bitcoin, Bitcoin Cash, Litecoin, XRP, Ethereum, dan Nem. Data yang digunakan adalah data *historical* dari 5 Juli 2018 hingga 4 Juli 2019. Hasil menunjukkan bahwa bitcoin mendapatkan porsi yang paling besar sehingga perlu dilakukan limitasi pada bobot bitcoin.

Pada penelitian lainnya yang berjudul oleh Kaczmarek dan Perez (2021). Dilakukan pembentukan portofolio optimal dengan menggunakan metode HRP pada data saham SP500. Didapatkan bahwa optimisasi menggunakan metode HRP menunjukkan hasil yang lebih baik dibanding optimisasi menggunakan *mean variance*.

Pada penelitian sebelumnya oleh Marcos Lopez de Prado pada tahun 2019. Penelitian tersebut mencoba untuk menyelesaikan masalah yang terdapat di optimasi portofolio yang diakibatkan oleh ketidakstabilan kovarians yang memiliki korelasi yang sangat tinggi antar variabelnya. Menggunakan metode NCO didapatkan hasil peningkatan *sharpe ratio* yang signifikan.

Pada penelitian ini peneliti akan menggunakan data *cryptocurrency* peringkat 10 teratas yang paling banyak disebutkan di *Twitter* pada tahun 2021. Data akan diperoleh menggunakan *data mining* pada aplikasi python dengan modul snscreape dan dilanjutkan dengan pengolahan data. Setelah diketahui peringkat 10 teratas *crypto*, dilakukan *forecasting* terhadap masing-masing *crypto* untuk data harian tahun 2022 menggunakan metode LSTM. Selanjutnya, hasil pendugaan harga *cryptocurrencies* akan disusun menjadi portofolio optimal dengan menggunakan metode *Hierarchical Risk Parity* dan *Nested Clustered Optimization*. Portofolio optimal yang diperoleh kemudian dinilai kinerja portfolionya dengan menggunakan rasio sharpe dan sortino yang kemudian akan dibandingkan portofolio mana yang lebih baik berdasarkan nilai *sharpe ratio* dan *sortino ratio* yang dihasilkan.

## 1.2 Rumusan Masalah

Permasalahan yang akan dibahas pada penelitian ini adalah sebagai berikut.

1. Apa saja *crypto* yang masuk ke 10 teratas paling banyak disebutkan di *Twitter* dari *tweet* selama 2021?
2. Bagaimana *forecasting* harga harian masing-masing *crypto* tersebut untuk tahun 2022?
3. Bagaimana perancangan portofolio optimal dari hasil *forecasting* masing-masing *crypto* dengan menggunakan metode *Hierarchical Risk Parity*?
4. Bagaimana perancangan portofolio optimal dari hasil *forecasting* masing-masing *crypto* dengan menggunakan metode *Nested Clustered Optimization*?

5. Bagaimana kinerja dari tiap portofolio optimal yang telah terbentuk menurut *sharpe ratio* dan *Sortino Ratio*?

### 1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dari penelitian ini berdasarkan permasalahan yang telah dirumuskan adalah sebagai berikut.

1. Memperoleh *crypto* yang masuk ke 10 teratas *trending Twitter* dari *tweet* di tahun 2021
2. Mendapatkan hasil *forecasting* harga harian dari masing-masing *crypto* yang *trending* pada tahun 2021 untuk 30 hari pertama 2022.
3. Memperoleh portofolio optimal yang bisa dibentuk dari hasil *forecasting* dengan menggunakan metode *Hierarchical Risk Parity*
4. Memperoleh portofolio optimal yang bisa dibentuk dari hasil *forecasting* dengan menggunakan metode *Nested Clustered Optimization*
5. Mendapatkan kinerja dari tiap portofolio yang telah dibentuk dengan menggunakan *sharpe ratio* dan *sortino ratio*

### 1.4 Manfaat Penelitian

Manfaat yang ingin dicapai dari hasil penelitian ini adalah sebagai berikut.

1. Bagi Investor *Crypto*, sebagai sumber informasi mengenai portofolio optimal yang mungkin bisa digunakan untuk tahun 2022.
2. Bagi Bidang Keilmuan, sebagai referensi dalam analisis *forecasting cryptocurrencies* dengan metode *Long Short-Term Memory* (LSTM)
3. Bagi Bidang Keilmuan, sebagai referensi dalam pembentukan portofolio optimal pada *cryptocurrencies* dengan metode *Hierarchical Risk Parity* (HRP)
4. Bagi Bidang Keilmuan, sebagai referensi dalam pembentukan portofolio optimal pada *cryptocurrencies* dengan metode *Nested Clustered Optimization* (NCO)

### 1.5 Batasan Masalah

Batasan masalah dari penelitian ini adalah sebagai berikut.

1. *Crypto* yang akan dianalisis adalah adalah *crypto* yang merupakan 10 teratas *trending* di *Twitter* pada periode 2021 dengan maksimal *tweet* 72000 per bulan
2. Metode *forecasting* yang akan digunakan adalah *Long Short Term Memory* (LSTM)
3. *Forecasting* dilakukan untuk 30 hari pertama 2022
4. Pembentukan portofolio optimal menggunakan perangkat lunak python dengan metode *Hierarchical Risk Parity* dan *Nested Clustered Optimization*
5. Pengukuran kinerja portofolio menggunakan *Sharpe Ratio* dan *Sortino Ratio*

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Hasil Penelitian Terdahulu

Diperlukan studi literatur dengan penelitian terdahulu yang digunakan sebagai acuan dalam penelitian ini. Pada penelitian oleh Zrara pada tahun 2020 dengan judul “*Portfolio Optimization Using Deep Learning for The Moroccan Market*”, dilakukan forecasting menggunakan metode *Long Short-Term Memory Forecasting*. Forecasting dilakukan terhadap harga penutupan pada beberapa saham di pasar saham maroko. Didapatkan hasil penelitian yaitu hasil *forecasting* menunjukkan bahwa LSTM bisa memprediksi harga dengan baik. Hal tersebut ditunjukkan dengan nilai akurasi forecasting dari tiap aset yang lebih dari 93%.

Pada penelitian kedua oleh Hrytsiuk, Babych, dan Bachyshyna pada tahun 2019 dengan judul “*Cryptocurrency Portfolio Optimization Using Value-At-Risk Measure*”. Metode yang digunakan adalah *Value at Risk* menggunakan *cryptocurrency* untuk pembentukan portofolio optimal. Hasil yang didapatkan yaitu bitcoin mendapatkan porsi yang paling besar sehingga perlu dilakukan limitasi pada bobot bitcoin.

Penelitian selanjutnya dilakukan oleh Kaczmarek Dan Perez pada tahun 2021 dengan judul “*Building portfolios based on machine learning predictions*”. Metode yang digunakan adalah *Hierarchical Risk Parity (HRP)* dan *mean variance*. Portofolio optimal dibentuk terhadap saham *SP500*. Didapatkan hasil bahwa optimisasi menggunakan metode HRP menunjukkan hasil yang lebih baik dibanding optimisasi menggunakan *mean variance*.

Penelitian terakhir dilakukan oleh Prado dengan judul “*A Robust Estimator of The Efficient Frontier*” pada tahun 2019. Dimana dilakukan pembentukan portofolio optimal terhadap 50 sekuritas secara acak. Metode yang digunakan adalah *Nested Clustered Optimization (NCO)* dan *mean variance*. Didapatkan bahwa Menggunakan metode NCO didapatkan hasil peningkatan *sharpe ratio* yang signifikan hingga sebesar 74%.

#### 2.2 Investasi

Menurut Cambridge *dictionary* makna investasi adalah tindakan menempatkan uang, tenaga, waktu, dll menjadi sesuatu untuk membuat keuntungan atau mendapatkan keuntungan, atau uang, tenaga, waktu, dan lain-lain. Menurut Hartono (2017), Investasi adalah penundaan konsumsi sekarang untuk dimasukkan ke aktiva produktif selama periode waktu yang tertentu. Investasi melibatkan penggunaan dana untuk menghasilkan pendapatan tambahan atau produksi yang berkualitas. Atribut penting sebuah investasi adalah bahwa itu berarti 'menunggu' hadiah. Hal ini membutuhkan investasi uang yang diinvestasikan dalam antisipasi bahwa keuntungan ini dapat dicapai di masa depan. Selain itu, investasi adalah transfer modal moneter ke aset yang, selama periode waktu tertentu, akan menghasilkan peningkatan atau pengembalian positif. Dana tersebut termasuk investasi yang aman dan berisiko. Bentuk investasi ini juga dikenal sebagai "Investasi Modal" (Gooding & Briscoe, 2019).

Menurut Zahroh (2015), terdapat beberapa jenis instrumen investasi. Instrumen tersebut seperti saham, obligasi, reksadana, *warrant*, dan *right*. Masing-masing instrumen investasi tersebut mempunyai tingkat risiko dan *return* yang berbeda-beda. Semakin tinggi tingkat risiko yang dimiliki sebuah instrumen investasi maka semakin besar pula ekspektasi return yang didapatkan dari investasi tersebut. Contohnya adalah saham yang memiliki tingkat risiko tinggi maka ekspektasi return yang diharapkan juga tinggi. Sebaliknya dengan reksadana yang memiliki tingkat risiko rendah maka ekspektasi return yang diharapkan juga rendah.

### **2.3 Cryptocurrencies**

*Cryptocurrencies* berasal dari dua kata yaitu kriptografi yang bermakna kode yang rahasia dan *currency* yang memiliki arti yaitu mata uang. Menurut Nurfia (2017) *cryptocurrency* adalah sistem mata uang virtual yang berfungsi seperti mata uang standar yang memungkinkan penggunaanya untuk melakukan pembayaran secara virtual atas transaksi bisnis yang terjadi tanpa biaya jasa. Karena sistemnya yang terdesentralisasi memungkinkan untuk seluruh transaksi antar dua pihak akan tercatat ke dalam sistem dan dapat diverifikasi serta kecepatan sirkulasi yang lebih tinggi. Namun *Cryptocurrency* memiliki sisi lain yaitu volatilitasnya sangat tinggi dimana nilainya dapat berubah naik atau turun dengan cepat. Contoh *cryptocurrencies* yang beredar di masyarakat adalah bitcoin, ethereum, xrp, dogecoin, solana, dll. *Cryptocurrencies* diperkenalkan konsepnya oleh Wei Dai pada tahun 1998 dengan nama *b-money*. Konsep *b-money* mencakup sejumlah fitur khusus yang telah lumrah untuk cryptocurrency saat ini, termasuk persyaratan komputasi untuk memfasilitasi mata uang digital, ketentuan bahwa pekerjaan ini harus diverifikasi oleh komunitas dalam buku besar kolektif, dan memberi penghargaan kepada pekerja atas masukan mereka. Untuk memastikan bahwa transaksi tetap terorganisir, Dai mengusulkan bahwa pembukuan kolektif akan diperlukan, dengan protokol kriptografi yang membantu mengotentikasi transaksi. Proposal ini sangat mirip dengan teknologi blockchain saat ini. Lebih lanjut, Dai menyarankan penggunaan tanda tangan digital, atau kunci publik, untuk otentikasi transaksi dan penegakan kontrak.

Crypto sendiri berjalan diatas sebuah *platform blockchain*. *Blockchain* pada awalnya dikembangkan untuk memenuhi kebutuhan akan sistem yang efisien, hemat biaya, handal, dan aman untuk melakukan dan mencatat transaksi keuangan. Pada awal penggunaannya blockchain dalam bitcoin yang dikembangkan pada tahun 2009 oleh Satoshi Nakamoto. Tidak seperti uang tradisional yang dikeluarkan oleh bank sentral, bitcoin tidak memiliki otoritas pusat dan tidak ada pihak yang mengendalikannya. Alih-alih mengandalkan otoritas pusat untuk memantau, memverifikasi dan menyetujui transaksi dan mengelola pasokan uang, bitcoin didukung oleh jaringan komputer peer to peer.

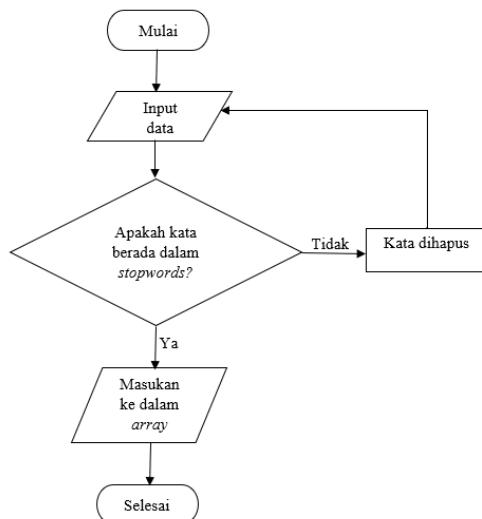
### **2.4 Data Mining**

Menurut Sumathi dkk (2016) *data mining* adalah proses menganalisa data dari berbagai sudut dan mengumpulkan hasilnya menjadi informasi yang berguna. Perangkat lunak *data mining* adalah alat analisis yang memungkinkan pengguna untuk menganalisis data dari berbagai dimensi, mengklasifikasikan data, dan meringkas hubungan antar data. Secara teknis, *data mining* adalah proses menemukan korelasi di antara banyak bidang dalam kumpulan data yang sangat besar. Lima elemen utama dari *data mining* adalah: 1) Memilih, Mengubah dan menyimpan data ke dalam *database*. Pada tahap ini dilakukan pemilihan data serta disimpan ke dalam *database* untuk digunakan atau diolah pada tahap selanjutnya. 2) Menyimpan dan mengolah data dalam sistem *database* multidimensi. Data yang sebelumnya masih dalam bentuk mentah akan diolah. Database multidimensi sendiri didefinisikan sebagai varian dari model relasional yang menggunakan struktur multidimensi untuk mengatur data dan mewakili hubungan antara data. Ketika struktur dipecah menjadi kubus dan kubus dapat menyimpan dan mengakses data dalam batas yang ditentukan. Setiap sel dalam struktur multidimensi berisi data agregat yang terkait dengan elemen umum di setiap dimensi. Data multidimensi ini sangat besar sehingga dapat dianalisis (ke pembuat keputusan). Digunakan untuk berorientasi analisis), hal ini mengintegrasikan dan mempercepat laporan sistem data. 3) Memungkinkan seorang *business analyst* dan profesional teknologi informasi untuk menggunakan data. Data yang telah tersedia selanjutnya digunakan oleh profesional untuk analisis karena data tanpa dianalisa tidak akan dapat dipergunakan. 4) Menggunakan

perangkat lunak aplikasi untuk menganalisis data. Untuk mempermudah seorang professional menganalisis data, diperlukan suatu perangkat lunak yang sesuai untuk kegunaannya sehingga hasil yang didapatkan bisa maksimal. 5) Menampilkan data dalam format yang dapat dipahami manusia, seperti grafik atau tabel. Visualisasi diperlukan agar orang-orang dapat memahami hasil analisis dari data yang sudah dianalisis sehingga bisa mendapatkan insight baru data hasil pengolahan data yang telah divisualisasikan tersebut.

Modul yang akan dipergunakan adalah modul *Snscreape* dikarenakan memiliki keuntungan yaitu tidak dibatasi oleh tweepy. Menurut Samira dkk (2021) snscreape adalah modul untuk mendapatkan data pada layanan jejaring sosial. Data yang bisa didapatkan seperti tagar, pencarian, dan postingan yang relevan. Modul tersebut digunakan untuk melakukan *scraping* terhadap data twitter. Menurut Marres dan Weltevrede, *scraping* adalah teknik yang terkenal untuk pengumpulan data online secara otomatis. Ini adalah salah satu praktik paling khas yang terkait dengan bentuk penelitian sosial digital saat ini, yang ditandai dengan munculnya Internet dan keberadaan baru data digital dalam kehidupan sosial. Scraping memungkinkan untuk menyatukan data dari beberapa lokasi atau web, membuat data yang diekstraksi tersedia untuk penggunaan tujuan baru yang lain, sehingga memungkinkan pengaturan ulang data *online*.

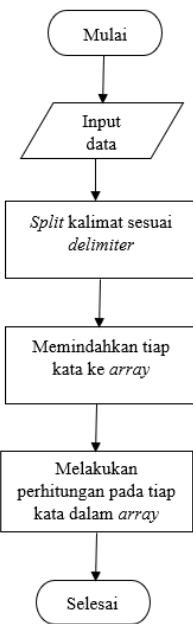
Pada proses data *mining* sendiri terdapat beberapa proses yang perlu dilakukan sebelum data dapat diolah menjadi data yang siap untuk dipergunakan. Proses tersebut disebut biasa disebut *pra-processing*. Menurut Nainggolan (2019), terdapat beberapa tahapan yang diperlukan dalam *pra-process* data. Pertama adalah pengumpulan data, kedua adalah *text pre-processing*, pada tahap ini dilakukan eliminasi data yang mengandung noise serta dilakukan pembersihan terhadap text yang tidak diperlukan. Langkah ketiga adalah seleksi fitur dimana dilakukan perubahan terhadap huruf besar menjadi huruf kecil serta menghilangkan tanda baca serta emoticon. Ketiga adalah dilakukan filtering dimana dipergunakan *stopwords*. Dimana *stopwords* akan menghilangkan karakter asing atau huruf asing serta menghilangkan kata yang tidak berpengaruh. Pada Gambar 2.1 dapat dilihat proses yang dilakukan dalam dilakukan filtering



**Gambar 2.1** Proses *filtering*

Pada Gambar 2.1 dapat dilihat proses *filtering* menggunakan *stopwords* dimana ketika terdapat sebuah kata yang tidak berada dalam list *stopwords* maka kata tersebut akan dihapus dan proses akan kembali melakukan *input* data untuk dilakukan *stopwords* berikutnya hingga kata dimasukan ke dalam array dan proses selesai.

Proses selanjutnya yang diperlukan adalah proses *tokenizing*. Menurut Salamah (2014), tokenizing adalah proses memecah aliran kalimat menjadi kata atau frase. Kata atau frase yang telah di token akan dipergunakan untuk proses selanjutnya. Proses ini menggunakan delimiter sebagai pembatas dari token itu sendiri. Pada Gambar 2.2 dapat dilihat proses dari *tokenizing*.



**Gambar 2.2** Proses tokenizing

## 2.5 Machine Learning

*Machine Learning* (ML) adalah bidang yang berfokus pada aspek pembelajaran *artificial Intelligence* (AI) yang menggunakan pengembangan algoritma yang paling mewakili sekumpulan data. Berbeda dengan pemrograman klasik yang dimana algoritma dikodekan secara eksplisit dengan menggunakan teknik yang diketahui, ML menggunakan kumpulan data untuk menghasilkan algoritma yang menggunakan kombinasi teknik dan bobot yang baru atau berbeda. *Machine learning* mulai diperkenalkan pada tahun 1950 oleh Alan Turing ketika muncul dengan “*Turing Test*” dimana tes tersebut dilakukan untuk menganalisa apakah komputer memiliki kecerdasannya sendiri atau tidak. dalam pembelajaran mesin, komputer dilengkapi dengan kumpulan data dan keluaran terkait. Komputer mempelajari dan menghasilkan algoritma yang menggambarkan hubungan antara keduanya. Algoritma ini dapat digunakan untuk inferensi pada dataset masa depan (Choi 2020).

Terdapat beberapa tipe dari *machine learning*. Tipe pertama adalah *supervised learning* atau pembelajaran yang diawasi. Pada pembelajaran yang diawasi mesin dilengkapi dengan data berlabel baik untuk input maupun output yang diharapkan selama pelatihannya dan algoritma pembelajaran yang diawasi menghasilkan fungsi pemetaan yang dapat mengidentifikasi output yang diharapkan untuk input yang diberikan. Proses pelatihan berlanjut hingga algoritma mencapai tingkat akurasi yang diinginkan. Salah satu tujuan standar pembelajaran terawasi adalah membuat komputer mempelajari sistem klasifikasi; oleh karena itu, biasanya digunakan untuk menyelesaikan masalah klasifikasi. Kedua adalah *unsupervised learning* atau pembelajaran yang tidak diawasi. Pada tipe ini mesin disediakan dengan dataset input yang tidak berlabel dan tidak diklasifikasikan dan algoritma pembelajaran tanpa pengawasan menghasilkan fungsi untuk mengidentifikasi struktur tersembunyi dalam dataset yang diberikan sesuai dengan pola, persamaan dan perbedaan yang ada di antara data tanpa pelatihan sebelumnya. Tidak ada penilaian tingkat akurasi struktur

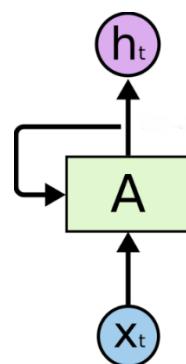
yang diidentifikasi oleh mesin. Salah satu fokus utama dari algoritma pembelajaran tanpa pengawasan adalah masalah pengelompokan dan asosiasi. Beberapa algoritma unsupervised learning yang umum digunakan adalah algoritma k-means untuk clustering. Tipe lainnya adalah *reinforcement learning* dimana mesin diberikan lingkungan di mana ia mengambil keputusan atas dasar *trial and error* dan belajar dari tindakannya sendiri dan pengalaman masa lalu. Untuk setiap keputusan yang benar, mesin menerima umpan balik hadiah dari lingkungan yang bertindak seperti sinyal penguatan dan informasi tentang pasangan status-tindakan yang dihargai disimpan. Kemudian mesin mengulangi perilaku yang dihargai setiap kali dihadapkan pada situasi yang sama. Algoritma pembelajaran penguatan memiliki penggunaannya dalam domain di mana pengambilan keputusan strategis. Karena memiliki algoritma-algoritma tersebut, *machine learning* memiliki beberapa fungsi yang sering dipergunakan. Seperti contohnya untuk klasifikasi, regresi, dan *sequence prediction* (Sodhi, dkk 2019).

*Deep learning* adalah sub kategori dari *machine learning*. Menurut Yanming (2015) metode dalam *deep learning* memanfaatkan *artificial neural network* untuk menyelesaikan proses yang dikerjakan. *Deep learning* akan mempelajari dan mengolah data yang memiliki abstraksi tinggi memanfaatkan arsitektur hirarki. Pada strukturnya *deep learning* memiliki ciri khas yaitu penggunaan *hidden layer* yang lebih dari satu (Arham 2018). *Hidden layer* merupakan lapisan yang berada di antara input layer dan output layer, dimana *artificial neuron* yang memiliki sekumpulan input dengan pembobot (*weight*) sera prosedur untuk menghasilkan output neuron. *Hidden layer* sendiri memiliki fungsi untuk proses pembelajaran pada machine learning.

## 2.6 Recurred Neural Network (RNN)

Algoritma yang digunakan dalam pengembangan *Recurred Neural Network* (RNN) adalah logika berpikir pada manusia yang pada umumnya tidak setiap saat membuat keputusan secara tunggal. Manusia akan lebih memperhatikan dan menggunakan masa lalu dalam sebuah pengambilan keputusan. Dengan logika tersebut, RNN tidak membuang informasi yang ada di masa lalu (Arham 2018).

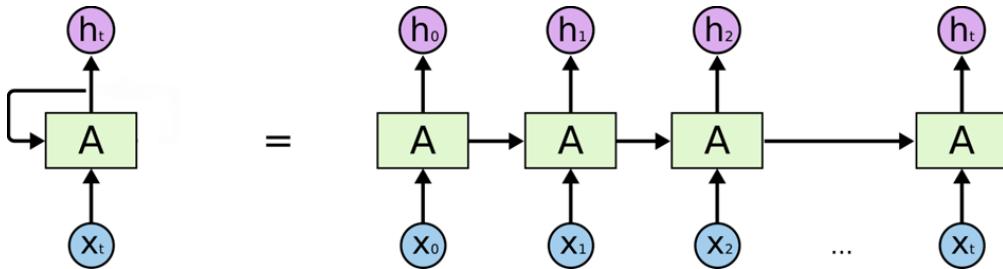
RNN adalah salah satu jenis dari neural network yang digunakan untuk memproses data yang bersambung (*sequential data*). Penyimpanan memori masa lampau pada RNN bisa terjadi karena proses *looping* yang ada dalam arsitekturnya.



Gambar 2.3 Arsitektur RNN

Dari Gambar 2.3, sebuah *neural network* A akan melihat beberapa input dari  $X_t$  dan mengeluarkan nilai  $h_t$ . Looping ini menghasilkan informasi yang akan diberikan dari satu tahapan *network* ke *network* berikutnya. RNN dapat diartikan sebagai banyak salinan dari *network* yang sama, masing-masing akan meneruskan informasi ke penerusnya. Pada Gambar

2.4 akan menunjukkan arsitektur RNN yang menggambarkan mengenai proses *looping* tersebut (Christopher 2015).



**Gambar 2.4** Looping pada Arsitektur RNN

Pada Gambar 2.4 dapat dilihat proses yang terjadi pada RNN. Dimana  $X_0$  adalah *input* pada saat  $t = 0$  dan  $h_0$  adalah hasil *output* pada saat  $t = 0$ . Tetapi *output* yang dihasilkan pada saat  $t = 0$  juga akan digunakan sebagai *input* pada saat  $t = 1$ . Begitu pula pada  $X_1$  adalah *input* pada saat  $t = 1$  dan  $h_1$  adalah hasil *output* pada saat  $t = 1$  yang memiliki *input* tambahan dari  $t = 0$  dan akan menghasilkan *output* yang akan digunakan sebagai *input* tambahan pada saat  $t = 2$ .

## 2.7 Statistika Deskriptif

Statistika deskriptif adalah metode analisis data secara statistik dengan cara mendeskripsikan maupun menggambarkan data yang dimiliki untuk memberikan gambaran terhadap data tersebut. Analisis yang biasa digunakan adalah rata-rata (*mean*) dan Standar deviasi untuk mengetahui sebaran data (Sugiyono, 2015). Statistik deskriptif digunakan untuk menggambarkan ciri-ciri dasar data dalam suatu penelitian. Bersama dengan analisis grafik sederhana, mereka membentuk dasar dari hampir setiap analisis kuantitatif data.

$$\bar{x} = \frac{1}{n} \sum_{t=1}^n x_t \quad (2.1)$$

$$std = \sqrt{\frac{\sum(x - \bar{x})^2}{n - 1}} \quad (2.2)$$

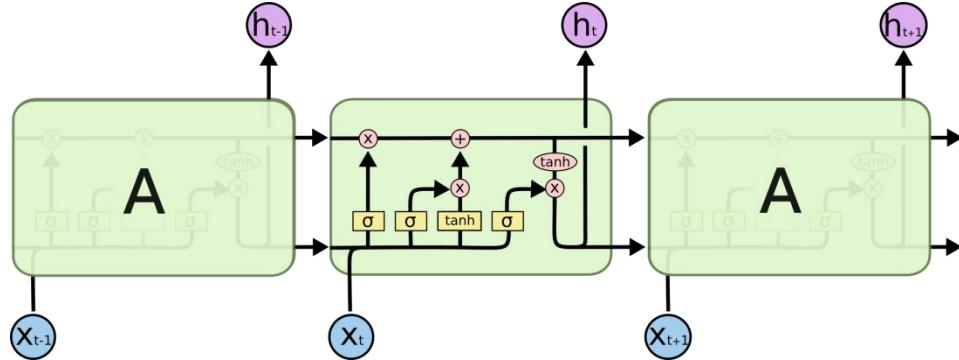
Dimana:

$\bar{x}$	= rata-rata ( <i>mean</i> )
$n$	= banyaknya data
$x_t$	= data pada saat ke- $t$
std	= standar deviasi
$\sum_{t=1}^n x_t$	= jumlah dari data ke 1 sampai n dari data x
$\sum(x - \bar{x})$	= jumlah dari selisih data dengan rata-rata

## 2.8 Long Short-term Memory (LSTM)

Menurut Zrara (2020) The *Long Short-term memory* (LSTM) adalah tipe yang spesial dari arsitektur RNN yang sering digunakan dalam *deep learning*. LSTM menggunakan satu set koneksi umpan balik untuk memproses urutan data. Metode ini dinamakan LSTM karena unit selnya memiliki kemampuan untuk melupakan bagian dari data yang disimpan sebelumnya dan pada saat yang sama, mengingat informasi baru tambahan. Struktur LSTM memiliki struktur rantai yang mirip dengan RNN, tetapi memiliki struktur *looping* yang berbeda. LSTM memilih menggunakan empat *layer neural network* dibanding hanya satu

yang membuat interaksinya menjadi lebih kompleks (Arham 2020). Pada Gambar 2.5 dapat dilihat arsitektur dari LSTM.



**Gambar 2.5** Arsitektur looping pada LSTM (Christopher 2015)

Berdasarkan gambar 2.5 dapat dilihat beberapa notasi seperti  $X_{t-1}, X_t$ , dan  $X_{t+1}$  yang menunjukkan input yang masuk pada saat ke- $t - 1$ ,  $t$  dan  $t + 1$ . Begitu pula  $h_{t-1}, h_t$ , dan  $h_{t+1}$  merupakan *output* pada saat ke- $t - 1$ ,  $t$  dan  $t + 1$ . Hasil output pada saat ke- $t - 1$  akan digunakan pada saat ke- $t$  dan seterusnya. Langkah-langkah yang akan diterapkan dalam LSTM adalah sebagai berikut. (Xuan 2019)

### 1. Menentukan Informasi yang tidak diperlukan

Langkah pertama dalam membangun LSTM adalah menentukan informasi mana yang akan dilupakan dari sel pada langkah itu. Proses ini akan mengidentifikasi dan informasi yang tidak diperlukan dan akan dihilangkan dari sel pada langkah itu. Proses mengidentifikasi dan mengecualikan data ini ditentukan oleh: fungsi sigmoid, yang mengambil *output* dari unit LSTM terakhir ( $h_{t-1}$ ) pada waktu  $t - 1$  dan arus masukan ( $X_t$ ) pada waktu  $t$ . Selain itu, fungsi sigmoid menentukan bagian mana dari *output* lama harus dihilangkan. Gerbang ini disebut *forget gate* ( $f_t$ ); dimana  $f_t$  adalah vektor dengan nilai berkisar dari 0 hingga 1, sesuai dengan setiap angka dalam status sel,  $C_{t-1}$ .

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (2.3)$$

$$\sigma = \frac{1}{1+e^{-x}} \quad (2.4)$$

*Keterangan:*

- $\sigma$  = Sigmoid function
- W = Bobot metrics
- $X_t$  = Input dari timestamp saat ini
- b = bias

Dengan bobot *metrics* yang diinisialisasi secara random dan bias sama dengan 1. Bias sendiri adalah sebuah “*offset*” yang ditambahkan ke setiap unit lapisan dari jaringan saraf yang tidak bergantung ke input lapisan. Bias memungkinkan lapisan untuk memodelkan ruang data yang berpusat di sekitar beberapa titik selain titik asli. Bobot *metrics* W kemudian digunakan kembali pada bobot *forget gate* ( $W_f$ ), *input gate* ( $W_i$ ), *Cell state* ( $W_c$ ), dan *Output gate* ( $W_o$ ). Kemudian dilakukan proses *backpropagation* untuk menyesuaikan kembali bobot dan bias yang digunakan pada proses sebelumnya untuk semakin memperkecil *error* dan meningkatkan akurasi dari pembelajaran. Sedangkan untuk *sigmoid function* digunakan untuk

mengatur seberapa banyak informasi bisa lewat. Fungsi sigmoid menghasilkan output berupa nilai dengan kisaran 0 sampai 1. Dimana 0 menunjukkan tidak ada informasi yang akan lewat sedangkan 1 berarti semua informasi akan lewat.

## 2. Menentukan, Menyimpan dan Memperbarui informasi

Langkah selanjutnya adalah memutuskan dan menyimpan informasi dari *input* baru ( $X_t$ ) dalam keadaan sel serta memperbarui status sel. Langkah ini berisi dua bagian, lapisan sigmoid dan yang kedua adalah *layer* tanh. Pertama, lapisan sigmoid memutuskan apakah informasi baru harus diperbarui atau diabaikan (0 atau 1), lalu kedua, fungsi tanh akan memberi bobot pada nilai yang dilewati, menentukan pentingnya level (-1 sampai 1). Kedua nilai dikalikan untuk memperbarui status sel baru. Memori baru ini kemudian ditambahkan ke memori lama ( $C_{t-1}$ ) menghasilkan ( $C_t$ ).

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2.5)$$

$$N_t = \tanh(W_n[h_{t-1}, X_t] + b_n) \quad (2.6)$$

$$C_t = \sigma(C_{t-1}f_t + N_t i_t) \quad (2.7)$$

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.8)$$

Keterangan:

$i_t$  = Input Gate

$C_{t-1}$  = Keadaan sel saat  $t - 1$

$C_t$  = Keadaan sel saat  $t$

Fungsi *tanh* (*Hyperbolic Tangent*), merupakan fungsi aktivasi dalam *deep learning*. Dimana fungsi *tanh* merupakan versi skala ulang dari fungsi sigmoid.

## 3. Output Value

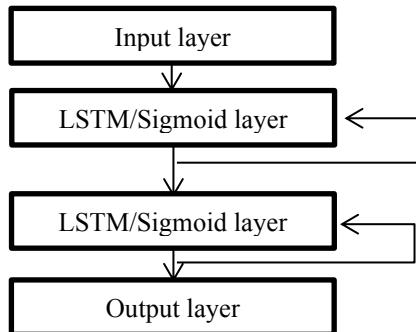
Pada langkah ini nilai keluaran ( $h_t$ ) didasarkan pada status sel *output* ( $O_t$ ) tetapi merupakan hasil dari *filtering*. Pertama, lapisan sigmoid memutuskan bagian mana dari status sel yang menghasilkan *output*. Selanjutnya, *output* dari gerbang sigmoid ( $O_t$ ) dikalikan dengan nilai baru yang dibuat oleh lapisan *tanh* dari keadaan sel ( $C_t$ ), dengan nilai berkisar antara -1 dan 1.

$$O_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (2.9)$$

$$h_t = O_t \tanh(C_t) \quad (2.10)$$

Dimana  $W_o$  dan  $b_o$  masing-masing adalah matriks bobot dan bias dari gerbang keluaran.

*Stacked LSTM* adalah salah satu jenis dari LSTM dimana terdapat beberapa lapisan dalam prosesnya yang berisi beberapa sel memori. Adanya beberapa lapisan dalam *stacked LSTM* ini dilakukan untuk menghasilkan akurasi yang lebih tinggi dan memperkecil *error*. Lapisan ini bekerja dengan cara memberikan *output* yang didapatkan dari lapisan pertama ke lapisan berikutnya. Kemudian dilakukan pembelajaran terhadap *output* tersebut untuk memberikan *output* baru dengan hasil yang lebih baik (Azzam, dkk 2021).



**Gambar 2.6** Arsitektur dari Stacked LSTM

Dimana seperti pada Gambar 2.6 pada *stacked* LSTM nilai *output* dari *layer* sebelumnya ( $h_t$ ) akan menjadi masukkan ( $x_t$ ) untuk *layer* setelahnya. Setelah itu akan dilakukan proses *backpropagation* untuk meningkatkan hasil akurasi dan mengecilkan error. *Backpropagation* adalah metode pelatihan jaringan saraf tiruan yang diawasi. Ini mengevaluasi kontribusi kesalahan dari setiap neuron atau unit setelah satu set data diproses. Tujuan *backpropagation* adalah untuk memodifikasi bobot untuk melatih jaringan *neural* untuk memetakan *input* ke *output* dengan benar.

## 2.9 Evaluasi Hasil *Forecasting*

Terdapat beberapa cara untuk mengetahui akurasi dari *forecasting* yang telah dilakukan seperti *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE). Akurasi hasil *forecasting* diperlukan untuk mengetahui model yang paling cocok digunakan untuk melakukan *forecasting*.

### 2.9.1 Mean Squared Error (MSE)

MSE dihitung dengan cara menjumlahkan selisih dari kuadrat nilai asli dan nilai hasil prediksi yang kemudian dibagi dengan total observasi. MSE digunakan untuk mengetahui akurasi dan *error* dari hasil yang didapat.

$$MSE = \frac{1}{n} \sum_{t=1}^t (A_t - F_t)^2 \quad (2.11)$$

Dimana  $F_t$  adalah observasi ke- $t$  dari hasil prediksi dan  $A_t$  adalah observasi ke- $t$  dari nilai yang sebenarnya (Ahmed dan Bahador, 2018).

### 2.9.2 Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengetahui keakuratan dari hasil prediksi yang didapat. Perhitungan dilakukan dengan menghitung selisih antara nilai aktual dan nilai prediksi lalu membagi dengan nilai aktual yang kemudian dikalikan dengan 100 dibagi total observasi (Myttenaere, dkk 2016).

$$MAPE = \frac{1}{n} \sum_{t=1}^t \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (2.12)$$

Dimana  $A_t$  adalah nilai actual dan  $F_t$  adalah nilai hasil prediksi.

## 2.10 Optimasi Portofolio

Ketika berinvestasi, terdapat risiko yang harus ditanggung oleh seorang investor. Semakin tinggi risiko maka semakin tinggi pula return yang diharapkan. Investasi yang memiliki risiko tinggi contohnya adalah saham dan *cryptocurrencies*. *Cryptocurrencies* memiliki risiko yang sangat tinggi, karena hal tersebut diperlukan suatu analisis untuk meminimalkan risiko tersebut. Salah satu cara untuk meminimalkan risiko adalah melakukan analisis pembentukan portofolio. Portofolio merupakan sekumpulan sekuritas atau aset yang membentuk sebuah kesatuan. Portofolio yang optimal adalah portofolio yang memberikan imbal hasil paling tinggi dengan tingkat risiko terkecil (Giharta, 2017).

### 2.10.1 Hierarchical Risk Parity (HRP)

Pendekatan *Hierarchical Risk Parity* (HRP) merupakan hasil dari Portofolio optimal berbasis risiko dengan menggunakan *covariance matrix* tanpa menggunakan *inverse*-nya. HRP menghitung bobot volatilitas terbaik untuk bagian aset yang serupa, yang secara *iterative* akan diperkecil sesuai pergerakan sub bagian yang lebih kecil sehingga setiap aset akan membentuk sub bagian. Algoritma HRP memiliki tiga langkah atau tahapan. Tahap pertama adalah penentuan hubungan hirarkis antara aset dengan skema pembentukan *cluster* rekursif. *Cluster* dibentuk dengan menggunakan korelasi untuk mengidentifikasi kelompok aset serupa yang kemudian digabungkan secara berurutan menjadi satu *cluster* besar. Tahap berikutnya adalah menggunakan kuasi diagonalisasi matrik kovarians, yaitu menata baris dan kolom berdasarkan informasi dari tahap pertama. Setelah itu dilakukan pembobotan dan dialokasikan menurut varians terbaik antar sub kelompok yang diperoleh. Berikut akan dirinci masing-masing tahapan tersebut (Prayut, 2019).

#### 1. Clustering

Menurut Prado (2018) *clustering* adalah teknik partisi untuk mengelompokkan titik data berdasarkan karakteristiknya. Dalam kasus HRP, koefisien korelasi digunakan sebagai karakteristik untuk mengukur kesamaan antara deret waktu, dan oleh karena itu untuk mengelompokkan aset yang memiliki deret waktu yang sama. HRP menggunakan sarang *agglomeratif* untuk pengelompokan, dimana awalnya semua aset individu berperilaku sebagai klaster terpisah. Kemudian, berdasarkan korelasinya, mereka mulai membentuk klaster yang lebih besar hingga semua aset serupa dikelompokkan bersama. Pertama, matrik jarak yang sesuai didefinisikan sebagai:

$$d_{i,j} = \sqrt{\frac{1}{2}(1 - p_{i,j})} \quad (2.13)$$

Dimana  $d_{i,j}$  adalah indeks korelasi jarak antara aset  $i$  dan  $j$  dan  $p_{i,j}$  adalah koefisien korelasi Pearson. Selanjutnya matriks yang mendefinisikan jarak Euclidean antara dua kolom  $d$  didefinisikan sebagai  $\bar{d}$  yang elemennya adalah

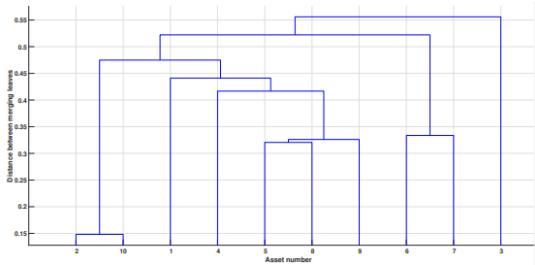
$$\bar{d}_{ij} = \sqrt{\sum_{n=1}^N (d_{n,i} - d_{n,j})^2} \quad \text{dengan } i, j = 1, \dots, N \quad (2.14)$$

Pengelompokan aglomeratif dimulai dengan setiap aset yang mewakili satu klaster. Pada setiap langkah, dua klaster terdekat digabungkan menjadi satu. Ukuran ketidakmiripan antara *cluster* dikenal sebagai kriteria linkage. Metode aglomerasi yang akan digunakan pada penelitian ini adalah *Average linkage*.

*Average Linkage*: Dalam teknik *average linkage* (AL) jarak ditentukan oleh rata-rata jarak antara dua titik dalam kluster (Prayut, 2019). Untuk kluster  $C_i, C_j$ :

$$d_{C_i C_j} = \text{mean}_{x,y} \left\{ \bar{d}(x,y) | x \in C_i, y \in C_j \right\} \quad (2.15)$$

Gambar 2.7 memberikan gambaran hasil dari pengelompokan agglomeratif dari tiap aset.



**Gambar 2.7** Contoh Ilustrasi Urutan *Tree Clustering*

Pada Gambar 2.7 berdasarkan contoh ilustrasi tersebut, sebuah aset yang memiliki korelasi yang tinggi akan ditempatkan bersebelahan atau berdekatan sedangkan aset yang memiliki nilai korelasi rendah akan ditempatkan secara berjauhan dan pemecahan dari aset-aset tersebut dilakukan secara *up to bottom*.

## 2. Diagonalisasi Kuasi

Pada langkah ini kami mengatur ulang aset dalam matriks korelasi sehingga korelasi terbesar terletak di sekitar diagonal. Dengan cara ini, aset akan berakhir dekat dengan yang serupa dan jauh dari aset yang sangat berbeda dan kami akan dapat memvisualisasikan klaster dalam matriks korelasi. Ini mengatur ulang matriks kovarians asli dari aset sehingga kovarians yang lebih besar ditempatkan di sepanjang diagonal dan yang lebih kecil di sekitar diagonal ini dan karena elemen *off-diagonal* tidak sepenuhnya nol, ini disebut matriks kovarians kuasi-diagonal. Ini memungkinkan kita untuk mengalokasikan bobot secara optimal mengikuti alokasi *inverse volatilitas* (Prayut, 2019).

## 3. Recursive Bisection

Ini adalah langkah terakhir di mana akan ditetapkan penentuan bobot dalam portofolio. Pertama akan diinisialisasi semua bobot dengan nilai yang sama untuk semua n aset,  $w = (1, 1, \dots, 1)$ . Kemudian akan dilakukan eksplorasi terhadap *tree clustering* yang sebelumnya sudah didapatkan dari atas ke bawah dan setiap kali dibagi menjadi dua kelompok ini akan bersaing untuk mendapatkan bobot. Artinya, dilakukan perhitungan volatilitas individu untuk masing-masing *cluster* dan akan memperbarui bobotnya dengan cara yang berbanding terbalik dengan volatilitas. Perhitungan volatilitas ini dengan mengingat bahwa untuk matriks korelasi diagonal, alokasi varians terbalik adalah optimal. Ini adalah, untuk setiap cluster bobot yang akan kita gunakan untuk menghitung volatilitasnya.

$$w = \frac{\text{diag}[V]^{-1}}{\text{trace}(\text{diag}[V]^{-1})} \quad (2.16)$$

Dimana  $V$  adalah matriks kovarian dari *constituent cluster* dan  $\text{diag}[V]^{-1}$  adalah diagonal matriks dari invers matriks  $V$  serta *trace* adalah jumlah dari diagonal yang didapatkan. Dengan begitu dapat dihitung varians dari kedua klaster.

$$\sigma_1 = w_1^T V_1 w_1 \quad (2.17)$$

$$\sigma_2 = w_2^T V_2 w_2 \quad (2.18)$$

Setelah itu dilakukan perhitungan terhadap dua faktor yang ada untuk menyesuaikan kembali bobot dari klaster,  $\alpha_1$  dan  $\alpha_2$ .

$$\alpha_1 = 1 - \frac{\sigma_1}{\sigma_1 + \sigma_2}; \alpha_2 = 1 - \alpha_1 \quad (2.19)$$

Untuk perhitungan bobot pada sisi kiri dan kanan dipergunakan hasil kali antara  $w$  dan faktor yang telah dihitung.

$$w_1 = w_1 \alpha_1 \quad (2.20)$$

$$w_2 = w_2 \alpha_2 \quad (2.21)$$

Kemudian langkah-langkah tersebut dilakukan hingga tersisa masing-masing satu aset pada tiap sisi kiri dan kanan sehingga didapatkan total bobot dari tiap aset pada portofolio adalah satu.

### 2.10.2 Nested Clustered Optimization (NCO)

*Nested clustered optimization* adalah pendekatan berbasis pembelajaran mesin untuk mengatasi masalah struktural ketidakstabilan kovarians dalam teori portofolio modern. Tujuan akhir dari metode ini adalah untuk mereduksi masalah optimasi berkondisi buruk menjadi beberapa sub-masalah yang lebih kecil dan berperilaku lebih baik. *Nested clustered optimization* memiliki empat tahapan di dalamnya yaitu :

#### 1. Klastering hirarki korelasi

Pertama perlu dilakukan klastering terhadap matriks kovarians yang dibagi menjadi variabel dengan korelasi tinggi (Prado, 2019). Jarak matriks kemudian digunakan untuk membentuk cluster menggunakan algoritma *agglomerative hierarchical clustering*.

#### 2. Menentukan jumlah Klaster yang optimal

Dilakukan perhitungan jumlah klaster yang optimal. Ini dilakukan untuk mereduksi matriks kovarian asli hingga setiap klaster direpresentasikan sebagai variabel tunggal.

#### 3. Within-Cluster Weight Allocation

Ketiga, alokasi bobot dalam *cluster* ditentukan menggunakan *cluster* yang terbentuk pada langkah sebelumnya dengan membuat matriks kovarians untuk konstituen *cluster* dan melakukan optimasi menggunakan metode optimasi portofolio yang diberikan.

$$w_i = \frac{\Sigma_i^{-1} 1}{1^T \Sigma_i^{-1} 1} \quad (2.22)$$

Dimana  $\Sigma_i$  menunjukkan kovarians matrix untuk klaster i.

#### 4. Between-Cluster Weight Allocation

Keempat, matriks kovarians yang tereduksi ditentukan dengan mempertimbangkan varians dan antar klaster. Dari sini, alokasi bobot antar-*cluster* dihitung menggunakan metode optimasi yang sama seperti pada langkah alokasi bobot dalam-*cluster* (Sjostrand, 2020).

$$V_i = w_i^T \sum_i w_i \quad (2.23)$$

Varians portofolio dalam klaster dari setiap klaster kemudian digunakan untuk membangun pengurangan matriks kovarians.

$$\sum = \begin{pmatrix} V_1 & v_{12} & \cdots & v_{1n} \\ v_{21} & V_2 & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ v_{n1} & \cdots & \cdots & V_n \end{pmatrix} \quad (2.24)$$

dimana n adalah jumlah *cluster* dan  $v_{ij}$  adalah kovarians antara cluster i dan j. Matriks kovarians tereduksi digunakan untuk menghitung alokasi varians minimum.

$$W = \frac{\Sigma^{-1} \mathbf{1}}{\mathbf{1}^T \Sigma^{-1} \mathbf{1}} \quad (2.25)$$

Sehingga w menjadi vektor gabungan dari bobot dalam *cluster* untuk semua aset yang ditentukan pada langkah sebelumnya. Bobot dalam klaster dan bobot antar klaster kemudian dapat digunakan untuk menghitung bobot aset sebagai:

$$w_{NCO} = W \cdot w \quad (2.26)$$

## 2.11 Analisis Kinerja Portofolio

Untuk mengetahui kinerja dari portofolio yang telah terbentuk, diperlukan analisis yang tepat. Penilaian kinerja portofolio dilakukan untuk mengetahui dan menganalisa apakah portofolio yang dibentuk dapat meningkatkan kemungkinan tercapainya tujuan dari investasi yang dilakukan. Penilaian kinerja tersebut untuk mengetahui return portofolio yang didapat sudah mampu mengompensasi tingkat risiko yang ditanggung oleh seorang investor. Beberapa metode yang dapat digunakan untuk mengetahui kinerja portofolio adalah *sharpe* dan *sortino ratio* (Fernandos, 2007).

### 2.11.1 Sharpe Ratio

*Sharpe ratio* merupakan rasio untuk mengukur imbal hasil aset terhadap risiko portofolio setelah dikurangi return aset bebas risiko. *Sharpe ratio* menggunakan rata-rata imbal hasil selama periode sampel yang dibagi dengan standar deviasi dari imbal hasil tersebut. Hal ini mengukur pertukaran imbal hasil terhadap total volatilitas (Bodie dkk, 2006).

$$S_a = \frac{R_a - R_b}{\sigma_a} \quad (2.27)$$

Dimana :

$S_a$  = *Sharpe ratio*

$R_a$  = *Return portofolio*

$R_b$  = *Risk free return*

$\sigma_a$  = Standar deviasi asset

### 2.11.2 Sortino Ratio

*Sortino ratio* adalah rasio untuk mengukur imbal hasil aset terhadap kerugian yang diterima portofolio setelah dikurangi return aset bebas risiko. *Sortino ratio* menggunakan *downside-risk*. Sebagai proksi untuk risiko bukan untuk keseluruhan volatilitas aset (Luca, 2020). *Downside-risk* adalah ukuran risiko yang secara spesifik mengukur risiko portfolio ketika kinerja portfolio mengalami kerugian atau mendapatkan target return dibawah yang

diharapkan. Karena hal tersebut kinerja portfolio ketika mengalami keuntungan atau memberikan return diatas target return yang diharapkan tidak dimasukan dalam perhitungan.

$$\text{Sortino Ratio} = \frac{\bar{r} - r_{MAR}}{\delta_{MAR}} \quad (2.28)$$

Dimana  $\bar{r}$  adalah ekspektasi *return* portofolio,  $r_{MAR}$  adalah *return* minimal yang diterima dan  $\delta_{MAR}$  adalah *downside-risk*.

$$\delta_{MAR} = \sqrt{\sum_{t=1}^T \frac{1}{365} \min(0, r_t - r_{MAR})^2} \quad (2.29)$$

Dengan *risk free rate* digunakan sebagai *return* minimal yang diterima, sehingga  $r_{MAR} = r_f$ .

## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1 Sumber Data dan Variabel Penelitian**

Pada penelitian ini variabel yang digunakan adalah nilai harga *closing* harian dari tiap *crypto* yang akan digunakan atau 10 teratas *crypto trending* di *Twitter* dari 72000 *tweet* per bulan pada tahun 2021. Data *closing* harian akan diperoleh dari website finance.yahoo.com. Periode yang akan diambil adalah data periode 1 Januari 2021 hingga 31 Desember 2021.

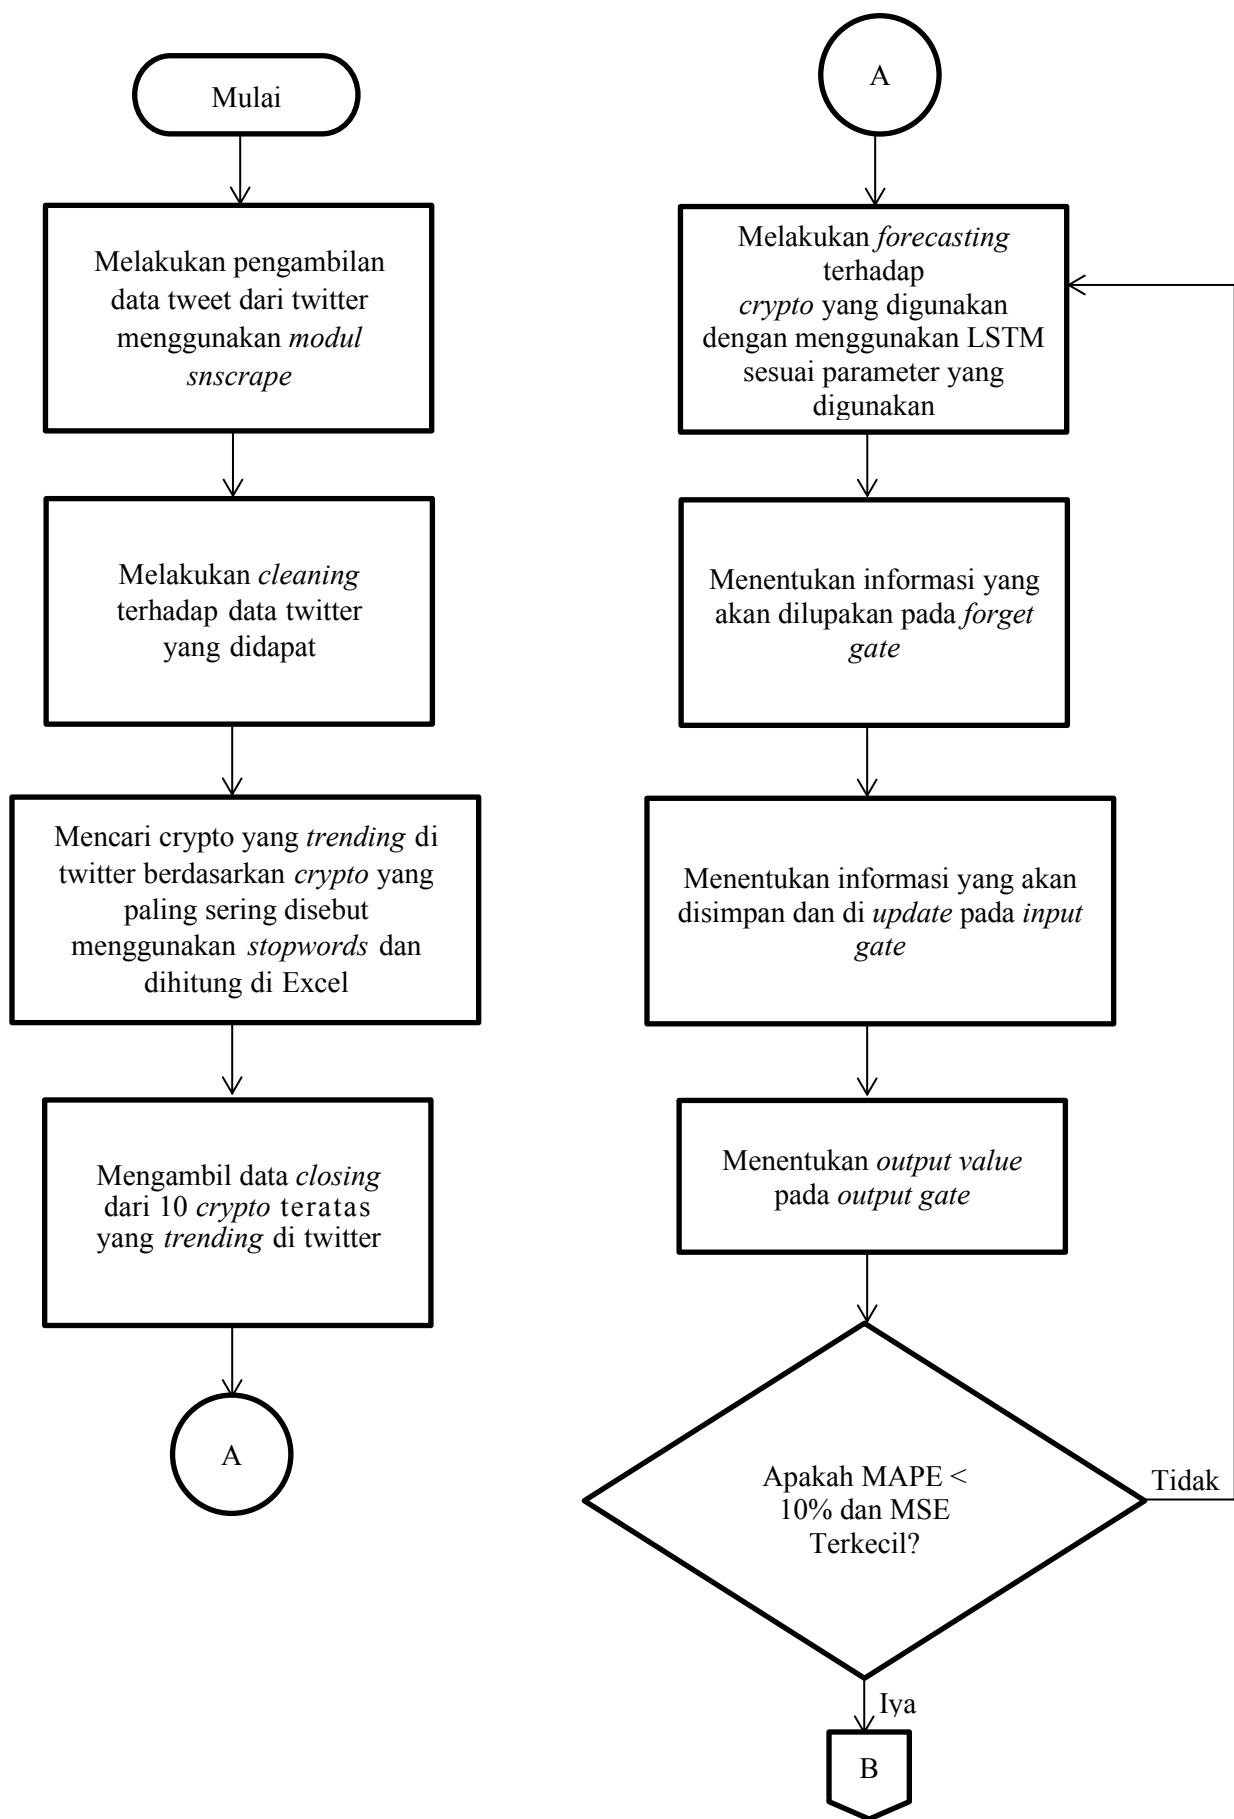
#### **3.2 Langkah Analisis**

Metode analisis yang digunakan dalam penelitian ini adalah *Long-Short Term Memory* (LSTM) untuk melakukan forecasting dari 10 teratas *Twitter trending*. Metode untuk pembentukan portofolio optimal dari hasil *forecasting* adalah Metode *Hierarchical Risk Parity* (HRP) dan *Nested Clustered Optimization* (NCO). Proses pengolahan data akan dilakukan menggunakan *software* python dan Excel. Berikut langkah-langkah analisis yang akan dilakukan.

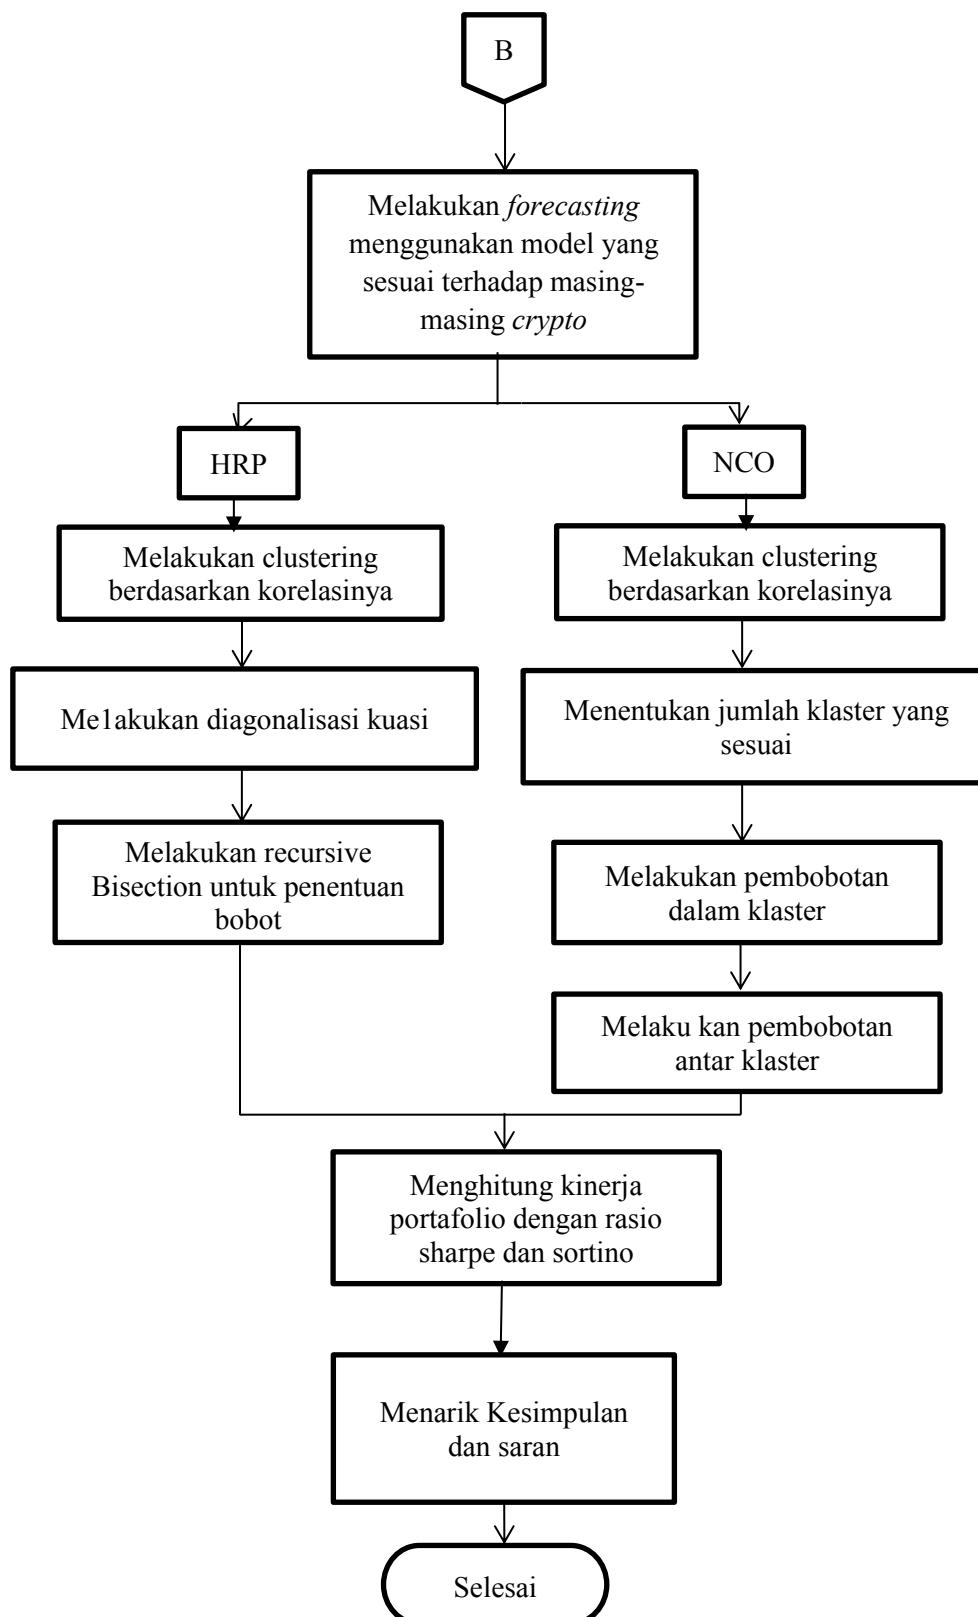
1. Melakukan pengambilan data di *Twitter* untuk periode 2021 dengan modul *sns scrape* pada python. Pengambilan data dilakukan secara bulanan dengan jumlah *tweet* yang diambil per bulan sebanyak 72000 *tweet* yang berhubungan dengan keyword yang digunakan.
2. Melakukan *cleaning* menggunakan python terhadap data *Twitter* yang diperoleh sehingga menghasilkan data yang bisa diolah. *Cleaning* yang dilakukan yaitu menghilangkan username, emoticon, spasi berlebih serta menghilangkan kata-kata yang tidak perlu atau kata imbuhan menggunakan *stopwords*.
3. Mencari *crypto* yang *trending* dari data hasil *cleaning* berdasarkan yang paling banyak disebutkan menggunakan python dan excel sehingga didapatkan 10 *crypto* yang *trending* di *Twitter* pada tahun 2021.
4. Mengambil data *closing* harian dari 10 *crypto* yang trending. Pengambilan data dilakukan menggunakan *python* pada program *Jupyter Notebook*.
5. Melakukan perhitungan statistika deskriptif terhadap 10 *crypto* yang digunakan untuk mengetahui karakteristik data.
6. Melakukan pembagian data *training* dan *testing* terhadap harga *closing* yang kemudian akan dilakukan pengujian terhadap data
7. Melakukan evaluasi terhadap hasil *forecasting* dengan melihat nilai MAPE dan MSE, dimana model yang akan digunakan adalah model dengan nilai MAPE dibawah 10% dan MSE terkecil.
8. Melakukan *forecasting* pada tiap *crypto* dengan menggunakan metode LSTM dengan model yang paling sesuai menggunakan harga *closing* sehingga didapatkan harga *forecasting* harga pada tahun 2022.
9. Melakukan pembuatan portofolio optimal dengan *Hierarchical Risk Parity* menggunakan data historis ditambah dengan hasil *forecasting* harga *cryptocurrency* yang telah dilakukan
10. Melakukan pembuatan portofolio optimal dengan *Hierarchical Risk Parity* menggunakan data historis ditambah dengan hasil *forecasting* harga *cryptocurrency* yang telah dilakukan dengan menghilangkan aset yang mendominasi portofolio.
11. Melakukan pembuatan portofolio optimal dengan *Nested Clustered Optimization* menggunakan data historis ditambah dengan hasil *forecasting* harga *cryptocurrency* yang telah dilakukan

12. Menghitung kinerja masing-masing portofolio dengan rasio sharpe dan sortino dengan menggunakan return, risiko serta *downside-risk*.
13. Melakukan perbandingan rasio sharpe dan sortino dari dua portofolio untuk mengetahui portofolio mana yang lebih cocok untuk digunakan pada penelitian ini

Tahapan proses penelitian analisis berdasarkan langkah di atas sesuai pada Gambar 3.1 berikut.



Gambar 3.1 Diagram Analisis Data



**Gambar 3.1** Diagram Analisis Data (Lanjutan)

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Pengumpulan Data

Pada tahap ini dilakukan pengumpulan data untuk memperoleh variabel yang digunakan dalam penelitian ini. Data yang dicari merupakan *tweet* yang mengandung kata *crypto* dan *cryptocurrency*. Pengambilan data dilakukan setiap bulan mulai bulan Januari hingga Desember 2021. Data diambil menggunakan *Jupyter Notebook* menggunakan modul *snsccrape*. Data yang telah didapatkan kemudian akan diolah untuk mengetahui *crypto* yang sedang trending di twitter pada tahun 2021.

##### 4.1.1 Pengambilan Data pada *Twitter*

Pengambilan Data dilakukan dengan metode *scrapping* menggunakan modul *snsccrape* pada *software Python Jupiter Notebook*. *Scraping* dilakukan pada media sosial *Twitter* dengan menggunakan beberapa *keyword* yaitu :

1. Crypto
2. crypto
3. Cryptocurrency
4. cryptocurrency

Keempat kata tersebut digunakan karena pada penelitian ini ingin berfokus pada *crypto*, selain itu penggunaan huruf kapital berpengaruh terhadap *scrapping* data yang diambil dari *Twitter*. *Syntax* untuk melakukan pengambilan data dapat dilihat pada Lampiran 1. Untuk mempermudah penyimpanan, maka hasil dari data yang telah diambil disimpan dalam file berbentuk csv. Terdapat 12 file csv yang didapatkan dari pengambilan data media sosial *Twitter* dilakukan tiap bulan untuk bulan Januari hingga Desember 2021.

	date	tweet_id	text
0	2021-07-30 23:59:56+00:00	1421259295853776898	@MoonManStan2 @1goonrich @JosephMRestrep1 @Bri...
1	2021-07-30 23:59:54+00:00	1421259286278066178	SPING #sonarians #sonartoken #bsc #HODL #Crypt...
2	2021-07-30 23:59:54+00:00	1421259285745463296	@crypto_birb That's perfect
3	2021-07-30 23:59:51+00:00	1421259275876409346	@NeerajKA Why should we listen to crypto lobby...
4	2021-07-30 23:59:50+00:00	1421259271304617989	@Bitboy_Crypto @TeamYouTube What did they say?

Gambar 4.1 Contoh Hasil Pengambilan Data pada *Twitter*

Pada Gambar 4.1 dapat dilihat contoh hasil pengambilan data mentah dari twitter. Data yang didapatkan berupa data waktu, *tweet id*, username dan text dari *tweet* yang dilakukan.

##### 4.1.2 Praproses Data

Sebelum data dapat digunakan untuk diproses, diperlukan praproses data. Dimana data awal yang didapatkan masih berupa kalimat atau paragraf utuh. Bahasa yang digunakan adalah bahasa inggris. Selain itu terhadap beberapa hal yang tidak diperlukan seperti penggunaan emoji, *username* dari pengguna *Twitter* dan beberapa hal lainnya. Terdapat beberapa tahapan yang diperlukan untuk praproses data.

###### 1. Pembersihan Data *Twitter*

Pada data hasil pengambilan *scrapping* terdapat simbol serta karakter yang kurang berguna selain itu juga terdapat kalimat yang berantakan. Maka perlu dilakukan pembersihan terhadap data *tweet* yang diperoleh. Terdapat beberapa tahapan dalam pembersihan *tweets*, yaitu:

1. Menghilangkan link URL yang terdapat pada *tweet*.
2. Menghilangkan *retweet*.
3. Menghapus *username* dari *tweet*.
4. Menghapus angka yang terdapat dalam *tweet*.
5. Menghilangkan *hashtag* yang terdapat pada *tweet*.
6. Menghapus *emoticon* yang terdapat pada *tweet*.
7. Menghapus spasi berlebih yang terdapat dalam *tweet*.
8. Melakukan *case folding* untuk menghilangkan huruf capital sehingga dan diganti menjadi huruf kecil.

Setelah dilakukan pembersihan, berikut merupakan data hasil pembersihan yang didapatkan.

**Tabel 4.1** Perbedaan *Tweet* Sebelum dan Sesudah Dilakukan Praproses Data

<b><i>Tweet sebelum dilakukan praproses</i></b>	<b><i>Tweet sesudah dilakukan praproses</i></b>
@MoonManStan2 @1goonrich	should be trying to create a logo with crazy
@JosephMRestrep1 @BriThaCryptoGu1	team written let s ask or
@brizzle99 @brandibaby23	
@JimmyCrypto888 Should be trying to create a logo with Crazy Team written ðŸ”¥ðŸ”¥ letâ€TM's ask	dear you are wrong about one thing it is possible to create more bitcoin this is something that can happen when regulators and politicians meddle so much with crypto and coders joining them carl
@udiWertheimer @michael_saylor @SquawkStreet @CNBC Dear @michael_saylor, You are wrong about one thing. It is possible to create more bitcoin. This is something that can happen when regulators and politicians meddle so much with crypto and coders joining them.	why do you believe xrp will shine and what value do you see xrp adding to the crypto ecosystem
@welcomecatena Why do you believe XRP will shine, and what value do you see \$XRP adding to the crypto ecosystem?	what a day for crypto punks can t wait to stake my for punks tokens
What a day for Crypto Punks. Canâ€TMt wait to stake my @punkscomic for \$PUNKS tokens	

Pada Tabel 4.1 Dapat dilihat perbedaan dari *tweet* sebelum dan sesudah dilakukan praproses data. Dimana *username* dihilangkan, karakter yang tidak diperlukan juga dihilangkan serta menghilangkan spasi berlebih pada *tweet* tersebut.

## 2. Melakukan filtering

Setelah didapatkan data yang sudah dibersihkan selanjutnya dilakukan proses *filtering*. Pada tahap ini dilakukan penyaringan kata-kata yang penting dan menghilangkan kata-kata yang tidak berpengaruh seperti kata hubung, imbuhan atau kata-kata yang menggunakan huruf asing.

**Tabel 4.2** Perbedaan *Tweet* Sebelum dan Sesudah Dilakukan Filtering

<b><i>Tweet sebelum dilakukan filtering</i></b>	<b><i>Tweet sesudah dilakukan filtering</i></b>
صار فيها عملية تقسيم مقابل انخفاض بالعمله هذا الى اعرفه والمبلغ بسقط الى حطيته بتوصية من شخص ف ما عرف عنها كثير そして配られる ホロリ	

Pada Tabel 4.2 dapat dilihat bahwa *Tweet* yang menggunakan huruf asing dihilangkan pada prosesnya sehingga tidak mengganggu proses pengolahan data yang dilakukan pada proses berikutnya.

### 3. Melakukan Tokenisasi

Tokenisasi adalah proses yang dilakukan untuk memisahkan kata yang terdapat pada tiap kalimat. Masing-masing kata yang sudah terpisah disebut sebagai token. Tokenisasi ini dilakukan untuk mempermudah perhitungan kata nama *cryptocurrency* yang terdapat dalam data. Karena setiap kata yang muncul dalam data akan dihitung frekuensi kata tersebut muncul pada periode data tersebut. Proses tokenisasi dapat dilihat pada diagram alir berikut.

**Tabel 4.3** Hasil Tokenisasi yang Dilakukan

Crypto Name	Crypto Symbol	Total Mentioned
<b>Bitcoin</b>	BTC	5033
<b>Ethereum</b>	ETH	3885
<b>Tether</b>	USDT	420
<b>BNB</b>	BNB	864
<b>USD Coin</b>	USDC	64
<b>Solana</b>	SOL	1254
<b>Cardano</b>	ADA	607
<b>Terra</b>	LUNA	186
<b>XRP</b>	XRP	1466
<b>Avalanche</b>	AVAX	75

Pada tabel 4.3 dapat dilihat contoh perhitungan dari tiap crypto yang muncul pada tiap bulannya. Pada Tabel 4.3 dapat dilihat bahwa bitcoin muncul sebanyak 5033 kali selama periode waktu tersebut. Proses ini kemudian dilakukan juga pada bulan-bulan lainnya sehingga akan mendapatkan hasil untuk satu tahun pada tahun 2021.

#### 4.1.3 Data *Cryptocurrency Trending Twitter*

Pada tahap ini dilakukan perhitungan terhadap frekuensi *crypto* yang muncul pada tiap periode yang digunakan. Perhitungan dilakukan menggunakan *Excel* dengan mencocokkan nama *crypto* dan simbol dari *crypto* tersebut dengan perhitungan tiap kata pada tahapan sebelumnya. Perhitungan dilakukan menggunakan fungsi SUMIF setelah didapatkan list *crypto* dan simbol yang telah beredar. Sepuluh *cryptocurrency* yang paling banyak disebutkan pada periode Januari hingga Desember 2021 adalah seperti dapat dilihat pada Tabel 4.4.

**Tabel 4.4** Sepuluh *Crypto* yang Masuk ke Trending *Twitter* pada Tahun 2021

No	Nama Crypto	Simbol	Total
1	Arweave	AR	426250
2	Ren	REN	79426
3	ThunderCore	TT	66764
4	Bitcoin	BTC	64739
5	TerraUSD	UST	61984
6	Amp	AMP	59083
7	Ethereum	ETH	52691
8	Aragon	ANT	51953
9	Kin	KIN	49203
10	Huobi Token	HT	44364

Didapatkan bahwa *Arweave* atau AR adalah *crypto* yang paling sering disebutkan di *Twitter* pada tahun 2021 dengan jumlah total muncul hingga lebih dari 426000 pada tahun tersebut.

Selanjutnya dilakukan pengambilan data harga *closing* dari 10 *cryptocurrency* yang sudah didapatkan. Pengambilan data menggunakan modul *yfinance* pada *software Jupyter Notebook* dengan rentang waktu yang akan diambil adalah 1 Januari hingga 31 Desember 2021. Selain itu, mata uang yang digunakan adalah dollar Amerika atau *USD*.

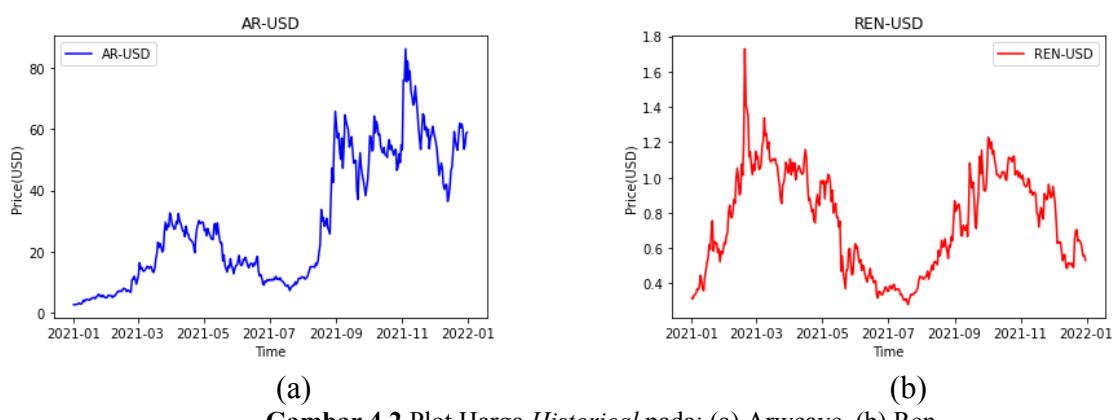
## 4.2 Statistika Deskriptif

Untuk melihat karakteristik dari tiap *crypto* yang akan digunakan dilakukan analisis statistika deskriptif. Statistika deskriptif dilakukan menggunakan harga penutupan dari *crypto* yang digunakan. Dimana mata uang yang digunakan adalah *USD* Dollar.

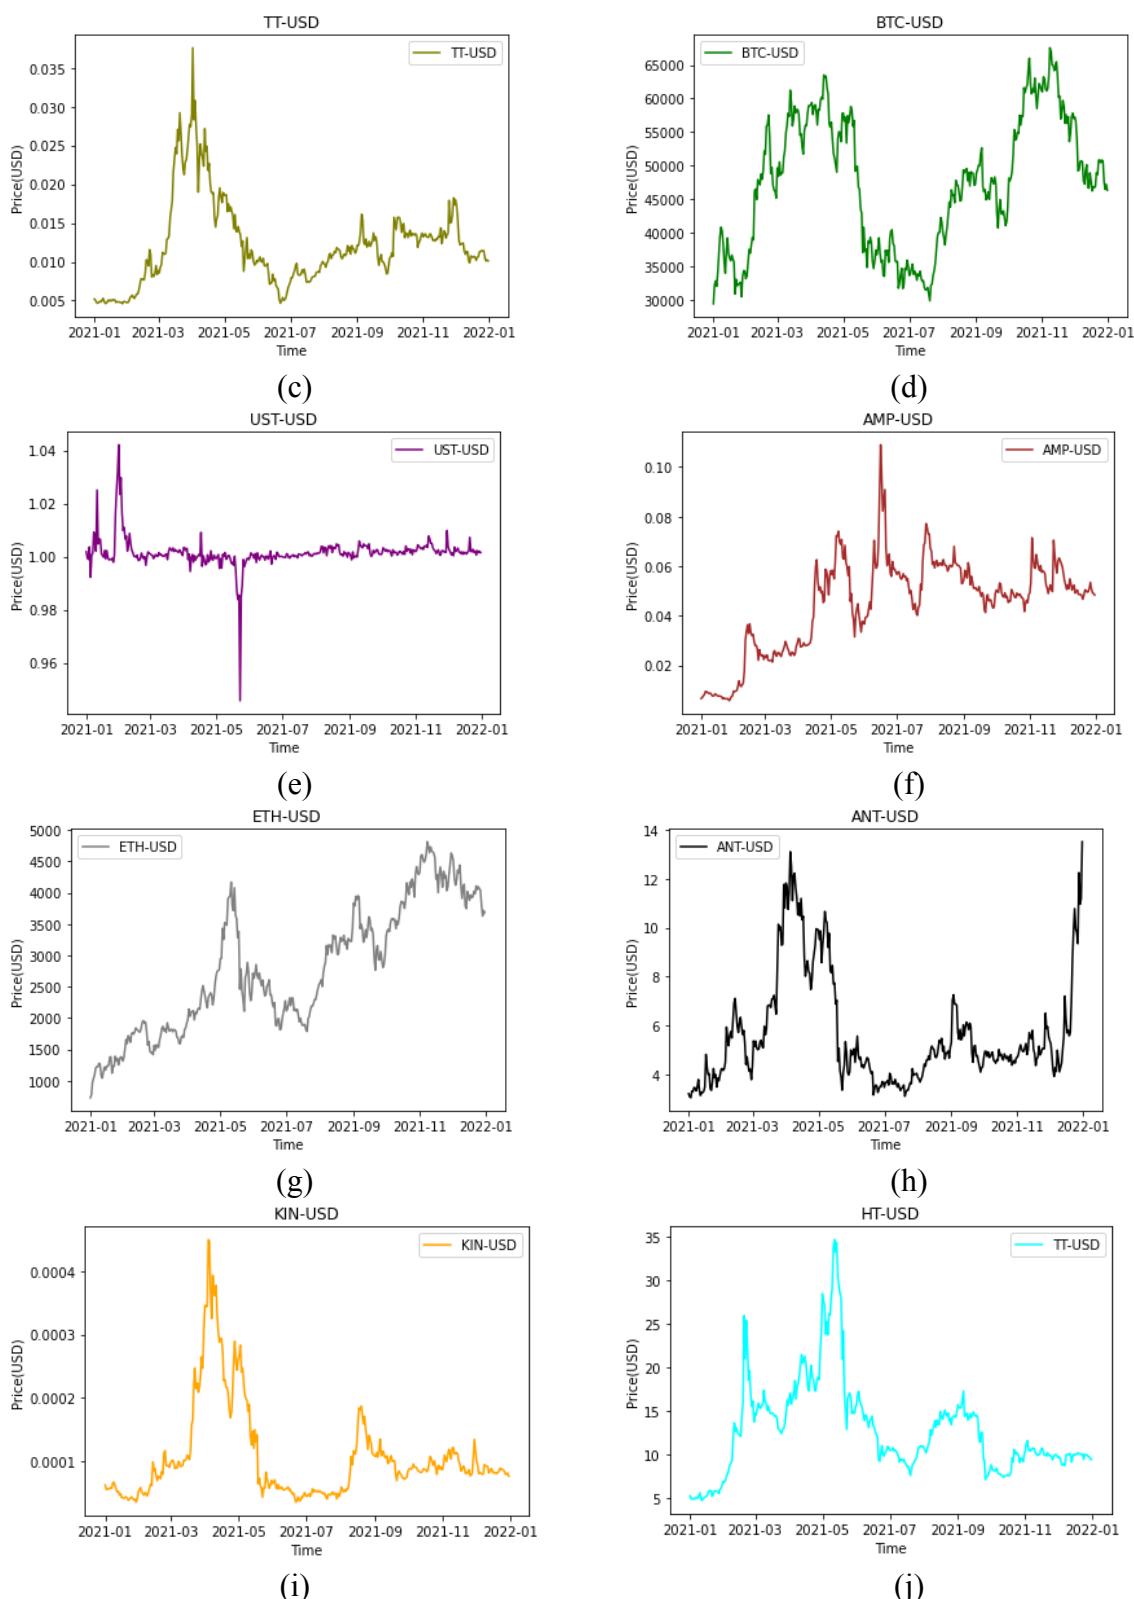
**Tabel 4.5** Hasil Statistika Deskriptif untuk tiap *Crypto* yang Digunakan

Crypto	Rata-rata	Tertinggi	Terendah	Standar Deviasi
<b>AMP</b>	0,045	0,109	0,006	0,019
<b>ANT</b>	5,672	13,505	3,059	2,256
<b>AR</b>	29,259	86,279	2,573	21,015
<b>BTC</b>	47436,930	67566,828	29374,150	9787,635
<b>ETH</b>	2778,354	4812,087	730,368	1023,544
<b>HT</b>	12,775	34,650	4,663	5,454
<b>KIN</b>	0,000	0,000	0,000	0,000
<b>REN</b>	0,753	1,729	0,279	0,282
<b>TT</b>	0,012	0,038	0,005	0,006
<b>UST</b>	1,001	1,042	0,946	0,006

Berdasarkan Tabel 4.5 dapat diketahui bahwa AMP memiliki nilai rata-rata \$0,045 serta memiliki nilai tertinggi \$0,109 dan terendah \$0,0057. Pada ANT nilai rata-ratanya yaitu \$5,672 dengan nilai tertinggi \$13,5 dan terendah \$3,06. AR dengan nilai rata-rata \$29,26 serta nilai tertinggi dan terendah \$86,28 dan \$2,57. BTC memiliki nilai rata-rata paling tinggi dibanding *crypto* lainnya dengan \$47436,93 dengan nilai tertinggi pada \$67566,83 dan terendah \$29374,15. ETH memiliki nilai rata-rata \$2778,354 dengan nilai tertinggi \$4812,08 dan terendah \$730,37. HT memiliki rata-rata \$12,77 dengan nilai tertinggi \$34,65 dan terendah \$4,66. KIN memiliki nilai rata-rata terendah dibanding *crypto* lainnya dengan \$0,0001 dan nilai tertinggi \$0,00045 dan terendah \$0,000036. REN memiliki nilai rata-rata \$0,753 dengan nilai tertinggi \$1,73 dan terendah \$0,279. TT memiliki nilai rata-rata \$0,012 dengan nilai tertinggi \$0,038 dan terendah \$0,0056. Dan terakhir UST memiliki nilai rata-rata \$1,0015 dengan nilai tertinggi \$1,042 dan terendah \$0,9457. Grafik historical data dapat dilihat pada Gambar 4.2.



**Gambar 4.2** Plot Harga *Historical* pada: (a) Arweave, (b) Ren



**Gambar 4.2** Plot harga *historical*: (c) Thundercoin, (d) Bitcoin, (e) Terra, (f) AMP, (g) Ethereum, (h) Aragon (i) Kin, (j) Huobi Token (lanjutan)

Berdasarkan gambar 4.2 dapat dilihat bahwa dalam jangka waktu 1 tahun crypto memiliki pergerakan harga dengan volatilitas tinggi. Seperti contohnya bitcoin pada Gambar 4.2 poin d yang sempat mengalami penurunan yang sangat besar dari nilai sebesar \$60000

menjadi \$30000 atau turun sebesar 50% hanya dalam jangka waktu 2 bulan, tetapi kemudian mengalami kenaikan lagi hingga mencapai \$65000 dalam waktu 3 bulan atau sebesar 120%. Contoh lainnya adalah Terra (UST) pada Gambar 4.2 poin e yang memiliki nilai stabil pada \$1 tiba-tiba mengalami penuruan menjadi \$0,95 dan kembali stabil menjadi \$1 dalam waktu beberapa hari.

### 4.3 Forecasting menggunakan Stacked LSTM

Pada tahap ini dilakukan forecasting menggunakan *Long Short-Term Memory* setelah didapatkan data harga *historical* dari sepuluh *cryptocurrency*. Pada *forecasting* LSTM ini akan digunakan 2 parameter yang dibedakan yaitu *unit* dan *batch*. *Unit* yang akan digunakan adalah 100 dan 200. *Unit* tersebut digunakan setelah dilakukan proses *trial and error* yang menghasilkan bahwa unit 100 dan 200 merupakan unit dengan nilai MAPE kurang dari 10%. Sedangkan untuk *batch* yang akan digunakan adalah 8 dan 16 digunakan karena menurut Ya Gao (2021) batch 8 dan 16 menghasilkan nilai MSE yang paling kecil. Pada Tabel 4.6 dapat dilihat nilai MAPE dan MSE dari proses *trial and error* pada *crypto* BTC.

**Tabel 4.6** Nilai MAPE dan MSE trial and error pada BTC

Crypto	Unit	Batch	MAPE	MSE
BTC	100	8	0,072175	3697809,8
	200	8	0,141279	20586647
	250	8	0,138361	17491492
	300	8	0,217304	26106284

Berdasarkan Tabel 4.6 dapat dilihat bahwa penggunaan unit 250 dan 300 menghasilkan nilai MAPE yang lebih rendah dibandingkan dengan unit 100 dan 200. Nilai MSE yang dihasilkan oleh unit 250 dan 300 juga lebih besar dibandingkan dengan unit 100 dan 200 yang menginterpretasikan bahwa keakuratan hasil forecasting pada unit 250 dan 300 lebih tidak akurat dibandingkan dengan unit 100 dan 200.

Dengan 2 parameter tersebut didapatkan 4 kombinasi yang berbeda untuk tiap *forecasting* yang dilakukan. Hal tersebut dilakukan untuk mengetahui *unit* dan *batch* yang paling optimal untuk digunakan pada *forecasting*.

#### 4.3.1 Pelatihan data Training dan Testing

Pembagian data *training* dan *testing* menggunakan rasio 80:20. LSTM yang digunakan adalah *stacked LSTM* dimana digunakan 4 layer di dalam prosesnya. Penggunaan 4 layer dikarenakan pada penelitian oleh Zrara (2020) penggunaan 4 layer berhasil memprediksi harga saham pada pasar Maroko dengan akurasi hingga lebih dari 93%. Digunakan *Optimizer Adam* di dalam proses LSTM. Dilakukan 4 jenis *forecasting* pada tiap *cryptocurrency* dengan kombinasi parameter seperti pada Tabel 4.7.

**Tabel 4.7** Kombinasi Parameter *Forecasting* yang Digunakan

No	Units	Batch	Layer
1	100	8	4
2	100	16	4
3	200	8	4
4	200	16	4

Dari keempat kombinasi tersebut, kemudian akan dilakukan perhitungan MAPE dan MSE. Kriteria pemilihan model adalah model dengan MAPE yang kurang dari 10% dan MSE terkecil. Dengan penjelasan nilai MAPE dapat dilihat pada Tabel 4.8.

**Tabel 4.8** Range Nilai MAPE

Range MAPE	Arti
< 10%	Kemampuan model peramalan sangat baik
10% – 20%	Kemampuan model peramalan baik
20% – 50%	Kemampuan model peramalan layak
> 50%	Kemampuan model peramalan buruk

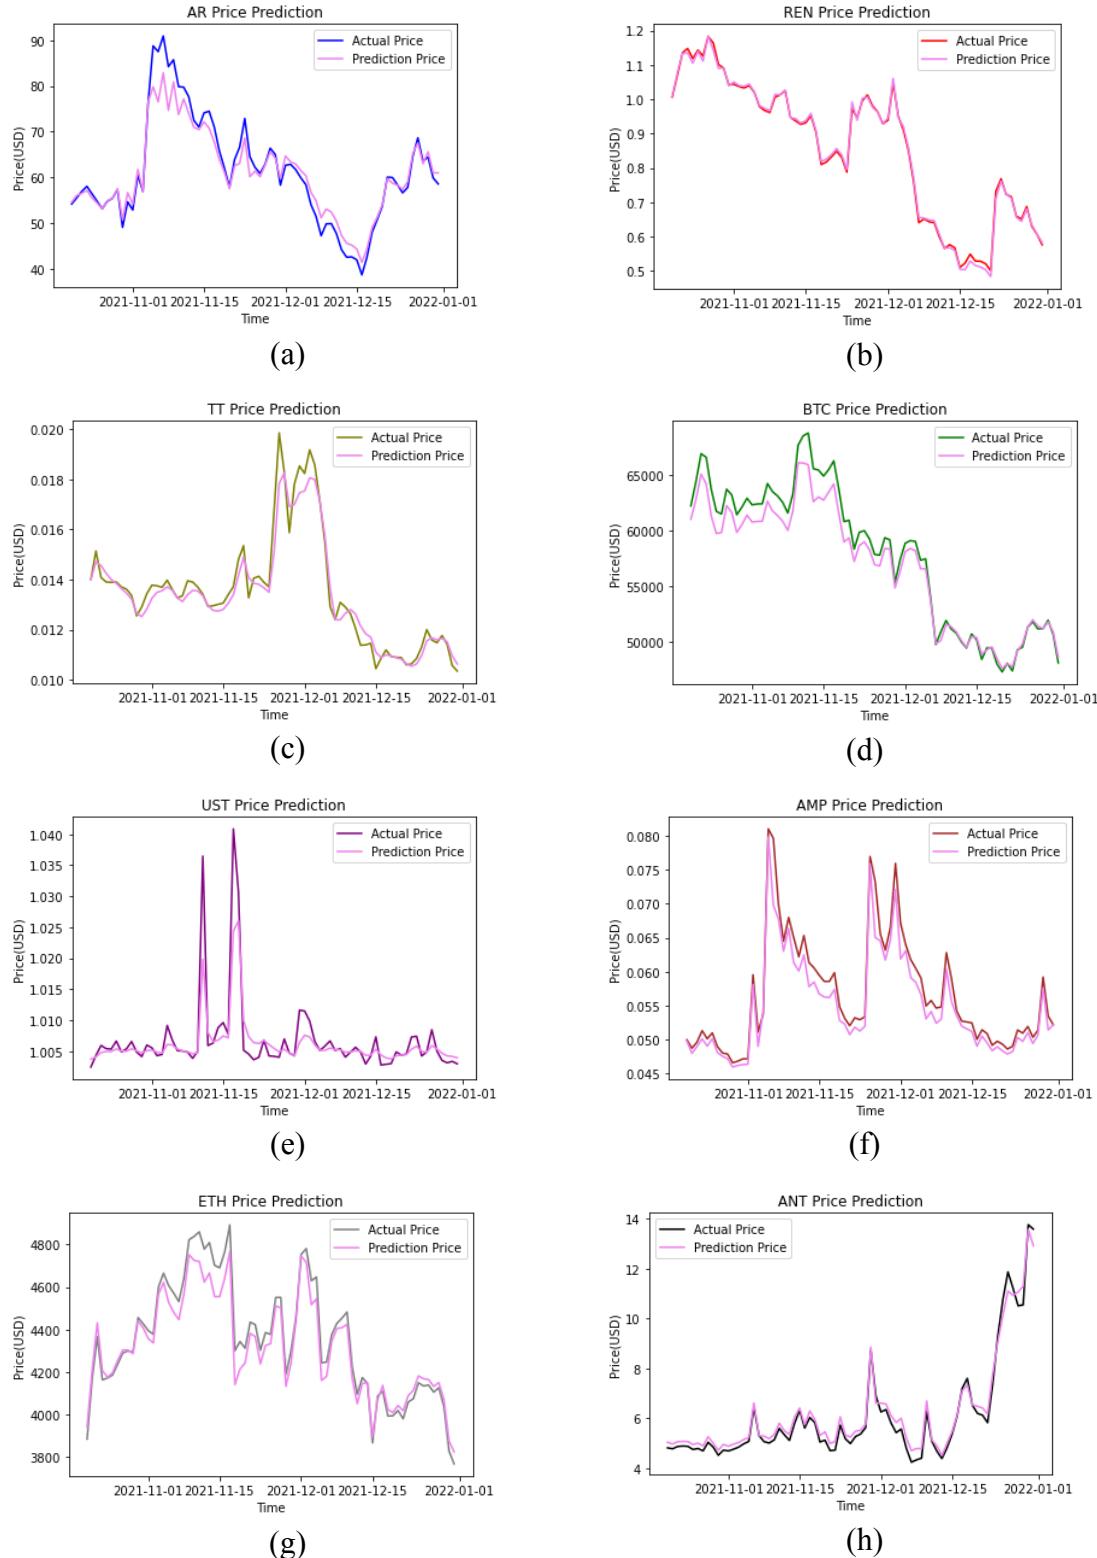
Data training akan digunakan untuk melatih model yang digunakan. Kemudian setelah dilakukan pelatihan menggunakan data *training*, model akan diuji menggunakan data *testing* dan dilihat nilai MAPE dan MSE dari hasil yang didapat. Didapatkan hasil sebagai berikut dari *fitting* yang telah dilakukan.

**Tabel 4.9** Hasil MAPE dan MSE dari fitting yang telah dilakukan

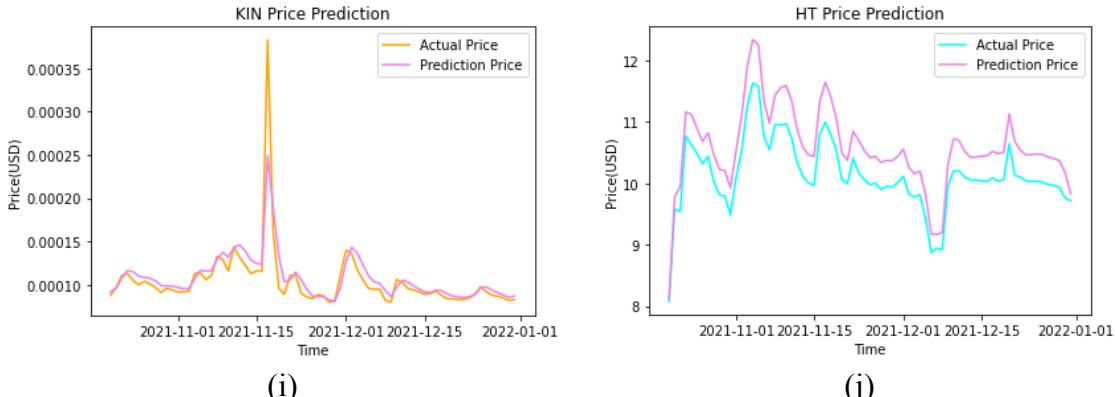
Crypto	Units	Batch	Training		Testing	
			MAPE	MSE	MAPE	MSE
<b>Arweave (AR)</b>	100	16	$6,35 \times 10^{-2}$	$6,45 \times 10^1$	$2,97 \times 10^{-2}$	$3,01 \times 10^1$
	200	8	$3,89 \times 10^{-2}$	$4,26 \times 10^1$	$2,33 \times 10^{-2}$	$2,55 \times 10^1$
<b>REN (REN)</b>	100	8	$6,20 \times 10^{-2}$	$7,14 \times 10^{-3}$	$2,68 \times 10^{-2}$	$3,09 \times 10^{-3}$
	100	16	$1,57 \times 10^{-2}$	$6,36 \times 10^{-3}$	$1,51 \times 10^{-2}$	$3,22 \times 10^{-3}$
<b>ThunderCore (TT)</b>	100	8	$3,28 \times 10^{-2}$	$3,30 \times 10^{-6}$	$8,24 \times 10^{-3}$	$1,10 \times 10^{-6}$
	200	8	$3,76 \times 10^{-2}$	$2,40 \times 10^{-6}$	$7,19 \times 10^{-2}$	$1,44 \times 10^{-6}$
<b>Bitcoin (BTC)</b>	100	8	$1,88 \times 10^{-2}$	$7,87 \times 10^6$	$7,22 \times 10^{-2}$	$3,70 \times 10^6$
	200	8	$3,62 \times 10^{-2}$	$8,93 \times 10^6$	$8,26 \times 10^{-2}$	$4,15 \times 10^6$
<b>TerraUSD (UST)</b>	100	8	$5,27 \times 10^{-2}$	$9,33 \times 10^{-5}$	$1,07 \times 10^{-2}$	$4,38 \times 10^{-5}$
	200	8	$2,55 \times 10^{-2}$	$9,11 \times 10^{-5}$	$2,22 \times 10^{-2}$	$4,24 \times 10^{-5}$
<b>Amp (AMP)</b>	100	8	$9,72 \times 10^{-2}$	$6,27 \times 10^{-5}$	$2,92 \times 10^{-2}$	$2,94 \times 10^{-5}$
	200	16	$9,41 \times 10^{-2}$	$4,20 \times 10^{-5}$	$5,56 \times 10^{-2}$	$2,90 \times 10^{-5}$
<b>Ethereum (ETH)</b>	100	8	$9,20 \times 10^{-2}$	$5,36 \times 10^4$	$2,26 \times 10^{-2}$	$2,32 \times 10^4$
	200	8	$6,66 \times 10^{-2}$	$9,63 \times 10^4$	$2,20 \times 10^{-2}$	$4,84 \times 10^4$
<b>Aragon (ANT)</b>	200	8	$8,20 \times 10^{-2}$	$0,14 \times 10^1$	$7,46 \times 10^{-2}$	$6,86 \times 10^{-1}$
	200	16	$8,66 \times 10^{-2}$	$0,19 \times 10^1$	$4,62 \times 10^{-2}$	$7,01 \times 10^{-1}$
<b>Kin (KIN)</b>	200	16	$1,15 \times 10^{-2}$	$1,97 \times 10^{-9}$	$1,10 \times 10^{-2}$	$1,36 \times 10^{-9}$
	200	8	$3,04 \times 10^{-2}$	$2,88 \times 10^{-9}$	$8,22 \times 10^{-2}$	$1,34 \times 10^{-9}$
<b>Huobi Token (HT)</b>	100	8	$6,82 \times 10^{-2}$	$0,12 \times 10^1$	$8,16 \times 10^{-2}$	$4,07 \times 10^{-1}$
	200	8	$9,27 \times 10^{-2}$	$5,39 \times 10^{-1}$	$5,24 \times 10^{-2}$	$3,60 \times 10^{-1}$

Berdasarkan Tabel 4.9, berdasarkan nilai MAPE dan MSE, dimana dipergunakan nilai MAPE yang kurang dari 10% yang kemudian dilakukan perbandingan terhadap nilai MSE yang paling kecil didapatkan model terbaik yang dapat digunakan untuk AR adalah model dengan unit=200 dan batch=8 dengan nilai MAPE 2% dan MSE 25,5. REN model dengan unit=100 dan batch=8 memiliki nilai MAPE 2% dan MSE 0,003. TT model dengan unit=100 dan batch=8 dengan MAPE 0,8% dan MSE  $1,1 \times 10^{-6}$ . BTC model dengan unit=100 dan batch=8 dengan MAPE 7%. UST model dengan unit=200 dan batch=8 dengan MAPE 0,2%. AMP model dengan unit=200 dan batch=16 dengan MAPE 5%. ETH model dengan unit=100 dan batch=8 dengan MAPE 2%. ANT model dengan unit=200 dan batch=8 dengan MAPE 7%. KIN model dengan unit=200 dan batch=8 dengan MAPE 8%. HT USD model dengan unit=200 dan batch=8 serta MAPE sebesar 5%.

Hasil dari *fitting* untuk model yang digunakan dapat dilihat pada Gambar 4.3. Berikut adalah grafik data harga hasil *fitting* pada data *testing* dari *Stacked Long Short-Term Memory* yang telah dilakukan.



**Gambar 4.3** Plot Hasil Peramalan Long Short-Term Memory pada Data Testing (a) Arweave, (b) Ren, (c) Thundercoin, (d) Bitcoin, (e) Terra, (f) AMP, (g) Ethereum

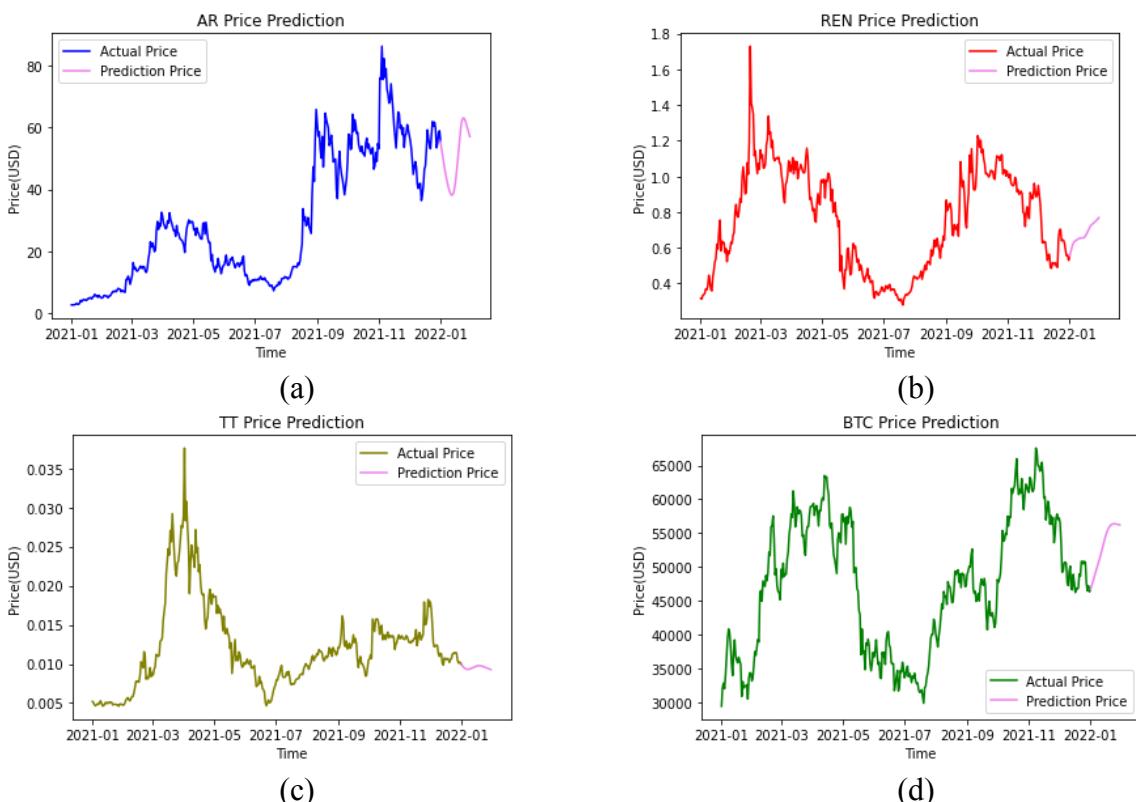


**Gambar 4.3** Plot Hasil Peramalan Long Short-Term Memory pada Data Testing (h) Aragon (i) Kin, (j) Huobi Token (lanjutan)

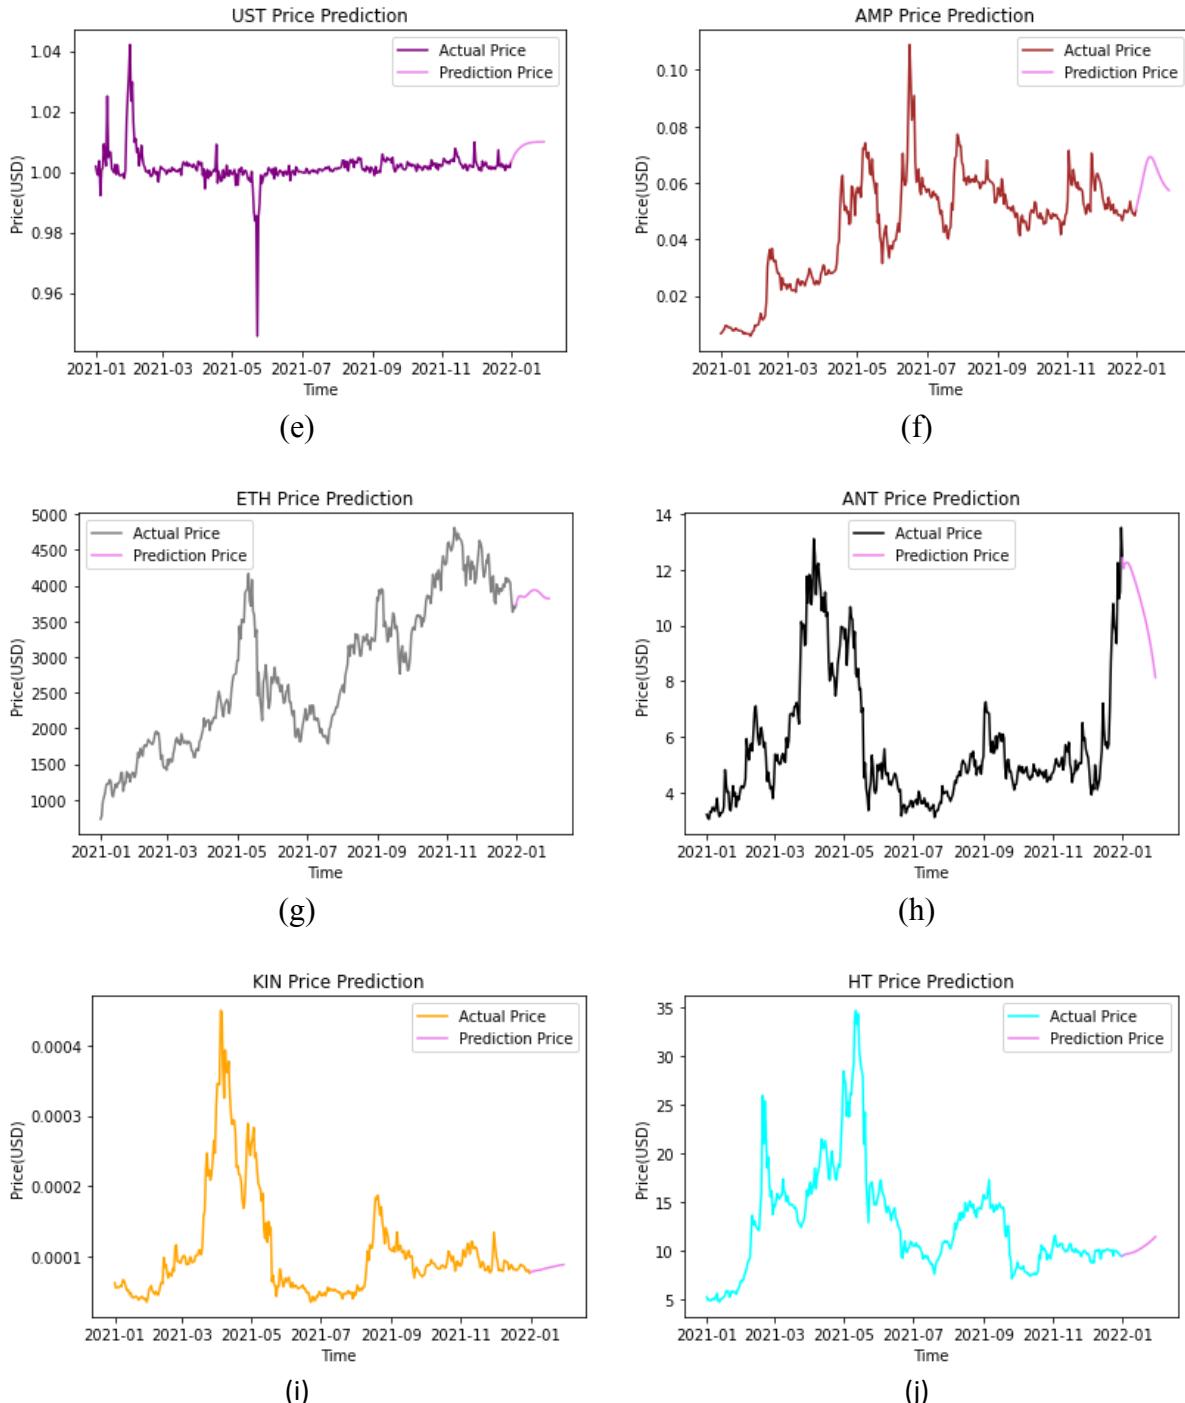
Berdasarkan Gambar 4.3 dapat dilihat bahwa hasil prediksi pada data testing dapat mengikuti pola yang dimiliki oleh tiap *crypto*. Seperti pada Gambar 4.3 poin e yaitu REN, hasil prediksi dapat mengikuti pola data *actual* dengan baik dan bisa memprediksi kenaikan dan penurunan harga dengan tepat. Begitu pula seperti Ethereum pada Gambar 4.3 pin g, hasil prediksi bisa memprediksi kenaikan dan penurunan harga dengan sesuai meskipun harga hasil prediksi dan data *actual* masih terdapat perbedaan.

#### 4.3.2 Hasil Peramalan Menggunakan *Stacked LSTM*

Setelah didapatkan model peramalan terbaik untuk setiap *crypto*, dilakukan *forecasting* untuk 30 hari kedepan atau untuk bulan Januari 2022. Hasil peramalan menggunakan model yang sesuai didapatkan hasil seperti dapat dilihat pada Gambar 4.4 untuk *forecasting* pada tiap *cryptocurrency*.



**Gambar 4.4** Plot Hasil Peramalan Long Short-Term Memory untuk 30 hari pada bulan januari 2022: (a) Arweave, (b) Ren, (c) Thundercoin, (d) Bitcoin



**Gambar 4.4** Plot Hasil Peramalan Long Short-Term Memory untuk 30 Hari pada Bulan Januari 2022: (e) Terra, (f) AMP, (g) Ethereum, (h) Aragon, (i) Kin, (j) Huobi Token (lanjutan)

Pada Gambar 4.4 dapat dilihat hasil prediksi dari tiap crypto untuk 30 hari pertama tahun 2022. Dimana jika dilihat pada *Arweave (AR)* pada poin a, hasil prediksi dapat mengikuti pola dari harga-harga sebelumnya dan menghasilkan pola *double-bottom*. Dapat dilihat pula pada grafik ANT pada poin h, bahwa setiap kali *crypto* tersebut mengalami kenaikan harga yang tinggi maka akan disusul dengan penurunan harga yang hampir sama besarnya dan pada prediksi yang dilakukan menghasilkan hasil menurun dari pola sebelumnya yang mengalami kenaikan harga. Pada poin f grafik AMP juga dapat dilihat terdapat pola harga yang cenderung naik dari waktu ke waktu dan hasil prediksi dari AMP juga menunjukkan hasil yang serupa. Berdasarkan hal tersebut dapat dilihat bahwa *forecasting*

menggunakan LSTM bisa mengingat pola-pola dari harga historis sebuah aset dan melakukan prediksi sesuai dengan pola harga historis tersebut.

#### 4.4 Pembentukan Portofolio Optimal menggunakan *Machine Learning*

Pembentukan portofolio optimal dilakukan menggunakan data awal yang sudah dimiliki yaitu data 10 crypto yang digunakan mulai 1 Januari hingga 31 Desember 2021 ditambah dengan data hasil *forecasting* menggunakan LSTM yang telah dilakukan sesuai dengan model yang terpilih untuk masing-masing *crypto* pada jangka waktu 30 hari pertama di tahun 2022. Pembentukan dilakukan menggunakan *machine learning* dengan metode *Hierarchical Risk Parity* dan *Nested Clustered Optimization* sehingga didapatkan perbandingan portofolio yang lebih baik untuk digunakan.

##### 4.4.1 *Hierarchical Risk Parity*

Metode *Hierarchical Risk Parity* akan membuat portofolio menggunakan diversifikasi risiko pada portofolio.

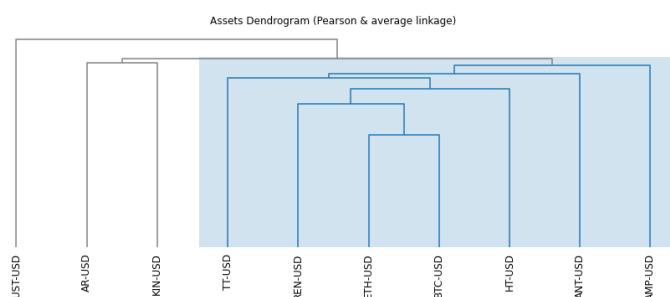
###### 1. *Tree Clustering*

Pada tahap ini dilakukan pengelompokkan aset berdasarkan dengan korelasi matriks dari tiap aset tersebut. Menggunakan persamaan 2.9 didapatkan korelasi dari tiap asset sebagai berikut seperti pada Tabel 4.10.

**Tabel 4.10** Korelasi dari Tiap Aset yang Digunakan Dalam Pembentukan Portofolio

	AMP	ANT	AR	BTC	ETH	HT	KIN	REN	TT	UST
<b>AMP</b>	1,00	0,34	0,26	0,43	0,43	0,30	0,29	0,41	0,31	0,17
<b>ANT</b>	0,34	1,00	0,27	0,43	0,48	0,38	0,29	0,44	0,38	0,17
<b>AR</b>	0,26	0,27	1,00	0,37	0,41	0,30	0,36	0,32	0,27	0,07
<b>BTC</b>	0,43	0,43	0,37	1,00	0,76	0,52	0,34	0,59	0,52	0,17
<b>ETH</b>	0,43	0,48	0,41	0,76	1,00	0,53	0,41	0,63	0,49	0,19
<b>HT</b>	0,30	0,38	0,30	0,52	0,53	1,00	0,30	0,52	0,37	0,20
<b>KIN</b>	0,29	0,29	0,36	0,34	0,41	0,30	1,00	0,37	0,32	0,26
<b>REN</b>	0,41	0,44	0,32	0,59	0,63	0,52	0,37	1,00	0,43	0,20
<b>TT</b>	0,31	0,38	0,27	0,52	0,49	0,37	0,32	0,43	1,00	0,14
<b>UST</b>	0,17	0,17	0,07	0,17	0,19	0,20	0,26	0,20	0,14	1,00

Berdasarkan Tabel 4.10 dapat dilihat korelasi dari tiap aset yang didapatkan dapat diketahui bahwa beberapa aset memiliki korelasi yang cukup tinggi satu sama lain ataupun sebaliknya. Untuk itu dilakukan pengelompokkan dari aset sesuai dengan korelasi yang didapatkan. Aset yang memiliki korelasi yang tinggi akan ditempatkan secara berdekatan. Hal tersebut dapat dilihat dari gambar berikut.

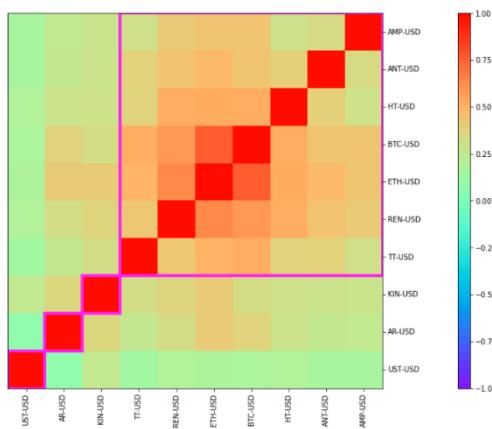


**Gambar 4.5** Hasil Tree Clustering Masing-Masing *Crypto* Menggunakan HRP

Berdasarkan Tabel 4.10 dan Gambar 4.5 dapat dilihat bahwa Ethereum dan Bitcoin memiliki nilai korelasi yang paling tinggi dibandingkan aset yang lain, yakni sebesar 0,76. Namun UST-USD memiliki nilai korelasi yang rendah. Nilai korelasi yang tinggi ini menunjukkan bahwa ketika *crypto* tersebut mengalami penurunan nilai, maka *crypto* yang memiliki nilai korelasi yang tinggi dengan *crypto* tersebut juga berpeluang untuk mengalami penurunan nilai. Begitu pula sebaliknya, ketika suatu *crypto* mengalami kenaikan nilai maka *crypto* yang memiliki korelasi tinggi dengan *crypto* tersebut akan mengalami kenaikan.

## 2. Diagonalisasi Kuasi

Pada tahap ini dilakukan penyusunan ulang terhadap tahap *tree clustering* sehingga membuat aset yang berkorelasi tinggi berada di dalam satu area.



**Gambar 4.6** Hasil Diagonalisasi Kuasi menggunakan Metode HRP

Berdasarkan Gambar 4.6 dapat dilihat bahwa UST-USD memiliki korelasi rendah dengan aset yang lain. Hal tersebut dikarenakan harga dari UST-USD yang cenderung lebih stabil dibandingkan dengan *crypto* lainnya. Begitu juga dengan AR-USD dan KIN USD yang memiliki rata-rata korelasi yang lebih rendah dibandingkan dengan *crypto* lainnya sehingga *crypto* tersebut membentuk klasternya masing-masing. Sedangkan untuk HT-USD, BTC-USD, ETH-USD, REN-USD, AMP-USD, TT-USD dan ANT-USD ditempatkan kedalam satu area yang sama karena memiliki nilai korelasi yang tinggi.

## 3. Weight Allocation

Langkah terakhir yang dilakukan dalam membentuk portofolio adalah melakukan pembobotan terhadap masing-masing aset yang digunakan dalam pembentukan portofolio. Pada pembobotan untuk masing-masing aset, *risk measure* yang digunakan adalah *variance*, dengan *risk free rate* 3,5% dan *linkage* yang digunakan adalah *average*. Hasil pembobotan untuk tiap aset dapat dilihat pada tabel 4.11.

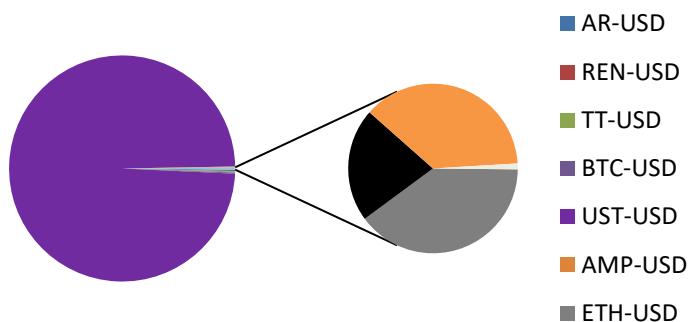
**Tabel 4.11** Hasil Pembobotan pada tiap *Crypto* Menggunakan Metode *Hierarchical Risk Parity* (HRP)

<i>Crypto</i>	<i>Weight</i>
AR	0,0018
REN	0,0014
TT	0,0015
BTC	0,0042
UST	0,9800
AMP	0,0008
ETH	0,0023

**Tabel 4.11** Hasil Pembobotan pada tiap *Crypto* Menggunakan Metode *Hierarchical Risk Parity* (HRP) (Lanjutan)

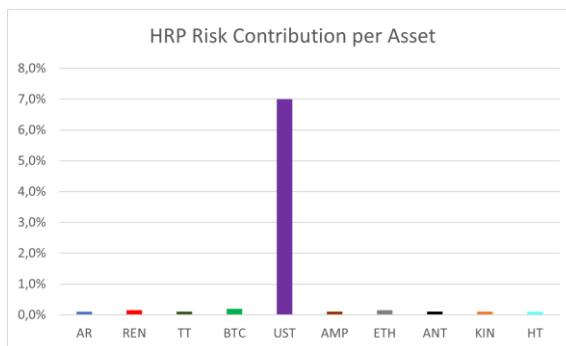
<i>Crypto</i>	Weight
ANT	<b>0,0008</b>
KIN	0,0011
HT	0,0016
<b>Total</b>	1

Berdasarkan Tabel 4.11 dapat dilihat bobot alokasi masing-masing crypto yang digunakan. Terdapat satu aset yang menguasai hampir keseluruhan portofolio yaitu UST. *Crypto* lain hanya mendapat sisa porsi sebesar 2% dari total keseluruhan portofolio sehingga membuat portofolio yang terbentuk tidak terdiversifikasi. Visualisasi bobot dari tiap crypto dapat dilihat pada Gambar 4.7.



**Gambar 4.7** Visualisasi Bobot tiap *Crypto* pada Portofolio HRP

Berdasarkan Gambar 4.7 dan Tabel 4.11 bahwa UST memiliki jumlah paling besar hingga 98% dari total portofolio dan AMP serta ANT mendapatkan proporsi yang paling kecil dari 10 aset yang digunakan yaitu sebesar 0,08%. Berdasarkan hasil visualisasi terhadap portofolio yang terbentuk, dapat dilihat bahwa portofolio yang terbentuk kurang terdiversifikasi dikarenakan terdapat satu aset yang nilainya jauh lebih besar daripada asset lainnya. Maksud dari diversifikasi sendiri adalah menempatkan aset tidak dalam 1 tempat saja atau dalam tugas akhir ini yaitu tidak menempatkan portofolio ke dalam satu aset *crypto* saja. Karena UST merupakan aset yang paling banyak mendapatkan proporsi didalam portofolio, maka UST juga memberikan kontribusi risiko paling tinggi terhadap portofolio yang dibentuk. Dimana kontribusi risiko dari tiap aset terhadap portofolio dapat dilihat pada Gambar 4.8.



**Gambar 4.8** Kontribusi Risiko tiap Aset terhadap Portofolio HRP

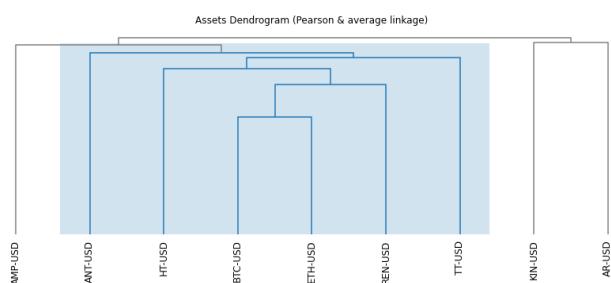
Dapat dilihat pada Gambar 4.8 bahwa UST-USD memberikan risiko paling tinggi terhadap aset yaitu sebesar 7% sedangkan aset lain memberikan kontribusi yang sangat kecil terhadap portofolio hingga mendekati 0%. Meskipun memiliki kontribusi risiko paling tinggi terhadap portofolio, tetapi risiko yang ditimbulkan tidak terlalu tinggi.

#### 4.4.2 Alternatif *Hierarchical Risk Parity*

Pada pembentukan portofolio HRP, dapat dilihat bahwa portofolio tidak terdiversifikasi dikarenakan ada satu *crypto* yang mendominasi di dalam portofolio yang telah terbentuk. *Crypto* tersebut adalah TerraUSD atau UST-USD. Hal tersebut dapat dikarenakan harga historicalnya yang cenderung lebih stabil dibandingkan dengan *crypto* lainnya dan juga korelasi yang rendah. Karena hal tersebut dibuatlah alternatif portofolio menggunakan metode HRP dengan tidak memasukkan TerraUSD ke dalam pembentukan portofolio. Dengan nilai korelasi yang dapat dilihat pada tabel 4.10. Selanjutnya dilakukan tahapan yang sama dengan metode HRP sebelumnya.

##### 1. Tree Clustering

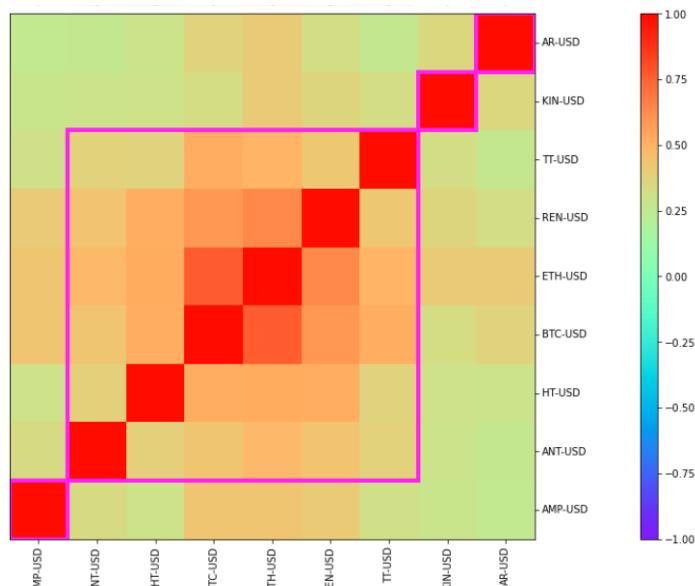
Berdasarkan nilai korelasi yang didapat selanjutnya akan dibentuk kluster sesuai dengan nilai korelasi masing-masing *crypto*. Hasil *tree clustering* dapat dilihat pada Gambar 4.9.



**Gambar 4.9** Hasil *Tree Clustering* Masing-Masing *Crypto* menggunakan Metode Alternatif HRP

##### 2. Diagonalisasi Kuasi

Pada tahap ini dilakukan penyusunan ulang terhadap tahap *tree clustering* sehingga membuat aset yang berkorelasi tinggi berada di dalam satu area.



**Gambar 4.10** Hasil Diagonalisasi Kuasi menggunakan Metode Alternatif HRP

Berdasarkan Gambar 4.10 dapat dilihat bahwa ANT, HT, BTC, ETH, REN, dan TT berada dalam satu klaster yang sama karena memiliki korelasi yang tinggi. Sedangkan AMP, KIN, dan AR membentuk klasternya masing-masing dikarenakan korelasinya yang rendah.

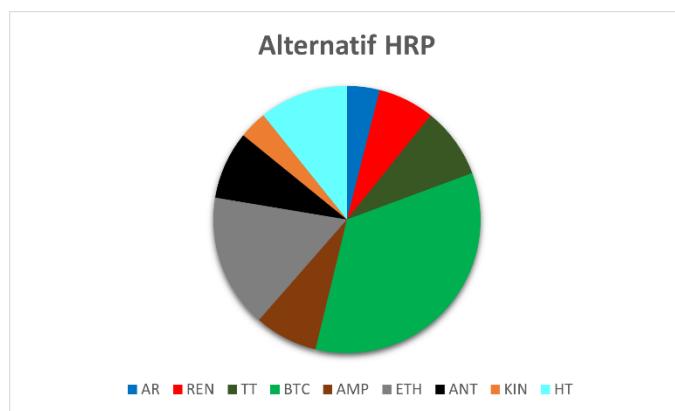
### 3. Weight Allocation

Selanjutnya dilakukan pembobotan terhadap masing-masing aset yang dipergunakan. Pada pembobotan ini risk measure yang digunakan adalah variance, dengan risk free rate 3,5% dan linkage average. Hasil pembobotan tiap aset dapat dilihat pada Tabel 4.12.

**Tabel 4.12** Hasil Pembobotan Alternatif pada tiap *Crypto* Menggunakan Metode *Hierarchical Risk Parity* (HRP)

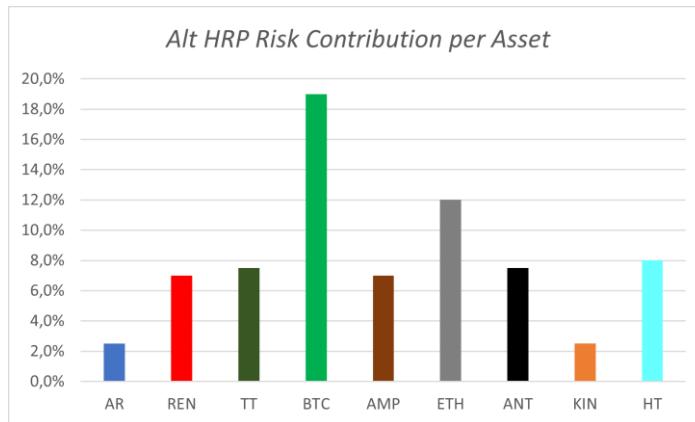
<i>Crypto</i>	Weight
AR	0,0395
REN	0,0683
TT	0,0857
BTC	0,3444
AMP	0,0766
ETH	0,1618
ANT	0,0823
KIN	0,0338
HT	0,1076
<b>Total</b>	1,0000

Didapatkan pembobotan untuk setiap aset seperti pada Tabel 4.12 dimana BTC mendapatkan bobot yang paling tinggi yaitu 34,44% diikuti oleh ETH dengan 16,18% dari total portofolio lalu HT dengan 10,76%, TT dengan 8,57%, ANT dengan 8,23%, AMP dengan 7,66%, REN dengan 6,83% alokasi dari total Portofolio, AR dengan 3,95% dan KIN dengan 3,38% dari total portofolio. Visualisasi dari bobot tiap aset terhadap total portofolio dapat dilihat dari Gambar 4.11.



**Gambar 4.11** Visualisasi Bobot tiap *Crypto* pada Portofolio Alternatif HRP

Pada Gambar 4.11 dapat dilihat bahwa portofolio lebih terdiversifikasi karena terbentuk dari beberapa aset. Dapat dilihat pula bahwa BTC mendapatkan porsi paling besar dalam portofolio. Berdasarkan hasil pembobotan yang telah didapatkan, dapat diketahui kontribusi risiko yang diberikan tiap aset kepada portofolio yang telah terbentuk.



**Gambar 4.12** Kontribusi Risiko tiap Aset terhadap Portofolio Alternatif HRP

Pada Gambar 4.12, dapat dilihat bahwa BTC memberikan kontribusi risiko paling tinggi terhadap portofolio dengan 19%, diikuti dengan ETH 12%, HT 8%, TT dan ANT dengan 7,5%, REN dan AMP 7%, AR dan KIN dengan 2,5%.

#### 4.4.3 Nested Clustered Optimization

Selanjutnya dilakukan pembentukan portofolio optimal menggunakan metode *Nested Clustered Optimization*. Optimisasi ini mengelompokkan aset kedalam klaster-klaster yang sesuai. Kemudian dari klaster-klaster tersebut ditentukan bobot untuk masing-masing klaster serta masing-masing aset yang ada didalam klaster tersebut.

##### 1. Pembentukan dan penentuan klaster

Pembentukan klaster dilakukan berdasarkan korelasi yang dimiliki oleh tiap aset sama seperti yang digunakan dalam metode *Hierarchical Risk Parity* yaitu membuat aset yang memiliki korelasi yang tinggi dalam satu klaster. Nilai korelasi dari tiap aset dapat dilihat pada tabel 4.10 dan penempatan aset berkorelasi tinggi dalam satu tempat bisa dilihat dari Gambar 4.6. Berdasarkan Gambar 4.6 dapat dilihat bahwa terbentuk empat klaster yang kemudian akan digunakan untuk pengalokasian bobot pada langkah berikutnya.

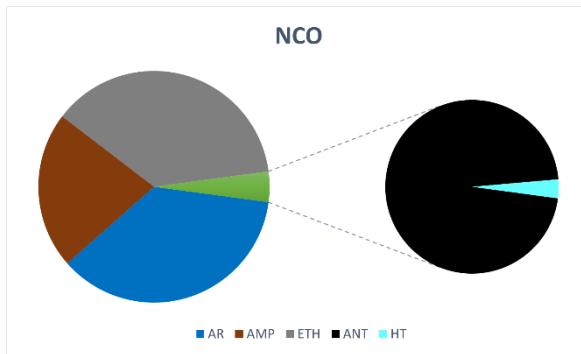
##### 2. Pembobotan

Menggunakan persamaan (2.22), (2.23), (2.24), (2.25) dan (2.26) didapatkan pembobotan untuk setiap aset seperti pada Tabel 4.13.

**Tabel 4.13** Hasil Pembobotan pada tiap Crypto menggunakan Metode Nested Clustered Optimization (NCO)

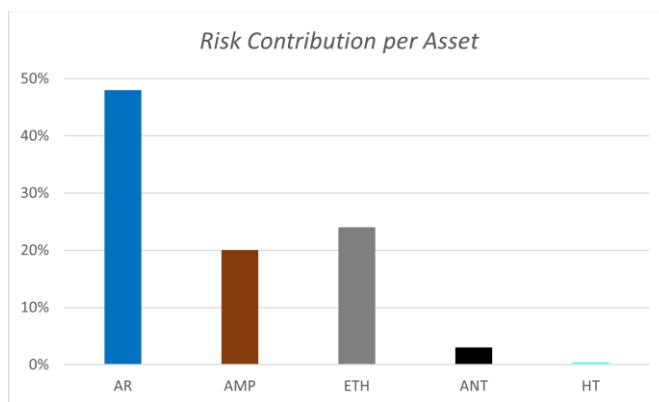
Crypto	Weight
AR	0,3636
AMP	0,2190
ETH	0,3747
ANT	0,0412
HT	0,0015
<b>Total</b>	<b>1,0000</b>

Seperti pada Tabel 4.13 didapatkan bahwa ETH-USD mendapatkan bobot yang paling tinggi yaitu 37,47% diikuti oleh AR-USD dengan 36,36% dari total portofolio lalu AMP-USD dengan 21,9%, ANT-USD dengan 4,12%, dan HT-USD dengan 0,15% alokasi dari total Portofolio. Visualisasi dari bobot tiap aset terhadap total portofolio dapat dilihat dari Gambar 4.13.



**Gambar 4.13** Visualisasi Bobot tiap *Crypto* pada Portofolio NCO

Berdasarkan Gambar 4.13 dapat dilihat bahwa portofolio tersusun atas 5 aset *crypto*. Terdapat 3 *crypto* penyusun utama portofolio yaitu AR, AMP, dan ETH. Berdasarkan hasil pembobotan yang telah didapatkan, dapat diketahui kontribusi risiko yang diberikan tiap aset kepada portofolio yang telah terbentuk.



**Gambar 4.14** Kontribusi Risiko Tiap Aset terhadap Portofolio NCO

Dapat dilihat pada Gambar 4.14 bahwa proporsi aset berbanding lurus dengan risiko yang diberikan yaitu semakin besar proporsi yang didapatkan semakin besar pula kontribusi risiko yang diberikan terhadap portofolio. Dimana AR-USD memberikan risiko kurang lebih sebesar 50%, AMP-USD sebesar 20, ETH-USD sebesar kurang lebih 25%, dan ANT-USD sebesar 3%.

#### 4.5 Perhitungan *Sharpe* dan *Sortino Ratio*

Setelah didapatkan komposisi dari portofolio optimal dilakukan perhitungan terhadap *Sharpe ratio* dan *Sortino Ratio*. Perhitungan dilakukan untuk melakukan perbandingan terhadap dua portofolio yang telah dibentuk menggunakan dua metode yang berbeda. Pada perhitungan ini dimisalkan bahwa modal awal yang dimiliki oleh investor adalah \$10000 yang kemudian disesuaikan dengan bobot yang didapatkan oleh masing-masing aset. Berikut adalah alokasi untuk masing-masing aset pada tiap portofolio.

**Tabel 4.14** Alokasi untuk Masing-masing Aset dalam Portofolio

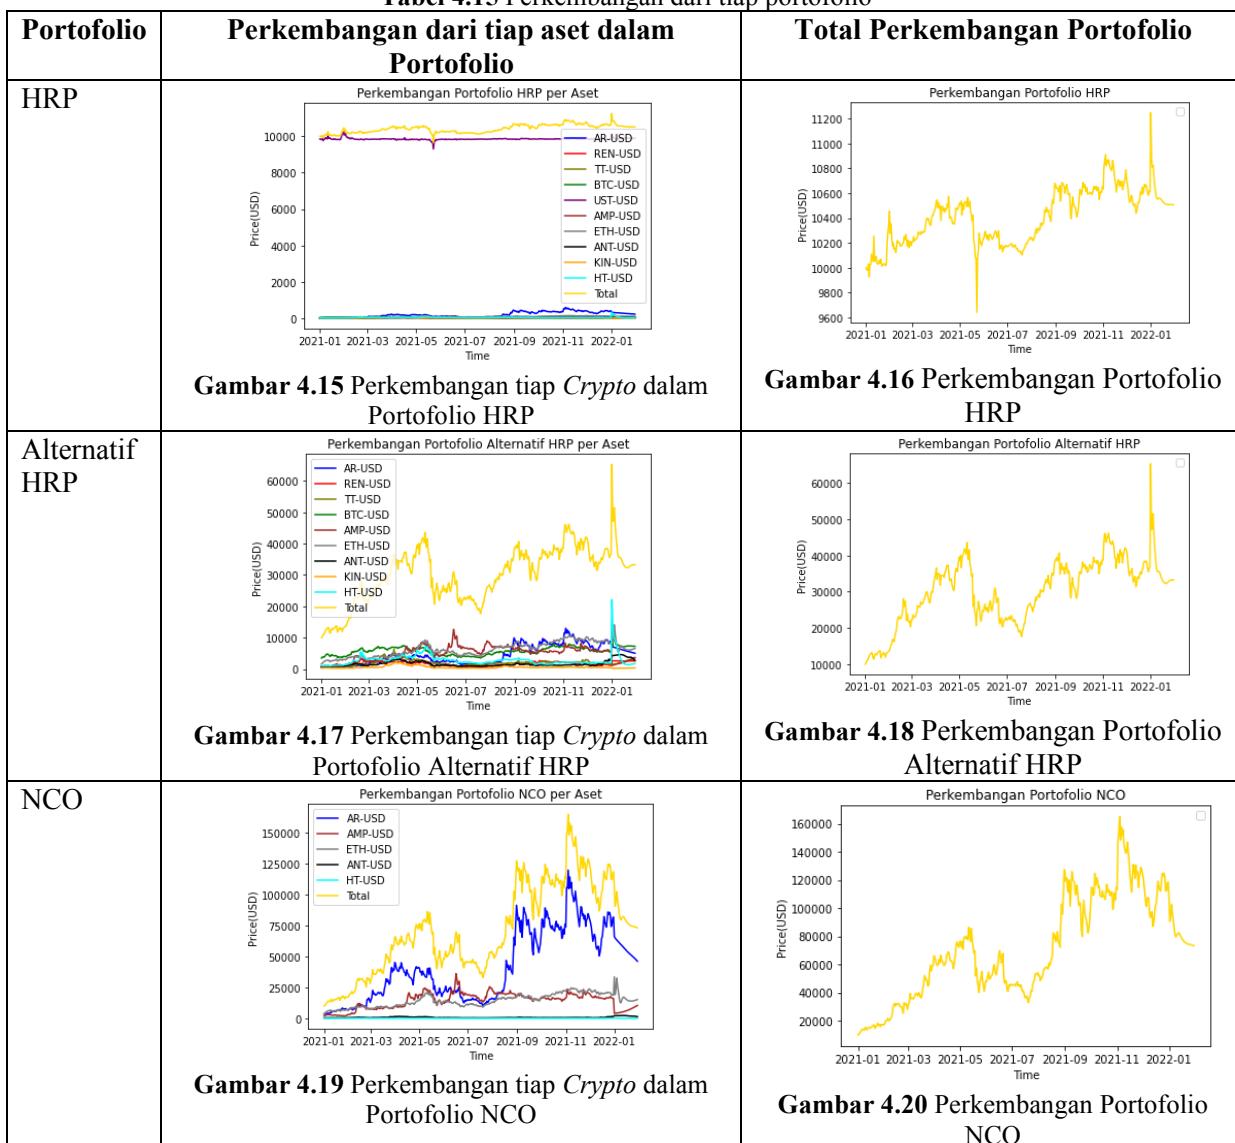
<i>Crypto</i>	HRP	Alt HRP	NCO
AR	\$18	\$395	\$3636
REN	\$14	\$683	0
TT	\$15	\$857	0
BTC	\$42	\$3444	0

**Tabel 4.14** Alokasi untuk Masing-masing Aset dalam Portofolio (lanjutan)

Crypto	HRP	Alt HRP	NCO
UST	\$9845	X	0
AMP	\$8	\$766	\$2190
ETH	\$23	\$1618	\$3747
ANT	\$8	\$823	\$412
KIN	\$11	\$338	0
HT	\$16	\$1076	\$ 15
Total	\$10000	\$10000	\$10000

Pada Tabel 4.14 dapat diketahui nilai awal dari masing-masing portofolio. Pada proses selanjutnya dapat dilihat perkembangan nilai dari tiap portofolio yang terbentuk. Perkembangan portofolio diamati mulai pada tanggal 1 Januari 2021 hingga 30 Januari 2022. Perkembangan dari tiap portofolio dapat dilihat pada Tabel 4.15.

**Tabel 4.15** Perkembangan dari tiap portofolio



Pada Tabel 4.15 dapat dilihat bahwa pada portofolio HRP nilai aset yang didapatkan di akhir periode yaitu sebesar \$10507,25. Pada portofolio alternatif HRP didapatkan nilai akhir

sebesar \$33304,23. Sedangkan pada portofolio NCO dapat dilihat bahwa pada akhir periode nilai dari investasi yang didapatkan meningkat hingga bernilai \$ 73302,61.

Pada perhitungan *Sharpe Ratio* dan *Sortino Ratio* diperlukan *risk free rate* sebagai batas minimal *return* investasi yang diinginkan. *Risk free rate* pada perhitungan ini akan menggunakan BI 7 Day (*Reverse*) *Repo Rate* yaitu sebesar 3,5% per tahun.

#### 4.5.1 Sharpe Ratio

Pada perhitungan *sharpe ratio* sesuai rumus 2.27, pertama diperlukan perhitungan *daily return* dari portofolio yang sudah dibentuk. Kemudian dilakukan perhitungan rata-rata *daily return* dari portofolio. Selain itu diperlukan perhitungan standar deviasi dari *return* portofolio yang dipunyai. Pada Tabel 4.16 merupakan hasil perhitungan untuk kedua portofolio.

**Tabel 4.16** Nilai Sharpe Ratio dari tiap portofolio

Portofolio	Rata-rata <i>Return</i>	<i>Risk Free-rate</i>	Standar deviasi Portofolio	<i>Sharpe Ratio</i>
<b>HRP</b>	0,000147	0,035	0,006614	0,008015
<b>Alt HRP</b>	0,005069	0,035	0,066585	0,074715
<b>NCO</b>	0,007532	0,035	0,070984	0,104776

Dilihat berdasarkan *sharpe ratio* pada Tabel 4.16 dapat diketahui bahwa portofolio menggunakan metode NCO menghasilkan nilai yang lebih baik yaitu sebesar 0,104776 dibandingkan dengan metode HRP yang memiliki *sharpe ratio* 0,008015 dan metode alternatif HRP dengan nilai *sharpe ratio* sebesar 0,074715. Hal tersebut menunjukkan bahwa pembentukan portofolio menggunakan metode NCO memberikan imbal hasil per risiko yang lebih baik dibandingkan dengan metode HRP dan alternatif HRP.

#### 4.5.2 Sortino Ratio

Pada perhitungan *Sortino Ratio* sesuai rumus 2.28 perbedaan yang dapat dilihat dibandingkan dengan *sharpe ratio* adalah *sortino ratio* menggunakan *downside risk* sebagai faktor pembagi. Hasil perhitungan *sortino ratio* dari dua portofolio dapat dilihat pada Tabel 4.17.

**Tabel 4.17** Nilai Sortino Ratio dari tiap Portofolio

Portofolio	Rata-rata <i>Return</i>	<i>Risk Free-rate</i>	<i>Downside Risk</i>	<i>Sortino Ratio</i>
<b>HRP</b>	0,000147	0,035	$2,045 \times 10^{-5}$	2,59235
<b>Alt HRP</b>	0,005069	0,035	$1,674 \times 10^{-3}$	2,97252
<b>NCO</b>	0,007532	0,035	$1,987 \times 10^{-3}$	3,743975

Berdasarkan nilai *sortino ratio* Tabel 4.17, dapat dilihat bahwa portofolio NCO menghasilkan hasil yang lebih baik yaitu sebesar 3,743975 dibandingkan dengan portofolio HRP dengan 2,59235 dan alternatif HRP dengan 2,97252. Hal tersebut menunjukkan bahwa pembentukan portofolio menggunakan metode NCO memberikan imbal hasil per *minimum acceptable return* yang lebih baik dibandingkan dengan metode HRP dan alternatif HRP.

(“*Halaman ini sengaja dikosongkan*”)

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan penelitian yang telah dilakukan, didapatkan kesimpulan sebagai berikut.

1. Sepuluh *crypto* yang menjadi trending di *Twitter* pada tahun 2021 adalah Arweave (AR-USD), REN(REN-USD), ThunderCore (TT-USD), Bitcoin (BTC), TerraUSD (UST), AMP(AMP-USD), Ethereum (ETH-USD), Aragon (ANT-USD), Kin (KIN-USD), Huobi Token (HT-USD).
2. Pada *forecasting* tiap *crypto* didapatkan model yang berbeda-beda untuk tiap *crypto*. *Unit* 100 cocok untuk digunakan pada REN, TT, BTC, dan ETH sedangkan *unit* 200 cocok untuk digunakan pada AR, UST, AMP, ANT, KIN, dan HT. Penggunaan *batch* 8 cocok untuk digunakan pada semua *crypto* kecuali AMP dengan *batch* 16.
3. Pada pembentukan portofolio optimal menggunakan metode HRP didapatkan komposisi portofolio yaitu UST-USD mendominasi proporsi dengan 0,98 dan *crypto* lainnya mendapatkan sisa proporsi sebesar 0,2. Diversifikasi portofolio kurang dapat dilihat dari portofolio ini meskipun risiko yang ditimbulkan kecil dikarenakan ada satu aset yang mendominasi dan harga asset tersebut selalu stabil di pasaran pada periode 2021. Dikarenakan adanya satu aset yang mendominasi pada pembentukan portofolio HRP maka dibentuklah suatu portofolio baru dengan menghilangkan aset *crypto* UST-USD dan didapatkan portofolio yang lebih terdiversifikasi dengan bobot masing-masing *crypto* dimana BTC dengan 34,44%, ETH dengan 16,18%, HT dengan 10,76%, TT dengan 8,57%, ANT dengan 8,23%, AMP dengan 7,66%, REN dengan 6,83%, AR dengan 3,95% dan KIN dengan 3,38% dari total portofolio.
4. Pada pembentukan portofolio optimal menggunakan metode NCO terdapat 5 aset *crypto* yang dimasukkan kedalam portofolio. Aset tersebut adalah ETH-USD dengan 37,47% dari total portofolio, AR-USD dengan 36,36%, AMP-USD dengan 22%, ANT-USD dengan 4,1%, dan HT-USD dengan 0,15% alokasi dari total Portofolio.
5. Berdasarkan nilai *Sharpe Ratio* didapatkan bahwa Portofolio NCO memiliki nilai *sharpe ratio* yang lebih baik yaitu sebesar 0,105 dibandingkan dengan portofolio HRP yang dengan 0,008 dan alternatif HRP dengan 0,075. Hal tersebut menunjukkan bahwa pembentukan portofolio menggunakan metode NCO memberikan imbal hasil per risiko yang lebih baik dibandingkan dengan metode HRP dan alternatif HRP. Selain itu pada perhitungan *Sortino ratio* Portofolio NCO juga menghasilkan nilai yang lebih baik yaitu sebesar 3,744 dibanding portofolio HRP dengan 2,592 maupun alternatif HRP dengan 2,973. Dilihat menggunakan dua indikator tersebut pembentukan portofolio menggunakan metode NCO lebih cocok untuk digunakan pada penelitian ini.

#### 5.2 Saran

Berdasarkan hasil penelitian tugas akhir yang sudah didapatkan, maka terdapat beberapa saran yang dapat diberikan yaitu.

1. Terdapat 1 *crypto* yang memiliki model dengan *batch* yang berbeda yaitu AMP yang menggunakan *batch* 16, saran untuk dilakukan pengkajian lebih lanjut mengenai alasan terjadinya perbedaan tersebut.
2. Pada LSTM menggunakan fungsi aktivasi *sigmoid* dan *tanh* dimana dua fungsi aktivasi tersebut memiliki fungsi yang sama tetapi perlu dikaji mengapa digunakan keduanya dan ditempatkan di tempat yang berbeda.

(“*Halaman ini sengaja dikosongkan*”)

## DAFTAR PUSTAKA

- Afrizal, Marliyah. (2021). “Analisis Terhadap Cryptocurrency (Perspektif Mata Uang, Hukum, Ekonomi Dan Syariah)”. **Jurnal Ekonomi Manajemen Bisnis** 22, 13-41.
- Ahmed, W. & Bahador, M. (2018). The accuracy of the LSTM model for predicting the S&P 500 index and the difference between prediction and backtesting, Stockholm: KTH Royal Institute of Technology.
- Arham, A. Z. (2018). Klasifikasi Ulasan Buku Menggunakan Algoritma Convolutional Neural Network – Long Short-Term Memory, Surabaya: Institut Teknologi Sepuluh Nopember.
- Arissinta, I. O., Sulistiyawati, I. D., Kurnianto, D. & Kharisudin, I. (2022). Pemodelan Time Series untuk Peramalan Web Traffic Menggunakan Algoritma Arima, LSTM, dan GRU, Semarang: Universitas Negeri Semarang.
- Azzam, R., Alkendi, Y., Taha, T., Huang, S. & Zweiru Y. (2021). A Stacked LSTM-Based Approach for Reducing Semantic Pose Estimation Error.
- Beck, M. (2020). How to Scrape Tweets With snscreape. [Online]. URL: <https://betterprogramming.pub/how-to-scrape-tweets-with-snscreape-90124ed006af>
- Bodie, Z., Kane A. & Markus, A.J. (2006), Investasi. Salemba Empat, Jakarta
- Cambridge Dictionary. (2021). Investment. [Online]. URL: <https://dictionary.cambridge.org/dictionary/english/investment>
- Choi, R. Y., Coyner, A. S., Jayashree, K. C., Chiang, M. F. & Campbell, J. P. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. [Online]. URL: <https://tvst.arvojournals.org/article.aspx?articleid=2762344>.
- Christopher, O. (2015). Understanding LSTM Networks. [Online]. URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- Dai, W., 1998. B-money. [Online]. <http://www.weidai.com/bmoney.txt>.
- De Prado, M. L. (2016). Building diversified portfolios that outperform out-of-sample. **Journal of Portfolio Management**, 1–31.
- De Prado, M. L. (2018). Advances in Financial Machine Learning. Hoboken: John Wiley & Sons.
- De Prado, M. L. (2019). A Robust Estimator of The Efficient Frontier, Ithaca: Cornell University.
- Donald C. (2021). Selama pandemi Covid-19, jumlah investor saham meningkat. Diakses melalui <https://www.sbm.itb.ac.id/id/2021/07/07/selama-pandemi-covid-19-jumlah-investor-saham-meningkat/> pada 13 Februari 2022 pukul 11.47 WIB.
- Eren, M. A., Erkul, M., Kaempf, K., Vasilauskaite, V. & Nino, A. F. (2021). Ask “Who”, Not “What”: Bitcoin Volatility Forecasting with Twitter Data, Zurich: ETH Zurich
- Fernandos, W. (2007). Analisis Kinerja Portfolio Yang Optimal (Studi Kasus Pada Saham-saham Yang Terdaftar dalam Indeks LQ45, Yogyakarta: Universitas Sanata Dharma.
- Giharta, A. S., & Sedana, I. B. P. (2017). Pembentukan Portofolio Optimal Pada Saham-Saham Perusahaan Sub-Sektor Konstruksi Bangunan di Bursa Efek Indonesia (Pendekatan Markowitz), Bali: Universitas Udayana.
- Gooding, S., & Briscoe, T. (2019). Active Learning for Financial Investment Reports.In Proceedings of the Second Financial Narrative Processing Workshop (FNP 2019) (pp. 25-32)
- Hartono, J. (2017). Teori Portofolio dan Analisis Investasi Edisi Kesebelas, Yogyakarta: BPFE

- Kamal, W., Gita, M. L., Henry, P. (2020). Pendekatan Long Short-Term Memory untuk Memprediksi Kondisi Motor 10 kV pada PLTU Batubara, Jakarta: Institut Teknologi PLN.
- Kandananond, K. (2012). A Comparison of Various Forecasting Methods for Autocorrelated Time Series, Valaya-Akongkorn: Rajabhat University.
- Liu, Y., Yang, C., Huang, K., & Gui, W. (2020). Non-ferrous Metals Price Forecasting Based on Variational Mode Decomposition and LSTM Network. *Knowledge-Based Systems*.
- Luca, B. (2020). Machine Learning Portfolio Optimization: Hierarchical Risk Parity and Modern Portfolio Theory, Roma: Libera Università Internazionale degli Studi Sociali.
- Marres, N. & Weltevrede, E. (2012). Scraping the Social: Issues in Live Research. University of Warwick.
- Myttenaere, A. D., Golden, B., Grand, B. L. & Rossi, F. (2016). Mean absolute percentage error for regression models. *Neurocomputing* 192, 38–48.
- Nainggolan, R., & Purba, E. (2019). Perbaikan Performa Cluster K-Means Menggunakan Sum Squared Error (Sse) Pada Analisis Online Customer Review Terhadap Produk Toko Online. Medan: Universitas Methodis Indonesia.
- Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. [Online]. URL: <https://bitcoin.org/bitcoin.pdf>.
- Nurfia, O. S. (2017). Kajian atas cryptocurrency sebagai alat pembayaran di Indonesia. Jakarta: BSI Jakarta
- Prayut, J. & Shashi, J. (2019). Can Machine Learning-Based Portfolios Outperform Traditional Risk-Based Portfolios? The Need to Account for Covariance Misspecification, Bengaluru: Indian Institute of Science
- Samira, Y., Dara, R., Mubareka, S., Papadopoulos, A. & Sharif, S. (2021). An analysis of COVID-19 vaccine sentiments and opinions on Twitter. *International Journal of Infectious Diseases* 108, 256-262.
- Sjostrand, D. & Behnejad, N. (2020). Exploration of Hierarchical Clustering in Long-Only Risk-Based Portfolio Optimization, Copenhagen: Copenhagen Business School.
- Sodhi, P., Awasthi, N., & Sharma, V. (2021). Introduction to Machine Learning and Its Basic Application in Python. Gwalior: Prestige Institute of Management.
- Sugiyono. (2015). Metode Penelitian Kombinasi (*Mix Methods*). Bandung: Alfabeta
- Sumathi, K., Kannan, S. & Nagarajan, K. (2016). Data Mining: Analysis of student database using Classification Techniques. *International Journal of Computer Applications* 141, 22-27.
- Xuan, H. L., Hung, V. H., Giha, L. & Sungho, J. (2019). Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting.
- Ya, G., Rong, W., Enmin, Z. (2021). Stock Prediction Based on Optimized LSTM and GRU Models, Beijing: School of Public Finance and Taxation, Central University of Finance and Economics.
- Yanming, G., Yu, L., Oerlemans, A., Songyang, L., Song, W., Michael, S. L. (2015). Deep learning for visual understanding: A review. *Neurocomputing* 187, 27-48.
- Zrara, L. (2020). Portfolio Optimization Using Deep Learning for The Moroccan Market, Ifran: Al Akhwayn University.

## LAMPIRAN

### Lampiran 1 Syntax Mining Data Twitter pada python Jupyter Notebook

```
import csv
import pandas as pd
import snscreape.modules.Twitter as snTwitter
csvFile = open('E:\\Materi Kuliah\\Data Twitter 1.csv', 'a', encoding = 'utf-8')
csvWriter = csv.writer(csvFile)

maxTweets = 72000
for i,tweet in enumerate(snTwitter.TwitterSearchScraper('Crypto OR crypto OR Cryptocurrencies OR cryptocurrencies' + 'since:2021-01-01 until:2021-01-31').get_items()):
    if i > maxTweets :
        break
    print(tweet.date, i)
    csvWriter.writerow([tweet.date, tweet.id, tweet.content,
    tweet.user.username.encode('utf-8'), tweet.user.verified, tweet.user.followersCount,
    tweet.user.friendsCount, tweet.mentionedUsers, tweet.replyCount, tweet.retweetCount,
    tweet.likeCount, tweet.media, tweet.lang.encode('utf-8'), tweet.user.location])

header_name = ['date', 'tweet_id', 'text', 'username', 'verified', 'followers','following',
    'mentioned users','retweet','like ', 'reply', 'media', 'language', 'location']
df = pd.read_csv("E:\\Materi Kuliah\\Data Twitter 1.csv", names=header_name)

import re
import nltk
from Sastrawi.Stemmer.StemmerFactory import StemmerFactory
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.feature_extraction.text import TfidfVectorizer
nltk.download('stopwords')
nltk.download('punkt')
from nltk.tokenize import word_tokenize
from nltk.corpus import stopwords
from nltk.stem import WordNetLemmatizer
text=df['text']
text

#Menghapus link
data_link=[]
for line in text:
    result=re.sub(r"https\S+"," ",line)
    data_link.append(result)

#Menghapus Retweet
data_rt=[]
for line in data_link:
    result=re.sub(r"RT"," ",line)
    data_rt.append(result)
```

## Lampiran 1 Syntax Mining Data Twitter pada python Jupyter Notebook (Lanjutan 1)

```
#Menghapus Username
data_uname=[]
for line in data_rt:
    result=re.sub(r"@\\S+"," ",line)
    data_uname.append(result)

#Menghapus Baris Baru
data_line=[]
for line in data_uname:
    result=re.sub("\n"," ",line)
    data_line.append(result)

#Menghapus Angka
data_num=[]
for line in data_line:
    result=re.sub("\d"," ",line)
    data_num.append(result)

#Menghapus Hashtag
data_hashtag=[]
for line in data_num:
    result=re.sub(r"#\\S+"," ",line)
    data_hashtag.append(result)

#Menghapus Emoticon
data_emoticon=[]
for line in data_hashtag:
    result=re.sub(r'<.*?>'," ",line)
    data_emoticon.append(result)

#Menghapus Punctuation
data_punc=[]
for line in data_emoticon:
    result=re.sub(r"[^\w\s]"," ",line)
    data_punc.append(result)

#Menghapus spasi berlebih
data_doublespace=[]
for line in data_punc:
    result=re.sub(r"\s+",' ',line)
    data_doublespace.append(result)

#Case Folding
data_casef=[]
for line in data_doublespace:
    a=line.lower()
    data_casef.append(a)
```

## Lampiran 1 Syntax Mining Data Twitter pada python Jupyter Notebook (Lanjutan 2)

```
factory=StemmerFactory()
stemmer=factory.create_stemmer()
df_stemmed=map(lambda x: stemmer.stem(x),data_casef)
data_stemmed=list(df_stemmed)

stopWords=set(stopwords.words('English'))

stopword=open("stopwords.txt").read()
stopword=set(stopword.split())
not_stopword={}
new_stopword=set([word for word in stopword if not word in stopword])

data_stop=[]
for line in data_stemmed:
    word_token=nltk.word_tokenize(line)
    word_token=[word for word in word_token if not word in stopword]
    data_stop.append(" ".join(word_token))

word_dict = {}

for full_text in data_stop:
    list_word = word_tokenize(full_text)

    for word in list_word:
        if word in word_dict.keys():
            word_dict[word] += 1
        else:
            word_dict[word] = 1
word_dict

data_items = word_dict.items()
data_list = list(data_items)
Hasil = pd.DataFrame(data_list)
Hasil

Hasil.to_excel('E:\\Materi Kuliah\\Data Twitter Januari 2021.xlsx', index = False)
```

## Lampiran 2 Syntax Forecasting LSTM pada software Jupyter Notebook

```
import math
import matplotlib.pyplot as plt
import keras
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.layers import *
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_error
from sklearn.model_selection import train_test_split
from keras.callbacks import EarlyStopping
import numpy as np
import pandas as pd
import yfinance as yf
import warnings

warnings.filterwarnings("ignore")
pd.options.display.float_format = '{:.4%}'.format

# Date range
start = '2021-01-01'
end = '2022-01-01'

edf = yf.download('AR-USD', start = start, end = end)
edf.tail()

training_set = edf.iloc[:292, 1:2].values
test_set = edf.iloc[292:, 1:2].values

# Feature Scaling
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)
# Creating a data structure with 30 time-steps and 1 output
X_train = []
y_train = []
for i in range(30, 292):
    X_train.append(training_set_scaled[i-30:i, 0])
    y_train.append(training_set_scaled[i, 0])
X_train, y_train = np.array(X_train), np.array(y_train)
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
```

## Lampiran 2 Syntax Forecasting LSTM pada software Jupyter Notebook (Lanjutan 1)

```
model = Sequential()
#Adding the first LSTM layer and some Dropout regularisation
model.add(LSTM(units = 200, return_sequences = True, input_shape = (X_train.shape[1], 1)))

model.add(Dropout(0.2))
# Adding a second LSTM layer and some Dropout regularisation
model.add(LSTM(units = 200, return_sequences = True))
model.add(Dropout(0.2))
# Adding a third LSTM layer and some Dropout regularisation
model.add(LSTM(units = 200, return_sequences = True))
model.add(Dropout(0.2))
# Adding a fourth LSTM layer and some Dropout regularisation
model.add(LSTM(units = 200))
model.add(Dropout(0.2))
# Adding the output layer
model.add(Dense(units = 1))

# Compiling the RNN
model.compile(optimizer = 'adam', loss = 'mean_squared_error',metrics=['accuracy'])

# Fitting the RNN to the Training set
model.fit(X_train, y_train, epochs = 100, batch_size = 8)

# Getting the predicted stock price of 2017
dataset_train = edf.iloc[:292, 1:2]
dataset_test = edf.iloc[292:, 1:2]
dataset_total = pd.concat((dataset_train, dataset_test), axis = 0)
inputs = dataset_total[len(dataset_total) - len(dataset_test) - 30:].values
inputs = inputs.reshape(-1,1)
inputs = sc.transform(inputs)
X_test = []
y_test = []
for i in range(30, 103):
    X_test.append(inputs[i-30:i, 0])
    y_test.append(inputs[i, 0])
X_test, y_test = np.array(X_test), np.array(y_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
print(X_test.shape)

predicted_stock_price = model.predict(X_test)
predicted_stock_price = sc.inverse_transform(predicted_stock_price)
```

## Lampiran 2 Syntax Forecasting LSTM pada software Jupyter Notebook (Lanjutan 2)

```
# Visualising the results
plt.plot(dataset_test.values, color = 'red', label = 'Real AR Price')
plt.plot(predicted_stock_price, color = 'blue', label = 'Predicted AR Price')
plt.xticks(np.arange(0,100,50))
plt.title('AR Price Prediction')
plt.xlabel('Time')
plt.ylabel('AR Price')
plt.legend()
plt.show()

predicted_stock_price

df1 = pd.DataFrame(data=predicted_stock_price,columns=['Predicted price'])
df2 = pd.DataFrame(data=dataset_test.values,columns=['Actual price'])

result2 = pd.concat([df1, df2], axis=1, join="inner")
result2

len(dataset_test)

x_input2=dataset_test[44:].values.reshape(1,-1)
x_input2.shape

temp_input=list(x_input2)
temp_input=temp_input[0].tolist()
```

## Lampiran 2 Syntax Forecasting LSTM pada software Jupyter Notebook (Lanjutan 3)

```
# demonstrate prediction for next 30 days
from numpy import array

lst_output=[]
n_steps=30
i=0
while(i<30):

    if(len(temp_input)>30):
        #print(temp_input)
        x_input2=np.array(temp_input[1:])
        print("{} day input {}".format(i,x_input2))
        x_input2=x_input2.reshape(1,-1)
        x_input2 = x_input2.reshape((1, n_steps, 1))
        #print(x_input)
        yhat = model.predict(x_input2, verbose=0)
        print("{} day output {}".format(i,yhat))
        temp_input.extend(yhat[0].tolist())
        temp_input=temp_input[1:]
        #print(temp_input)
        lst_output.extend(yhat.tolist())
        i=i+1
    else:
        x_input2 = x_input2.reshape((1, n_steps,1))
        yhat = model.predict(x_input2, verbose=0)
        print(yhat[0])
        temp_input.extend(yhat[0].tolist())
        print(len(temp_input))
        lst_output.extend(yhat.tolist())
        i=i+1

print(lst_output)

real_predicted_stock_price = sc.inverse_transform(lst_output)
real_predicted_stock_price

pred_price = pd.DataFrame(data=real_predicted_stock_price,columns=['Predicted price'])

pred_price.to_excel('E:\\Materi Kuliah\\AR Price Prediction new fix 2022.xlsx', index = False)

day_new=np.arange(1,31)
day_pred=np.arange(31,61)

plt.plot(day_new,dataset_test[44:])
plt.plot(day_pred,real_predicted_stock_price)
```

### Lampiran 3 Syntax Pembentukan Portofolio Optimal Menggunakan Metode HRP

```
import numpy as np
import pandas as pd
import warnings
Y = pd.read_excel("Return Crypto.xlsx")
print(Y)

import riskfolio as rp

# Plotting Assets Clusters

ax = rp.plot_dendrogram(returns=Y,
                        codependence='pearson',
                        linkage='average',
                        k=None,
                        max_k=10,
                        leaf_order=True,
                        ax=None)

# Building the portfolio object
port = rp.HCPortfolio(returns=Y)

# Estimate optimal portfolio:

model = 'HRP' # Could be HRP or HERC
codependence = 'pearson' # Correlation matrix used to group assets in clusters
rm = 'MV' # Risk measure used, this time will be variance
rf = 0.035 # Risk free rate
linkage = 'average' # Linkage method used to build clusters
max_k = 10 # Max number of clusters used in two difference gap statistic, only for HERC
model
leaf_order = True # Consider optimal order of leafs in dendrogram

w = port.optimization(model=model,
                      codependence=codependence,
                      rm=rm,
                      rf=rf,
                      linkage=linkage,
                      max_k=max_k,
                      leaf_order=leaf_order)

display(w.T)
```

### Lampiran 3 Syntax Pembentukan Portofolio Optimal Menggunakan Metode HRP (Lanjutan)

```
# Plotting the composition of the portfolio

ax = rp.plot_pie(w=w,
                  title='HRP Naive Risk Parity',
                  others=0.2,

                  nrow=25,
                  cmap="tab20",
                  height=8,
                  width=10,
                  ax=None)

# Plotting the risk contribution per asset

mu = Y.mean()
cov = Y.cov() # Covariance matrix
returns = Y # Returns of the assets

ax = rp.plot_risk_con(w=w,
                      cov=cov,
                      returns=returns,
                      rm=rm,
                      rf=0,
                      alpha=0.05,
                      color="tab:blue",
                      height=6,
                      width=10,
                      t_factor=252,
                      ax=None)
```

#### Lampiran 4 Syntax Pembentukan Portofolio Optimal Menggunakan Metode NCO

```
import numpy as np
import pandas as pd
import warnings
Y = pd.read_excel("Return Crypto.xlsx")
print(Y)

import riskfolio as rp

# Plotting Assets Clusters

ax = rp.plot_clusters(returns=Y,
                      codependence='pearson',
                      linkage='average',
                      k=None,
                      max_k=10,
                      leaf_order=True,
                      dendrogram=True,
                      #linecolor='tab:purple',
                      ax=None)

# Building the portfolio object
port = rp.HCPortfolio(returns=Y)

# Estimate optimal portfolio:

model='NCO' # Could be HRP or HERC
codependence = 'pearson' # Correlation matrix used to group assets in clusters
covariance = 'hist' # Covariance estimation technique
rm = 'MV' # Risk measure used, this time will be variance
rf = 0 # Risk free rate
l = 2 # Risk aversion factor, only usefull with "Utility" objective
linkage = 'average' # Linkage method used to build clusters
max_k = 10 # Max number of clusters used in two difference gap statistic
leaf_order = True # Consider optimal order of leafs in dendrogram

w = port.optimization(model=model,
                      codependence=codependence,
                      covariance=covariance,
                      rm=rm,
                      rf=rf,
                      l=l,
                      linkage=linkage,
                      max_k=max_k,
                      leaf_order=leaf_order)

display(w.T)
```

#### Lampiran 4 Syntax Pembentukan Portofolio Optimal Menggunakan Metode NCO (Lanjutan)

```
# Plotting the composition of the portfolio

ax = rp.plot_pie(w=w,
                  title='NCO Sharpe',
                  others=0.05,
                  nrow=25,
                  cmap="tab20",
                  height=8,
                  width=10,
                  ax=None)

# Plotting the risk contribution per asset

mu = Y.mean()
cov = Y.cov() # Covariance matrix
returns = Y # Returns of the assets

ax = rp.plot_risk_con(w=w,
                      cov=cov,
                      returns=returns,
                      rm=rm,
                      rf=0,
                      alpha=0.05,
                      color="tab:blue",
                      height=6,
                      width=10,
                      t_factor=252,
                      ax=None)
```

**Lampiran 5** Harga *Closing Cryptocurrency* (USD)

Date	AMP	ANT	AR	BTC	ETH
01/01/2021	0,006602	3,223857	2,616596	29374,15	730,3676
02/01/2021	0,006913	3,100452	2,668228	32127,27	774,535
03/01/2021	0,007629	3,059262	2,573396	32782,02	975,5077
04/01/2021	0,008113	3,328323	2,688557	31971,91	1040,233
05/01/2021	0,00939	3,310233	2,826397	33992,43	1100,006
06/01/2021	0,00937	3,477399	3,096421	36824,36	1207,112
07/01/2021	0,009036	3,460288	2,83997	39371,04	1225,678
08/01/2021	0,008632	3,34137	2,793347	40797,61	1224,197
09/01/2021	0,008722	3,497975	3,195387	40254,55	1281,077
10/01/2021	0,008578	3,802596	4,093892	38356,44	1262,247
11/01/2021	0,007832	3,354771	3,61444	35566,66	1090,145
12/01/2021	0,007542	3,149882	4,101477	33922,96	1043,435
13/01/2021	0,007757	3,288305	4,3894	37316,36	1130,739
14/01/2021	0,008472	3,268802	4,24369	39187,33	1218,453
15/01/2021	0,008093	3,325827	4,12126	36825,37	1171,835
16/01/2021	0,007684	3,505313	4,085334	36178,14	1233,538
17/01/2021	0,007578	4,82588	4,621489	35791,28	1230,172
18/01/2021	0,007631	4,313033	4,604915	36630,07	1257,28
19/01/2021	0,007443	4,013154	4,913291	36069,8	1377,296
20/01/2021	0,007302	4,042876	4,957302	35547,75	1382,274
21/01/2021	0,006405	3,431361	4,534002	30825,7	1121,571
22/01/2021	0,006856	3,361181	5,148321	33005,76	1236,512
23/01/2021	0,006429	3,712956	5,386702	32067,64	1230,991
24/01/2021	0,006512	4,250317	6,054687	32289,38	1391,609
25/01/2021	0,006454	3,881387	5,508363	32366,39	1324,415
26/01/2021	0,006463	4,000208	5,594422	32569,85	1357,058
27/01/2021	0,005676	3,495567	5,07757	30432,55	1253,187
28/01/2021	0,006344	3,858297	5,716569	33466,1	1332,492
29/01/2021	0,007393	3,752465	5,253137	34316,39	1382,523
30/01/2021	0,007573	3,980893	4,9939	34269,52	1376,115
31/01/2021	0,009534	4,206297	4,808392	33114,36	1314,986
01/02/2021	0,009402	4,251532	5,012342	33537,18	1369,041
02/02/2021	0,009576	4,170299	5,653942	35510,29	1515,194
03/02/2021	0,00975	4,252562	5,662075	37472,09	1660,91
04/02/2021	0,011375	4,509894	5,495378	36926,07	1594,763
05/02/2021	0,013666	5,940227	5,488233	38144,31	1718,651
06/02/2021	0,011949	5,486105	4,91758	39266,01	1677,847
07/02/2021	0,011386	5,1802	5,482517	38903,44	1614,228
08/02/2021	0,012031	5,612459	5,475626	46196,46	1746,617
09/02/2021	0,012765	5,75906	5,900498	46481,11	1768,035
10/02/2021	0,017617	5,501045	6,526814	44918,18	1744,243
11/02/2021	0,030197	6,249326	6,962653	47909,33	1783,798
12/02/2021	0,033812	6,919285	6,878495	47504,85	1843,533
13/02/2021	0,036345	7,11287	7,172016	47105,52	1814,11

**Lampiran 5 Harga Closing Cryptocurrency (USD) (Lanjutan 1)**

<b>Date</b>	<b>AMP</b>	<b>ANT</b>	<b>AR</b>	<b>BTC</b>	<b>ETH</b>
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
21/11/2021	0,050439	5,165127	64,48	58730,48	4269,733
22/11/2021	0,049749	4,806161	59,77984	56289,29	4088,458
23/11/2021	0,070455	4,883087	60,72327	57569,07	4340,764
24/11/2021	0,064688	5,058047	57,71746	56280,43	4239,981
25/11/2021	0,060035	5,062578	59,9322	57274,68	4274,743
26/11/2021	0,057219	5,059084	53,56708	53569,77	4030,909
27/11/2021	0,061812	6,506244	57,36921	54815,08	4096,912
28/11/2021	0,063264	5,884752	57,96672	57248,46	4294,454
29/11/2021	0,062387	5,956691	60,90766	57806,57	4445,105
30/11/2021	0,061175	5,55121	59,31493	57005,43	4631,479
01/12/2021	0,059881	5,381486	57,45539	57229,83	4586,99
02/12/2021	0,057336	5,260393	55,8483	56477,82	4511,302
03/12/2021	0,054194	4,767883	53,35481	53598,25	4220,706
04/12/2021	0,052602	4,203801	49,44504	49200,7	4119,587
05/12/2021	0,050585	3,929012	44,85275	49368,85	4198,323
06/12/2021	0,052394	4,279242	46,87536	50582,63	4358,737
07/12/2021	0,050877	4,124787	48,94908	50700,09	4315,062
08/12/2021	0,054829	4,997384	47,12236	50504,8	4439,358
09/12/2021	0,052912	4,628133	41,69375	47672,12	4119,816
10/12/2021	0,050289	4,115061	40,26643	47243,3	3908,496
11/12/2021	0,051714	4,295977	41,80026	49362,51	4084,452
12/12/2021	0,052303	4,487653	41,90407	50098,34	4134,453
13/12/2021	0,049108	5,059458	36,36469	46737,48	3784,227
14/12/2021	0,049797	5,528383	38,21987	46612,63	3745,44
15/12/2021	0,050344	7,205992	41,27671	48896,72	4018,389
16/12/2021	0,048576	6,249706	46,50061	47665,43	3962,47
17/12/2021	0,048573	5,708905	47,61384	46202,14	3879,487
18/12/2021	0,048565	5,823686	52,92479	46848,78	3960,86
19/12/2021	0,04803	5,584923	59,2161	46707,02	3922,593
20/12/2021	0,046612	5,726956	56,35904	46880,28	3933,844
21/12/2021	0,048289	6,95791	54,35633	48936,61	4020,26
22/12/2021	0,050387	8,721221	53,12382	48628,51	3982,1
23/12/2021	0,050193	9,904326	57,2827	50784,54	4108,016
24/12/2021	0,04948	10,77552	61,906	50822,2	4047,983
25/12/2021	0,049615	9,956494	60,47696	50429,86	4093,281
26/12/2021	0,050937	9,790114	61,68597	50809,52	4067,328
27/12/2021	0,053422	9,348137	59,82	50640,42	4037,548
28/12/2021	0,050828	12,24661	53,43	47588,86	3800,893
29/12/2021	0,049177	10,95857	54,8	46444,71	3628,532
30/12/2021	0,048943	11,19089	58,49	47178,13	3713,852
31/12/2021	0,04832	13,50503	58,92	46306,45	3682,633

**Lampiran 5** Harga *Closing Cryptocurrency* (USD) (Lanjutan 2)

Date	HT	KIN	REN	TT	UST
01/01/2021	5,191839	0,000063	0,317025	0,0052	1,001797
02/01/2021	4,849645	0,000056	0,312195	0,005045	0,999595
03/01/2021	4,899794	0,000057	0,333155	0,004771	0,998929
04/01/2021	4,839642	0,000057	0,336494	0,004652	1,00365
05/01/2021	4,813535	0,000057	0,344533	0,004765	0,992179
06/01/2021	5,010023	0,000059	0,369677	0,004891	1,000534
07/01/2021	5,027218	0,000058	0,364019	0,004821	1,001259
08/01/2021	4,927656	0,000067	0,386059	0,005007	1,009173
09/01/2021	5,222805	0,000067	0,446128	0,005286	1,005192
10/01/2021	5,555771	0,000062	0,412413	0,004945	1,001972
11/01/2021	4,799314	0,000056	0,36723	0,004628	1,02502
12/01/2021	4,66288	0,000052	0,358589	0,004655	1,004702
13/01/2021	4,935185	0,000053	0,436646	0,004838	1,006509
14/01/2021	4,998907	0,000047	0,473961	0,005079	1,006509
15/01/2021	5,08337	0,000049	0,52032	0,004939	1,001076
16/01/2021	5,172934	0,000043	0,539421	0,005062	1,000375
17/01/2021	5,349366	0,000043	0,619612	0,004965	0,999732
18/01/2021	5,780925	0,000042	0,59371	0,005123	1,002345
19/01/2021	5,805819	0,000044	0,685694	0,005105	0,999083
20/01/2021	5,775754	0,000044	0,755103	0,005066	1,002236
21/01/2021	5,178503	0,000042	0,582973	0,004761	0,99965
22/01/2021	5,438717	0,000039	0,636038	0,004846	0,998735
23/01/2021	5,773094	0,000041	0,626738	0,004827	0,99899
24/01/2021	5,771614	0,000043	0,629033	0,004824	0,998878
25/01/2021	5,70426	0,000044	0,573594	0,004759	0,999322
26/01/2021	5,695242	0,000041	0,594759	0,004768	0,997848
27/01/2021	5,470711	0,00004	0,522281	0,004593	1,00057
28/01/2021	5,922643	0,000041	0,581492	0,004858	1,016355
29/01/2021	6,043631	0,000036	0,566836	0,004878	1,02506
30/01/2021	6,407718	0,000041	0,588933	0,004817	1,03193
31/01/2021	6,885053	0,000053	0,630635	0,004745	1,042085
01/02/2021	6,808389	0,000056	0,624007	0,004749	1,023395
02/02/2021	6,925922	0,000059	0,670291	0,004959	1,029711
03/02/2021	7,450408	0,000052	0,68562	0,005387	1,016602
04/02/2021	7,715353	0,00005	0,803524	0,005522	1,009807
05/02/2021	8,108231	0,000047	0,842708	0,005694	1,010927
06/02/2021	8,768901	0,000051	0,780595	0,005418	1,006548
07/02/2021	8,954744	0,000049	0,771785	0,005275	1,007718
08/02/2021	9,204639	0,000046	0,809294	0,00555	1,002042
09/02/2021	11,74499	0,000051	0,874971	0,005806	1,004429
10/02/2021	13,59416	0,000059	0,854495	0,005832	1,008726
11/02/2021	12,61697	0,000064	0,996933	0,006296	1,004817
12/02/2021	12,99222	0,000062	1,053451	0,006983	1,002379
13/02/2021	12,52989	0,000099	0,99485	0,007772	1,001512

**Lampiran 5 Harga Closing Cryptocurrency (USD) (Lanjutan 3)**

Date	HT	KIN	REN	TT	UST
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
21/11/2021	10,15408	0,00009	0,78645	0,013861	1,001993
22/11/2021	9,80548	0,000081	0,763609	0,013063	1,002517
23/11/2021	9,935332	0,000083	0,909517	0,013461	1,000868
24/11/2021	9,795976	0,000082	0,895979	0,013717	1,000445
25/11/2021	9,635506	0,000087	0,873854	0,017907	1,002054
26/11/2021	9,34705	0,000078	0,882875	0,014999	1,00226
27/11/2021	9,773931	0,000078	0,96095	0,01509	1,001778
28/11/2021	9,909893	0,000082	0,916035	0,016065	1,001736
29/11/2021	9,960942	0,000104	0,885754	0,018231	1,001525
30/11/2021	9,727752	0,000135	0,896448	0,017332	1,009781
01/12/2021	9,582038	0,000117	0,948716	0,017945	1,003683
02/12/2021	9,656142	0,0001	0,895272	0,017078	1,002528
03/12/2021	9,378091	0,000095	0,846362	0,0152	1,001738
04/12/2021	8,794803	0,000081	0,745354	0,012768	1,000632
05/12/2021	8,729391	0,000083	0,627337	0,012173	1,001291
06/12/2021	8,884338	0,000081	0,63662	0,012289	1,000313
07/12/2021	8,701125	0,00008	0,629021	0,012379	1,003556
08/12/2021	9,917165	0,00008	0,63279	0,012381	1,001878
09/12/2021	9,978077	0,000095	0,580823	0,011342	1,002415
10/12/2021	9,894942	0,000093	0,529308	0,010955	1,003167
11/12/2021	10,02005	0,000093	0,561439	0,011342	1,001686
12/12/2021	10,05604	0,000092	0,562759	0,011267	1,001691
13/12/2021	9,086709	0,000082	0,490782	0,010112	1,000985
14/12/2021	9,734673	0,000084	0,485048	0,009852	1,00179
15/12/2021	9,996642	0,000089	0,515705	0,010745	1,000864
16/12/2021	9,866949	0,000087	0,514449	0,010668	1,001535
17/12/2021	9,992175	0,000082	0,507068	0,010556	1,0015
18/12/2021	10,03251	0,000083	0,515128	0,010697	1,000888
19/12/2021	10,12883	0,000082	0,495428	0,010551	1,001723
20/12/2021	10,01321	0,000081	0,490325	0,0102	1,001973
21/12/2021	10,00249	0,000083	0,653511	0,010612	1,007215
22/12/2021	9,957153	0,000084	0,699448	0,010677	1,001949
23/12/2021	10,00191	0,000089	0,703831	0,011283	1,001817
24/12/2021	9,401219	0,000089	0,638959	0,01132	1,002696
25/12/2021	9,962747	0,000087	0,644952	0,011457	1,001499
26/12/2021	9,923896	0,000087	0,641323	0,011408	1,00209
27/12/2021	9,909386	0,000085	0,624098	0,011412	1,000515
28/12/2021	9,734398	0,00008	0,584282	0,010486	1,002239
29/12/2021	9,68143	0,00008	0,554609	0,010101	1,001423
30/12/2021	9,487837	0,000082	0,558474	0,010233	1,001984
31/12/2021	9,371063	0,000077	0,529795	0,010117	1,00144

**Lampiran 6** Nilai MAPE dan MSE setiap kombinasi

<b>Crypto</b>	<b>Units</b>	<b>Batch</b>	<b>MAPE</b>	<b>MSE</b>
<b>Arweave (AR)</b>	100	8	0.039635	30.91035
	100	16	0.029685	30.1357
	200	8	0.02333	25.53684
	200	16	0.053543	31.07485
<b>REN (REN)</b>	100	8	0.026754	0.003094
	100	16	0.015065	0.003215
	200	8	0.097076	0.005953
	200	16	0.02218	0.003443
<b>ThunderCore (TT)</b>	100	8	0.008238	1.1E-06
	100	16	0.098218	1.81E-06
	200	8	0.071922	1.44E-06
	200	16	0.071154	1.58E-06
<b>Bitcoin (BTC)</b>	100	8	0.072175	3697810
	100	16	0.141279	20586647
	200	8	0.082625	4153750
	200	16	0.090754	5652104
<b>TerraUSD (UST)</b>	100	8	0.001072	4.38E-05
	100	16	0.005812	4.73E-05
	200	8	0.002223	4.24E-05
	200	16	0.001494	4.26E-05
<b>Amp (AMP)</b>	100	8	0.029176	2.94E-05
	100	16	0.096212	3.11E-05
	200	8	0.020059	4.53E-05
	200	16	0.055567	2.9E-05
<b>Ethereum (ETH)</b>	100	8	0.0226	23186.86
	100	16	0.023057	104945.8
	200	8	0.022028	48411.22
	200	16	0.027841	93983.85
<b>Aragon (ANT)</b>	100	8	0.078769	0.983439
	100	16	0.120547	0.805575
	200	8	0.074601	0.686291
	200	16	0.046199	0.70099
<b>Kin (KIN)</b>	100	8	0.151127	1.32E-09
	100	16	0.131406	1.52E-09
	200	8	0.082181	1.34E-09
	200	16	0.11006	1.36E-09
<b>Huobi Token (HT)</b>	100	8	0.081553	0.40685
	100	16	0.157567	0.423205
	200	8	0.052357	0.359798
	200	16	0.153347	0.322699

**Lampiran 7 Hasil Pengujian Data *Testing* pada tiap *Crypto***

Date	AMP		ANT		AR	
	Pred price	Act price	Pred price	Act price	Pred price	Act price
20/10/2021	0,0497924	0,05472	5,041303	4,82235	54,5515	54,1134
21/10/2021	0,0479897	0,048754	4,973402	4,78094	56,02693	55,49667
22/10/2021	0,0490194	0,049659	5,066374	4,872366	56,48341	56,93415
23/10/2021	0,0501381	0,051341	5,076255	4,891595	57,11614	58,00862
24/10/2021	0,0490621	0,050145	5,071172	4,879096	55,46325	56,369
25/10/2021	0,0501561	0,051009	4,949553	4,75382	54,35692	54,75255
26/10/2021	0,0481121	0,048999	5,006274	4,792579	53,09632	53,08691
27/10/2021	0,047597	0,048053	4,897832	4,696932	54,84552	54,75422
28/10/2021	0,0472033	0,047901	5,263712	5,04131	55,33381	55,35317
29/10/2021	0,0459848	0,04662	5,004857	4,846834	57,46176	57,34047
30/10/2021	0,0462191	0,046845	4,720181	4,520599	50,63182	49,02297
31/10/2021	0,0463445	0,04719	4,955873	4,725216	56,63139	54,61028
01/11/2021	0,0464031	0,047206	4,880606	4,694314	54,09711	52,83154
02/11/2021	0,0581459	0,059561	4,969804	4,76577	61,71254	60,42404
03/11/2021	0,0490081	0,05113	5,031248	4,846746	57,00771	56,90018
04/11/2021	0,0543036	0,053791	5,153212	4,979804	76,47351	75,99448
05/11/2021	0,0798011	0,081025	5,227976	5,076478	79,80846	88,7686
06/11/2021	0,0697486	0,079611	6,615544	6,453203	76,52856	87,5041
07/11/2021	0,0677841	0,069937	5,308246	5,31193	82,84854	90,94004
08/11/2021	0,0630377	0,064493	5,289114	5,067347	74,68564	84,22177
09/11/2021	0,0663866	0,067985	5,184575	5,011406	80,89757	85,73311
.	.	.	.	.	.	.
15/12/2021	0,0512209	0,052485	5,47127	5,364439	44,28416	41,9241
16/12/2021	0,0490492	0,050062	6,142496	6,101495	41,34238	38,62377
17/12/2021	0,0505374	0,051469	7,102035	7,205992	44,35781	42,51315
18/12/2021	0,0495455	0,050892	7,339759	7,607409	48,93893	47,91588
19/12/2021	0,048383	0,049187	6,54384	6,529955	51,2471	50,68746
20/12/2021	0,0489732	0,049784	6,486298	6,202422	53,97732	53,61587
21/12/2021	0,0483696	0,049351	6,414954	6,127182	59,72646	60,02532
22/12/2021	0,0479067	0,04864	6,179584	5,829005	58,7205	59,94484
23/12/2021	0,0482623	0,049037	7,78335	7,373947	58,2562	58,34052
24/12/2021	0,0503302	0,051436	9,058664	9,290846	57,37158	56,58451
25/12/2021	0,0497473	0,050964	10,13969	10,75709	59,0495	57,76792
26/12/2021	0,0510553	0,051955	11,10774	11,87702	65,18588	64,53084
27/12/2021	0,0494475	0,050371	10,93935	11,22429	67,5174	68,64923
28/12/2021	0,0507303	0,051416	11,06778	10,516	62,96667	63,53239
29/12/2021	0,0575596	0,059222	11,30766	10,55691	65,56915	64,418
30/12/2021	0,0514436	0,053472	13,59238	13,77055	60,99286	59,8474
31/12/2021	0,0521985	0,0522	12,92943	13,59467	60,94966	58,52761

**Lampiran 7** Hasil Pengujian Data *Testing* pada tiap *Crypto* (Lanjutan 1)

Date	BTC		ETH		HT	
	Pred price	Act price	Pred price	Act price	Pred price	Act price
20/10/2021	61039,64	62238,43	3941,8	3883,929	8,126252	8,07936
21/10/2021	62815,76	64434,54	4209,574	4167,472	9,771229	9,579249
22/10/2021	65084,73	66930,39	4431,245	4366,088	9,947622	9,540064
23/10/2021	64216,82	66600,55	4207,037	4162,976	11,15929	10,7695
24/10/2021	61318,47	63715,02	4175,031	4171,664	11,12089	10,62232
25/10/2021	59744,94	61743,88	4196,704	4185,729	10,89621	10,48782
26/10/2021	59852,07	61505,8	4253,821	4236,667	10,67861	10,3159
27/10/2021	62254,82	63729,32	4303,438	4289,131	10,81971	10,43703
28/10/2021	61656,8	63229,03	4303,498	4299,153	10,4718	10,02901
29/10/2021	59845,87	61435,18	4285,955	4293,151	10,22729	9,816788
30/10/2021	60547,73	62128,63	4440,978	4455,735	10,20652	9,789916
31/10/2021	61403,91	62927,61	4407,006	4426,849	9,923593	9,486051
01/11/2021	60783,75	62330,14	4357,122	4394,45	10,52232	10,08433
02/11/2021	60836,95	62406,17	4336,604	4377,322	11,08456	10,5181
03/11/2021	60864,29	62419	4565,957	4599,948	11,88475	11,24123
04/11/2021	62654,96	64242,79	4621,024	4664,91	12,33486	11,62792
05/11/2021	61777,59	63516,94	4526,836	4606,516	12,25799	11,57736
06/11/2021	61360,83	63123,29	4480,504	4570,896	11,34327	10,76803
07/11/2021	60844,9	62541,47	4446,317	4530,997	10,97302	10,54649
08/11/2021	60027,57	61590,68	4567,576	4640,922	11,42917	10,95596
09/11/2021	61814,34	63326,99	4751,352	4822,363	11,55587	10,94817
.	.	.	.	.	.	.
.	.	.	.	.	.	.
15/12/2021	50407,9	50205	3892,665	3866,634	10,43883	10,04247
16/12/2021	48914,2	48431,4	4069,122	4086,373	10,44492	10,02843
17/12/2021	49298,25	49473,96	4136,875	4110,369	10,51836	10,08608
18/12/2021	49556,22	49425,57	4023,755	3992,792	10,48125	10,03293
19/12/2021	48508,13	48004,89	4008,871	3993,83	10,50385	10,06001
20/12/2021	47618,93	47313,83	4042,167	4018,658	11,12539	10,64303
21/12/2021	48050,13	48089,66	4017,965	3980,099	10,6764	10,12996
22/12/2021	47796,69	47401,72	4089,07	4058,821	10,53549	10,10061
23/12/2021	49191,52	49300,92	4113,494	4073,792	10,46101	10,03636
24/12/2021	49851,27	49544,8	4181,352	4149,027	10,46377	10,03028
25/12/2021	51341,05	51332,34	4168,114	4134,106	10,47728	10,03026
26/12/2021	52001,13	51814,03	4164,446	4138,565	10,46442	10,01262
27/12/2021	51439,89	51176,6	4132,027	4105,024	10,42637	9,980114
28/12/2021	51205,51	51196,38	4150,128	4126,001	10,40182	9,964552
29/12/2021	51803,34	51956,33	4071,615	4037,538	10,36704	9,935543
30/12/2021	50921,96	50679,86	3875,37	3827,982	10,17693	9,75975
31/12/2021	48625,94	48119,74	3824,37	3767,56	9,83471	9,716867

**Lampiran 7 Hasil Pengujian Data *Testing* pada tiap *Crypto* (Lanjutan 2)**

Date	KIN		REN	
	Pred price	Act price	Pred price	Act price
20/10/2021	9,21E-05	8,8E-05	1,00779	1,005985
21/10/2021	9,61E-05	9,7E-05	1,077079	1,06907
22/10/2021	0,000108	0,000111	1,133041	1,135188
23/10/2021	0,000116	0,000113	1,135274	1,148043
24/10/2021	0,000115	0,000105	1,105048	1,118296
25/10/2021	0,000111	1E-04	1,139448	1,143171
26/10/2021	0,000109	0,000104	1,111091	1,125706
27/10/2021	0,000108	0,000101	1,183565	1,182871
28/10/2021	0,000105	9,7E-05	1,142089	1,163616
29/10/2021	9,92E-05	9,1E-05	1,090105	1,101125
30/10/2021	9,87E-05	9,6E-05	1,090824	1,090918
31/10/2021	9,85E-05	9,4E-05	1,038908	1,04264
01/11/2021	9,7E-05	9,2E-05	1,050457	1,043548
02/11/2021	9,58E-05	9,2E-05	1,039953	1,037165
03/11/2021	9,58E-05	9,3E-05	1,037485	1,032733
04/11/2021	0,000107	0,000113	1,044447	1,039967
05/11/2021	0,000117	0,000114	1,021231	1,019953
06/11/2021	0,000116	0,000106	0,981453	0,978379
07/11/2021	0,000116	0,000111	0,973692	0,967321
08/11/2021	0,00013	0,000133	0,96678	0,961471
09/11/2021	0,000138	0,000129	1,014093	1,005919
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.
15/12/2021	9,2E-05	8,9E-05	0,505542	0,51031
16/12/2021	9,12E-05	9E-05	0,503708	0,52323
17/12/2021	9,4E-05	9,3E-05	0,529	0,54931
18/12/2021	9,32E-05	8,8E-05	0,516337	0,529138
19/12/2021	8,96E-05	8,4E-05	0,511835	0,528655
20/12/2021	8,73E-05	8,4E-05	0,504077	0,521454
21/12/2021	8,6E-05	8,3E-05	0,484094	0,501095
22/12/2021	8,55E-05	8,3E-05	0,7113	0,732046
23/12/2021	8,64E-05	8,5E-05	0,761905	0,768547
24/12/2021	8,94E-05	8,9E-05	0,724653	0,723301
25/12/2021	9,64E-05	9,8E-05	0,711971	0,716205
26/12/2021	9,75E-05	9,2E-05	0,656367	0,659337
27/12/2021	9,41E-05	8,8E-05	0,644458	0,651889
28/12/2021	9,09E-05	8,7E-05	0,680981	0,687921
29/12/2021	8,84E-05	8,5E-05	0,634575	0,630222
30/12/2021	8,56E-05	8,2E-05	0,607791	0,607027
31/12/2021	8,71E-05	8,3E-05	0,58297	0,576544

**Lampiran 7** Hasil Pengujian Data *Testing* pada tiap *Crypto* (Lanjutan 3)

Date	TT		UST	
	Pred price	Act price	Pred price	Act price
20/10/2021	0,014001	0,014	1,003697	1,002426
21/10/2021	0,014708	0,015139	1,004078	1,004307
22/10/2021	0,014556	0,014079	1,004777	1,005907
23/10/2021	0,014245	0,013901	1,004939	1,0054
24/10/2021	0,014	0,013886	1,004946	1,005325
25/10/2021	0,013844	0,013902	1,005348	1,006625
26/10/2021	0,013636	0,013703	1,005001	1,004864
27/10/2021	0,013453	0,013613	1,00499	1,005373
28/10/2021	0,013216	0,013363	1,005382	1,006553
29/10/2021	0,012651	0,012545	1,005059	1,004835
30/10/2021	0,012518	0,012907	1,004694	1,004124
31/10/2021	0,012822	0,013435	1,005083	1,00598
01/11/2021	0,01325	0,013775	1,005166	1,005519
02/11/2021	0,013487	0,013748	1,004807	1,004269
03/11/2021	0,013553	0,013689	1,00468	1,004462
04/11/2021	0,013708	0,013973	1,006076	1,009146
05/11/2021	0,013569	0,0136	1,005999	1,006782
06/11/2021	0,013261	0,013261	1,005346	1,005076
07/11/2021	0,013119	0,013352	1,005042	1,005025
08/11/2021	0,013391	0,013946	1,004891	1,004842
09/11/2021	0,013566	0,0139	1,004555	1,003836
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.
15/12/2021	0,011102	0,010441	1,005306	1,007294
16/12/2021	0,010884	0,010846	1,004377	1,002756
17/12/2021	0,010993	0,011187	1,003907	1,002873
18/12/2021	0,01095	0,010921	1,003736	1,002977
19/12/2021	0,010876	0,010894	1,004237	1,004866
20/12/2021	0,010818	0,010882	1,004357	1,004362
21/12/2021	0,010635	0,010593	1,004433	1,004521
22/12/2021	0,010539	0,010632	1,005309	1,007266
23/12/2021	0,010628	0,010849	1,0058	1,007406
24/12/2021	0,01096	0,011307	1,004962	1,004218
25/12/2021	0,01155	0,012	1,004793	1,004871
26/12/2021	0,01167	0,011586	1,005892	1,00846
27/12/2021	0,011589	0,011474	1,005355	1,004998
28/12/2021	0,011653	0,01176	1,004646	1,003504
29/12/2021	0,011512	0,011417	1,004236	1,003111
30/12/2021	0,01095	0,010567	1,004138	1,003347
31/12/2021	0,010627	0,010344	1,003925	1,00295

**Lampiran 8 Hasil Forecasting Cryptocurrency (USD)**

Date	AMP	ANT	AR	BTC	ETH
01/01/2022	0,050254	12,41407	55,46741	46726,63	3726,048
02/01/2022	0,051966	12,03118	52,94096	47110,92	3794,772
03/01/2022	0,053685	12,20454	51,02267	47593,78	3833,101
04/01/2022	0,055299	12,23417	48,75962	48126,52	3852,707
05/01/2022	0,057057	12,25774	46,77147	48658,88	3855,245
06/01/2022	0,059036	12,23569	44,90512	49170,61	3847,927
07/01/2022	0,06111	12,17614	43,20748	49660,47	3840,374
08/01/2022	0,063117	12,08961	41,6802	50141,29	3837,408
09/01/2022	0,064949	11,98462	40,35329	50630,46	3842,304
10/01/2022	0,066536	11,8678	39,26457	51143,89	3854,694
11/01/2022	0,067809	11,74314	38,47108	51690,29	3870,571
12/01/2022	0,068699	11,6131	38,07774	52267,7	3886,917
13/01/2022	0,069162	11,47897	38,26003	52863,37	3903,361
14/01/2022	0,069211	11,34137	39,12544	53458,87	3918,366
15/01/2022	0,068897	11,20038	40,72799	54032,97	3929,395
16/01/2022	0,068285	11,05604	43,06132	54563,52	3936,269
17/01/2022	0,067452	10,90796	46,08929	55032,24	3939,317
18/01/2022	0,066476	10,75546	49,62005	55427,59	3938,077
19/01/2022	0,065428	10,59776	53,31709	55744,52	3932,801
20/01/2022	0,064364	10,43386	56,87977	55984,77	3923,819
21/01/2022	0,063327	10,26241	59,90037	56155,76	3911,396
22/01/2022	0,062348	10,08191	61,99622	56267,29	3896,616
23/01/2022	0,061442	9,89091	63,01278	56331,43	3880,253
24/01/2022	0,060619	9,687925	63,06508	56359,22	3863,889
25/01/2022	0,059879	9,471814	62,48706	56360,53	3848,721
26/01/2022	0,059223	9,240993	61,54584	56343,89	3835,871
27/01/2022	0,058645	8,993938	60,45862	56315,88	3826,105
28/01/2022	0,058138	8,726852	59,38351	56280,85	3820,342
29/01/2022	0,057695	8,440945	58,27336	56242,84	3818,617
30/01/2022	0,057308	8,135021	57,04065	56205,52	3819,526

**Lampiran 8 Hasil Forecasting Cryptocurrency (USD)**

<b>Date</b>	<b>HT</b>	<b>KIN</b>	<b>REN</b>	<b>TT</b>	<b>UST</b>
01/01/2022	9,41615	7,86E-05	0,55407	0,009906	1,003347
02/01/2022	9,478961	7,86E-05	0,575889	0,009727	1,003803
03/01/2022	9,541557	7,93E-05	0,598631	0,009581	1,004669
04/01/2022	9,587114	7,99E-05	0,617094	0,009464	1,005551
05/01/2022	9,617405	8,03E-05	0,629336	0,009378	1,006231
06/01/2022	9,640437	8,06E-05	0,63617	0,009325	1,006737
07/01/2022	9,662122	8,09E-05	0,640154	0,009305	1,007164
08/01/2022	9,686293	8,1E-05	0,643478	0,009314	1,007561
09/01/2022	9,715446	8,13E-05	0,647217	0,009345	1,007931
10/01/2022	9,750899	8,16E-05	0,651072	0,009392	1,008262
11/01/2022	9,7931	8,2E-05	0,653844	0,009452	1,008551
12/01/2022	9,841899	8,25E-05	0,65493	0,009518	1,008799
13/01/2022	9,896701	8,3E-05	0,654986	0,009584	1,009009
14/01/2022	9,956541	8,35E-05	0,655193	0,009643	1,009185
15/01/2022	10,02063	8,39E-05	0,656942	0,009696	1,009331
16/01/2022	10,08836	8,44E-05	0,661493	0,009738	1,009453
17/01/2022	10,15922	8,48E-05	0,669344	0,009765	1,009557
18/01/2022	10,23294	8,52E-05	0,679991	0,009779	1,009644
19/01/2022	10,30939	8,55E-05	0,69235	0,009776	1,009711
20/01/2022	10,3886	8,59E-05	0,704987	0,009757	1,009759
21/01/2022	10,47067	8,63E-05	0,715883	0,009724	1,009792
22/01/2022	10,5558	8,66E-05	0,724308	0,00968	1,009826
23/01/2022	10,64421	8,7E-05	0,730444	0,009627	1,009855
24/01/2022	10,73609	8,73E-05	0,735416	0,009569	1,009875
25/01/2022	10,83161	8,76E-05	0,740051	0,00951	1,009889
26/01/2022	10,93111	8,79E-05	0,74498	0,009452	1,009899
27/01/2022	11,03491	8,82E-05	0,750432	0,009397	1,009906
28/01/2022	11,14334	8,85E-05	0,756401	0,009348	1,009907
29/01/2022	11,25664	8,87E-05	0,76269	0,009305	1,009908
30/01/2022	11,37501	8,9E-05	0,769017	0,00927	1,009907

### Lampiran 9 Hasil Perkembangan Portofolio HRP (USD)

Date	AR	REN	TT	BTC	UST	AMP	ETH	ANT	KIN	HT	Total
01/01/2021	18,0	14,0	15,0	42,0	9845,0	8,0	23,0	8,0	11,0	16,0	10000,0
02/01/2021	18,4	13,8	14,6	45,9	9823,4	8,4	24,4	7,7	9,8	14,9	9981,2
03/01/2021	17,7	14,7	13,8	46,9	9816,8	9,2	30,7	7,6	10,0	15,1	9982,5
04/01/2021	18,5	14,9	13,4	45,7	9863,2	9,8	32,8	8,3	10,0	14,9	10031,4
05/01/2021	19,4	15,2	13,7	48,6	9750,5	11,4	34,6	8,2	10,0	14,8	9926,5
06/01/2021	21,3	16,3	14,1	52,7	9832,6	11,4	38,0	8,6	10,3	15,4	10020,7
07/01/2021	19,5	16,1	13,9	56,3	9839,7	10,9	38,6	8,6	10,1	15,5	10029,3
08/01/2021	19,2	17,0	14,4	58,3	9917,5	10,5	38,6	8,3	11,7	15,2	10110,7
09/01/2021	22,0	19,7	15,2	57,6	9878,4	10,6	40,3	8,7	11,7	16,1	10080,2
10/01/2021	28,2	18,2	14,3	54,8	9846,7	10,4	39,7	9,4	10,8	17,1	10049,7
11/01/2021	24,9	16,2	13,4	50,9	10073,2	9,5	34,3	8,3	9,8	14,8	10255,2
12/01/2021	28,2	15,8	13,4	48,5	9873,5	9,1	32,9	7,8	9,1	14,4	10052,8
13/01/2021	30,2	19,3	14,0	53,4	9891,3	9,4	35,6	8,2	9,3	15,2	10085,7
14/01/2021	29,2	20,9	14,7	56,0	9891,3	10,3	38,4	8,1	8,2	15,4	10092,5
15/01/2021	28,4	23,0	14,2	52,7	9837,9	9,8	36,9	8,3	8,6	15,7	10035,3
16/01/2021	28,1	23,8	14,6	51,7	9831,0	9,3	38,8	8,7	7,5	15,9	10029,6
17/01/2021	31,8	27,4	14,3	51,2	9824,7	9,2	38,7	12,0	7,5	16,5	10033,2
18/01/2021	31,7	26,2	14,8	52,4	9850,4	9,2	39,6	10,7	7,3	17,8	10060,1
19/01/2021	33,8	30,3	14,7	51,6	9818,3	9,0	43,4	10,0	7,7	17,9	10036,6
20/01/2021	34,1	33,3	14,6	50,8	9849,3	8,8	43,5	10,0	7,7	17,8	10070,1
21/01/2021	31,2	25,7	13,7	44,1	9823,9	7,8	35,3	8,5	7,3	16,0	10013,5
22/01/2021	35,4	28,1	14,0	47,2	9814,9	8,3	38,9	8,3	6,8	16,8	10018,7
23/01/2021	37,1	27,7	13,9	45,9	9817,4	7,8	38,8	9,2	7,2	17,8	10022,6
24/01/2021	41,7	27,8	13,9	46,2	9816,3	7,9	43,8	10,5	7,5	17,8	10033,4
25/01/2021	37,9	25,3	13,7	46,3	9820,7	7,8	41,7	9,6	7,7	17,6	10028,3
26/01/2021	38,5	26,3	13,8	46,6	9806,2	7,8	42,7	9,9	7,2	17,6	10016,5
27/01/2021	34,9	23,1	13,2	43,5	9832,9	6,9	39,5	8,7	7,0	16,9	10026,6
28/01/2021	39,3	25,7	14,0	47,9	9988,1	7,7	42,0	9,6	7,2	18,3	10199,6
29/01/2021	36,1	25,0	14,1	49,1	10073,6	9,0	43,5	9,3	6,3	18,6	10284,6
30/01/2021	34,4	26,0	13,9	49,0	10141,1	9,2	43,3	9,9	7,2	19,7	10353,7
31/01/2021	33,1	27,8	13,7	47,3	10240,9	11,6	41,4	10,4	9,3	21,2	10456,8
.	.	.	.	.	.	.	.	.	.	.	.
01/01/2022	327,0	52,3	17,8	145,9	10107,0	14,9	206,1	41,7	6,9	329,8	11249,5
02/01/2022	321,6	52,8	19,1	88,6	9991,6	15,1	117,8	41,6	7,0	221,9	10877,1
03/01/2022	317,5	53,0	21,0	119,8	9930,4	15,3	146,0	41,5	7,1	157,0	10808,6
04/01/2022	313,8	53,1	23,0	131,1	9892,4	15,6	200,0	42,2	7,2	146,4	10824,8
05/01/2022	310,3	53,0	25,1	108,3	9868,4	15,9	164,1	42,4	7,3	139,0	10733,8

**Lampiran 9 Hasil Perkembangan Portofolio HRP (USD) (Lanjutan)**

Date	AR	REN	TT	BTC	UST	AMP	ETH	ANT	KIN	HT	Total
06/01/2022	306,9	52,9	27,1	95,0	9854,5	16,2	134,1	42,8	7,4	125,4	10662,4
07/01/2022	303,6	52,7	29,1	94,5	9848,2	16,6	106,7	43,2	7,5	110,7	10612,9
08/01/2022	300,2	52,6	31,1	94,2	9847,9	17,1	83,1	43,5	7,6	95,6	10572,8
09/01/2022	296,8	52,5	32,9	92,9	9851,8	17,5	76,7	43,8	7,7	81,3	10554,0
10/01/2022	293,3	52,4	34,5	91,0	9858,3	18,1	85,4	44,0	7,8	68,7	10553,5
11/01/2022	289,7	52,3	36,0	89,2	9865,9	18,6	97,5	44,3	8,0	57,9	10559,5
12/01/2022	286,0	52,3	37,4	87,6	9873,3	19,3	104,5	44,5	8,1	48,7	10561,7
13/01/2022	282,4	52,3	38,7	86,6	9879,6	19,9	105,2	44,5	8,2	40,9	10558,3
14/01/2022	278,7	52,3	39,9	86,1	9884,3	20,6	102,0	44,2	8,3	34,6	10551,1
15/01/2022	275,2	52,3	41,0	86,0	9887,3	21,4	97,9	43,2	8,5	29,6	10542,4
16/01/2022	271,8	52,2	42,2	86,4	9888,8	22,2	94,2	42,6	8,6	26,0	10535,0
17/01/2022	268,5	52,2	43,3	87,1	9889,0	23,1	91,3	41,0	8,7	23,5	10527,7
18/01/2022	265,3	52,2	44,5	87,8	9888,4	24,0	89,1	40,1	8,8	21,9	10522,2
19/01/2022	262,3	52,3	45,7	88,6	9887,2	24,9	87,6	38,2	9,0	21,0	10516,8
20/01/2022	259,4	52,3	47,1	89,2	9885,9	26,0	86,6	37,6	9,1	20,5	10513,6
21/01/2022	256,5	52,3	48,5	89,6	9884,7	27,0	86,0	36,1	9,2	20,4	10510,3
22/01/2022	253,7	52,3	49,9	89,8	9883,6	28,1	85,7	35,9	9,4	20,6	10509,1
23/01/2022	250,9	52,3	51,4	89,8	9882,9	29,3	85,8	36,4	9,5	20,9	10509,2
24/01/2022	248,1	52,3	53,0	89,7	9882,3	30,4	86,2	36,4	9,6	21,3	10509,4
25/01/2022	245,2	52,3	54,5	89,5	9882,1	31,7	86,9	36,4	9,7	21,9	10510,2
26/01/2022	242,2	52,3	56,0	89,2	9882,0	32,9	87,9	35,3	9,9	22,5	10510,2
27/01/2022	239,1	52,3	57,4	88,9	9882,1	34,2	89,1	33,9	10,0	23,1	10510,3
28/01/2022	235,9	52,3	58,7	88,6	9882,3	35,5	90,5	31,1	10,1	23,9	10509,0
29/01/2022	232,4	52,3	59,9	88,3	9882,6	36,9	92,0	27,7	10,3	24,6	10506,9
30/01/2022	228,8	52,3	61,1	88,1	9882,8	38,2	93,4	26,9	10,4	25,3	10507,2

## Lampiran 10 Hasil Hasil Perkembangan Portofolio Alternatif HRP (USD)

Date	AR	REN	TT	BTC	AMP	ETH	ANT	KIN	HT	Total
01/01/2021	395,0	683,0	857,0	3444,0	766,0	1618,0	823,0	338,0	1076,0	10000,0
02/01/2021	402,8	672,6	831,5	3766,8	802,1	1715,8	791,5	300,4	1005,1	10288,6
03/01/2021	388,5	717,8	786,3	3843,6	885,2	2161,1	781,0	305,8	1015,5	10884,6
04/01/2021	405,9	724,9	766,7	3748,6	941,3	2304,5	849,7	305,8	1003,0	11050,3
05/01/2021	426,7	742,3	785,3	3985,5	1089,5	2436,9	845,1	305,8	997,6	11614,5
06/01/2021	467,4	796,4	806,1	4317,5	1087,2	2674,1	887,7	316,5	1038,3	12391,3
07/01/2021	428,7	784,2	794,5	4616,1	1048,4	2715,3	883,4	311,2	1041,9	12623,7
08/01/2021	421,7	831,7	825,2	4783,4	1001,5	2712,0	853,0	359,5	1021,2	12809,2
09/01/2021	482,4	961,1	871,2	4719,7	1012,0	2838,0	893,0	359,5	1082,4	13219,2
10/01/2021	618,0	888,5	815,0	4497,1	995,3	2796,3	970,7	332,6	1151,4	13065,0
11/01/2021	545,6	791,2	762,7	4170,0	908,7	2415,0	856,4	300,4	994,6	11744,8
12/01/2021	619,2	772,5	767,2	3977,3	875,1	2311,5	804,1	279,0	966,4	11372,3
13/01/2021	662,6	940,7	797,3	4375,2	900,0	2505,0	839,5	284,3	1022,8	12327,4
14/01/2021	640,6	1021,1	837,1	4594,6	983,0	2699,3	834,5	252,2	1036,0	12898,2
15/01/2021	622,1	1121,0	814,0	4317,6	939,0	2596,0	849,0	262,9	1053,5	12575,2
16/01/2021	616,7	1162,1	834,3	4241,7	891,5	2732,7	894,9	230,7	1072,1	12676,7
17/01/2021	697,7	1334,9	818,3	4196,4	879,2	2725,2	1232,0	230,7	1108,6	13223,0
18/01/2021	695,2	1279,1	844,3	4294,7	885,4	2785,3	1101,0	225,3	1198,1	13308,4
19/01/2021	741,7	1477,3	841,3	4229,0	863,6	3051,2	1024,5	236,1	1203,2	13667,9
20/01/2021	748,4	1626,8	834,9	4167,8	847,2	3062,2	1032,1	236,1	1197,0	13752,5
21/01/2021	684,5	1256,0	784,6	3614,2	743,1	2484,6	876,0	225,3	1073,2	11741,6
22/01/2021	777,2	1370,3	798,7	3869,8	795,5	2739,3	858,1	209,2	1127,2	12545,1
23/01/2021	813,2	1350,2	795,5	3759,8	745,9	2727,0	947,9	220,0	1196,5	12556,0
24/01/2021	914,0	1355,2	795,0	3785,8	755,6	3082,9	1085,0	230,7	1196,2	13200,4
25/01/2021	831,5	1235,8	784,3	3794,8	748,8	2934,0	990,9	236,1	1182,2	12738,4
26/01/2021	844,5	1281,4	785,8	3818,7	749,9	3006,3	1021,2	220,0	1180,3	12908,1
27/01/2021	766,5	1125,2	757,0	3568,1	658,6	2776,2	892,4	214,6	1133,8	11892,3
28/01/2021	863,0	1252,8	800,6	3923,8	736,1	2951,9	985,0	220,0	1227,5	12960,5
29/01/2021	793,0	1221,2	803,9	4023,5	857,8	3062,7	957,9	193,1	1252,5	13165,7
30/01/2021	753,9	1268,8	793,9	4018,0	878,7	3048,5	1016,3	220,0	1328,0	13325,9
31/01/2021	725,9	1358,6	782,0	3882,5	1106,2	2913,1	1073,8	284,3	1426,9	13553,4
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
01/01/2022	7175,6	2550,6	1014,4	11964,9	1428,2	14501,9	4294,3	213,4	22180,0	65323,2
02/01/2022	7057,0	2574,6	1093,0	7262,7	1447,4	8286,9	4282,7	215,3	14923,2	47142,8
03/01/2022	6967,7	2586,7	1199,8	9822,9	1469,1	10273,1	4266,2	217,9	10558,7	47362,1
04/01/2022	6886,6	2589,2	1314,4	10752,7	1494,2	14068,6	4342,0	220,8	9842,2	51510,6
05/01/2022	6809,9	2585,3	1432,0	8878,5	1522,9	11544,0	4364,3	223,8	9346,5	46707,3
06/01/2022	6735,8	2578,5	1549,7	7793,1	1555,6	9431,6	4403,6	226,9	8436,1	42710,8
07/01/2022	6662,6	2571,0	1664,5	7749,2	1592,4	7505,2	4446,8	230,2	7443,6	39865,7

**Lampiran 10 Hasil Hasil Perkembangan Portofolio Alternatif HRP (USD) (Lanjutan)**

Date	AR	REN	TT	BTC	AMP	ETH	ANT	KIN	HT	Total
08/01/2022	6588,8	2564,5	1774,2	7725,4	1633,6	5843,8	4478,1	233,6	6427,2	37269,2
09/01/2022	6513,3	2559,4	1877,1	7615,4	1679,2	5398,3	4507,2	237,2	5469,4	35856,4
10/01/2022	6435,9	2555,7	1972,2	7462,0	1729,3	6005,9	4527,1	240,8	4622,8	35551,6
11/01/2022	6356,8	2553,1	2059,3	7310,9	1784,0	6860,2	4557,7	244,6	3896,4	35623,0
12/01/2022	6276,7	2551,4	2138,7	7185,7	1843,3	7353,4	4573,3	248,4	3275,6	35446,5
13/01/2022	6196,3	2550,3	2211,7	7099,3	1907,2	7400,8	4575,8	252,2	2751,5	34945,2
14/01/2022	6116,8	2549,6	2279,8	7056,2	1975,7	7178,3	4550,7	256,1	2324,3	34287,5
15/01/2022	6039,0	2549,2	2344,9	7054,1	2049,0	6886,4	4444,9	260,0	1993,6	33621,1
16/01/2022	5963,6	2549,0	2409,0	7085,6	2126,9	6624,8	4380,7	264,0	1750,4	33153,9
17/01/2022	5891,2	2548,9	2474,1	7139,3	2209,5	6420,4	4216,9	267,9	1582,3	32750,5
18/01/2022	5821,9	2549,0	2541,8	7202,8	2296,7	6270,7	4123,3	271,9	1474,3	32552,1
19/01/2022	5755,4	2549,2	2613,2	7264,3	2388,6	6164,6	3926,4	275,8	1411,4	32348,9
20/01/2022	5691,3	2549,5	2688,9	7314,9	2485,1	6092,4	3867,4	279,7	1381,5	32350,7
21/01/2022	5629,1	2549,8	2768,9	7349,4	2586,1	6048,1	3713,8	283,7	1374,8	32303,6
22/01/2022	5567,8	2550,1	2852,6	7366,4	2691,5	6028,8	3697,0	287,6	1384,1	32425,9
23/01/2022	5506,6	2550,4	2938,9	7367,7	2801,0	6033,7	3747,4	291,6	1404,9	32642,2
24/01/2022	5444,8	2550,7	3026,3	7356,5	2914,5	6062,4	3744,4	295,5	1434,2	32829,3
25/01/2022	5381,5	2550,9	3113,0	7337,1	3031,8	6113,8	3747,1	299,4	1470,2	33044,8
26/01/2022	5316,0	2551,2	3197,5	7313,2	3152,4	6184,9	3631,6	303,3	1511,5	33161,6
27/01/2022	5247,7	2551,5	3278,2	7287,8	3276,0	6271,3	3489,4	307,3	1556,6	33265,7
28/01/2022	5175,9	2551,8	3354,0	7263,4	3402,2	6367,8	3204,0	311,2	1605,2	33235,4
29/01/2022	5100,2	2552,0	3424,3	7241,5	3530,4	6469,5	2852,5	315,1	1654,0	33139,6
30/01/2022	5020,1	2552,2	3489,0	7222,6	3660,1	6571,5	2768,1	319,0	1701,6	33304,2

**Lampiran 11 Hasil Hasil Perkembangan Portofolio NCO (USD)**

Date	AR	AMP	ETH	ANT	HT	Total
01/01/2021	3636	2190	3747	412	15	10000
02/01/2021	3707,747	2293,164	3973,592	396,2292	14,01135	10384,74
03/01/2021	3575,97	2530,674	5004,641	390,9652	14,15624	11516,41
04/01/2021	3735,996	2691,225	5336,701	425,3505	13,98245	12203,26
05/01/2021	3927,538	3114,829	5643,354	423,0386	13,90702	13122,67
06/01/2021	4302,761	3108,194	6192,84	444,402	14,47471	14062,67
07/01/2021	3946,399	2997,401	6288,089	442,2152	14,52439	13688,63
08/01/2021	3881,612	2863,387	6280,491	427,0178	14,23674	13466,74
09/01/2021	4440,283	2893,241	6572,303	447,0315	15,08947	14367,95
10/01/2021	5688,838	2845,474	6475,696	485,9612	16,05145	15512,02
11/01/2021	5022,596	2598,013	5592,766	428,7304	13,86594	13655,97
12/01/2021	5699,378	2501,815	5353,126	402,5462	13,47176	13970,34
13/01/2021	6099,474	2573,134	5801,025	420,2363	14,25849	14908,13
14/01/2021	5896,996	2810,312	6251,022	417,7438	14,44259	15390,52
15/01/2021	5726,869	2684,591	6011,856	425,0315	14,68662	14863,03
16/01/2021	5676,946	2548,919	6328,41	447,9693	14,94538	15017,19
17/01/2021	6421,983	2513,756	6311,145	616,7341	15,45512	15879,07
18/01/2021	6398,952	2531,337	6450,213	551,1937	16,70196	15948,4
19/01/2021	6827,468	2468,975	7065,932	512,87	16,77388	16892,02
20/01/2021	6888,626	2422,202	7091,472	516,6684	16,68702	16935,66
21/01/2021	6300,411	2124,652	5753,988	438,5184	14,96147	14632,53
22/01/2021	7154,064	2274,256	6343,671	429,5496	15,71327	16217,25
23/01/2021	7485,316	2132,613	6315,343	474,5055	16,67933	16424,46
24/01/2021	8413,543	2160,145	7139,365	543,1787	16,67506	18272,91
25/01/2021	7654,375	2140,906	6794,637	496,0305	16,48046	17102,43
26/01/2021	7773,962	2143,891	6962,107	511,2155	16,45441	17407,63
27/01/2021	7055,749	1882,829	6429,218	446,7238	15,8057	15830,33
28/01/2021	7943,697	2104,417	6836,076	493,0797	17,1114	17394,38
29/01/2021	7299,715	2452,389	7092,748	479,5546	17,46095	17341,87
30/01/2021	6939,482	2512,098	7059,876	508,7471	18,51286	17038,72
31/01/2021	6681,701	3162,596	6746,265	537,5531	19,89195	17148,01
.	.	.	.	.	.	.
.	.	.	.	.	.	.
01/01/2022	66051,75	4083,221	33583,8	2149,743	309,2011	106177,7
02/01/2022	64960,32	4138,032	19191,02	2143,969	208,0366	90641,38
03/01/2022	64138,08	4200,175	23790,65	2135,697	147,1942	94411,8
04/01/2022	63391,47	4271,85	32580,32	2173,629	137,206	102554,5
05/01/2022	62685,25	4353,957	26733,79	2184,819	130,2955	96088,11
06/01/2022	62003,76	4447,38	21841,94	2204,475	117,603	90615,16
07/01/2022	61329,89	4552,744	17380,7	2226,127	103,7683	85593,22
08/01/2022	60649,9	4670,423	13533,15	2241,787	89,59825	81184,86
09/01/2022	59955,27	4800,796	12501,4	2256,343	76,24665	79590,06

**Lampiran 10** Hasil Hasil Perkembangan Portofolio NCO (USD) (Lanjutan)

Date	AR	AMP	ETH	ANT	HT	Total
10/01/2022	59242,98	4944,094	13908,55	2266,285	64,4436	80426,36
11/01/2022	58514,95	5100,444	15887,06	2281,612	54,31838	81838,39
12/01/2022	57777,01	5269,936	17029,26	2289,405	45,66373	82411,27
13/01/2022	57037,4	5452,646	17139,05	2290,677	38,35787	81958,13
14/01/2022	56305,23	5648,661	16623,71	2278,121	32,40171	80888,13
15/01/2022	55589,05	5858,01	15947,74	2225,153	27,79219	79647,75
16/01/2022	54895,56	6080,738	15341,95	2192,992	24,40168	78535,64
17/01/2022	54228,96	6316,868	14868,61	2110,995	22,05765	77547,49
18/01/2022	53590,52	6566,354	14521,73	2064,145	20,55198	76763,29
19/01/2022	52978,58	6829,11	14276,11	1965,608	19,67557	76069,08
20/01/2022	52389,02	7104,979	14109	1936,031	19,25824	75558,29
21/01/2022	51815,81	7393,705	14006,3	1859,168	19,1653	75094,15
22/01/2022	51251,69	7694,906	13961,62	1850,765	19,29499	74778,28
23/01/2022	50688,92	8008,114	13972,99	1875,983	19,58464	74565,59
24/01/2022	50119,79	8332,704	14039,52	1874,476	19,99331	74386,48
25/01/2022	49537,05	8667,917	14158,43	1875,819	20,49479	74259,72
26/01/2022	48934,13	9012,802	14323,11	1818,02	21,07042	74109,13
27/01/2022	48305,11	9366,186	14523,19	1746,801	21,70044	73962,99
28/01/2022	47644,7	9726,876	14746,69	1603,929	22,37691	73744,57
29/01/2022	46948,11	10093,43	14982,26	1427,96	23,05752	73474,81
30/01/2022	46210,53	10464,23	15218,41	1385,714	23,72168	73302,61

## BIODATA PENULIS



Penulis dilahirkan di Malang pada tanggal 5 Agustus 2000, dan merupakan anak pertama dari dua bersaudara. Penulis telah menempuh pendidikan formal mulai dari, SDN Klojen Kota Malang (2006-2012), SMPN 08 Malang (2012-2015), dan SMAN 03 Malang (2015-2018). Setelah lulus dari SMA pada tahun 2018, penulis mengikuti SBMPTN, dan diterima di Departemen Aktuaria Institut Teknologi Sepuluh Nopember (ITS) dan terdaftar dengan nomor registrasi peserta (NRP) 06311840000032. Selama masa perkuliahan penulis aktif pada kegiatan akademik, dan non-akademik. Kegiatan non-akademik yang pernah dilakukan penulis, diantaranya mengikuti organisasi, Kerja Praktik, dan COOP. Organisasi yang pernah diikuti penulis adalah Himpunan Mahasiswa Aktuaria ITS (HIMASAKTA ITS) sebagai Kepala Departemen Pengembangan Sumber Daya Mahasiswa (2019-2020) dan Ketua Himpunan (2020-2021). Penulis pernah melakukan KP di CSUL Finance cabang Surabaya sebagai *credit analyst*, dan COOP di PT. Smartfren Telecom Tbk sebagai *Big Data Business Analyst*.

Adapun mengenai informasi lebih lanjut mengenai Tugas Akhir ini, dapat ditanyakan kepada penulis melalui email penulis, yaitu [nathanaelsn17@gmail.com](mailto:nathanaelsn17@gmail.com).