

## BAB V HASIL DAN PEMBAHASAN

### 5.1 Pembahasan Hasil dan Uraian dari Perancangan

Bab ini akan menjelaskan pembahasan dari hasil pengujian yang sudah peneliti lakukan. Hasil dari pengujian tersebut akan peneliti jelaskan secara detail sebagai berikut.

#### 5.1.1 *Import Library*

Sebelum memulai sebuah *machine learning* maka dibutuhkannya sebuah *library* yang akan membantu peneliti. Maka dari itu diperlukan *import library machine learning* yang akan dipakai oleh peneliti. *Library* yang akan dipakai nantinya yaitu *pandas*, *numpy* (proses komputasi numerik), *matplotlib* (visualisasikan data kedalam sumbu x dan y), dan *sklearn* (membagi data *train* dan data *test*). Berikut gambar dari *import library* yang peneliti pakai.

```
[1] #Import libraries
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
```

*Gambar 5. 1. Import Library*

#### 5.1.2 *Import Dataset*

Tahapan selanjutnya yaitu melakukan *import dataset*. Dataset yang sudah di dapatkan kemudian di *import* atau di *load* ke dalam *program*. Dataset tersebut yang akan dipakai untuk melakukan prediksi harga *ethereum*. Berikut hasil dari *import dataset*.

|      | Date       | High(d-5)   | High(d-4)   | High(d-3)   | High(d-2)   | High(d-1)   | High(d)     | High(d+1)   | Low(d-5)    | Low(d-4)    | Low(d-3)    | Low(d-2)    | Low(d-1)    | Low(d)      | Low(d+1)    |
|------|------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| 0    | 2017-11-14 | 329.451996  | 324.717987  | 319.453003  | 319.153015  | 328.415009  | 340.177002  | 340.911987  | 307.056000  | 294.541992  | 298.191986  | 298.513000  | 307.024994  | 316.763000  | 329.812988  |
| 1    | 2017-11-15 | 324.717987  | 319.453003  | 319.153015  | 328.415009  | 340.177002  | 340.911987  | 336.158997  | 294.541992  | 298.191986  | 298.513000  | 307.024994  | 316.763000  | 329.812988  | 323.605988  |
| 2    | 2017-11-16 | 319.453003  | 319.153015  | 328.415009  | 340.177002  | 340.911987  | 336.158997  | 334.963989  | 298.191986  | 298.513000  | 307.024994  | 316.763000  | 329.812988  | 323.605988  | 327.523010  |
| 3    | 2017-11-17 | 319.153015  | 328.415009  | 340.177002  | 340.911987  | 336.158997  | 334.963989  | 349.615997  | 298.513000  | 307.024994  | 316.763000  | 329.812988  | 323.605988  | 327.523010  | 327.687012  |
| 4    | 2017-11-18 | 328.415009  | 340.177002  | 340.911987  | 336.158997  | 334.963989  | 349.615997  | 371.290985  | 307.024994  | 316.763000  | 329.812988  | 323.605988  | 327.523010  | 327.687012  | 344.739990  |
| ...  | ...        | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         | ...         |
| 1536 | 2022-01-28 | 2542.144775 | 2537.208496 | 2498.507080 | 2705.784180 | 2510.451660 | 2548.778564 | 2627.609375 | 2381.515137 | 2172.301270 | 2359.384766 | 2417.683105 | 2328.452148 | 2367.833740 | 2526.989746 |
| 1537 | 2022-01-29 | 2537.208496 | 2498.507080 | 2705.784180 | 2510.451660 | 2548.778564 | 2627.609375 | 2631.408447 | 2172.301270 | 2359.384766 | 2417.683105 | 2328.452148 | 2367.833740 | 2526.989746 | 2550.460938 |
| 1538 | 2022-01-30 | 2498.507080 | 2705.784180 | 2510.451660 | 2548.778564 | 2627.609375 | 2631.408447 | 2697.735352 | 2359.384766 | 2417.683105 | 2328.452148 | 2367.833740 | 2526.989746 | 2550.460938 | 2489.072266 |
| 1539 | 2022-01-31 | 2705.784180 | 2510.451660 | 2548.778564 | 2627.609375 | 2631.408447 | 2697.735352 | 2802.315430 | 2417.683105 | 2328.452148 | 2367.833740 | 2526.989746 | 2550.460938 | 2489.072266 | 2682.621826 |
| 1540 | 2022-02-01 | 2510.451660 | 2548.778564 | 2627.609375 | 2631.408447 | 2697.735352 | 2802.315430 | 0.000000    | 2328.452148 | 2367.833740 | 2526.989746 | 2550.460938 | 2489.072266 | 2682.621826 | 0.000000    |

1541 rows x 15 columns

Gambar 5. 2. Import Dataset

Pada Gambar 5.2 data didapatkan dari website *yahoo.finance.com*. Kemudian data tersebut diolah kedalam data *time series*. Peneliti memfokuskan terhadap data *high* dan *low*. Kemudian data tersebut diolah kedalam data *time series* (d-5) samapai (d). Data tersebut merupakan harga 5 hari sebelumnya pada Ethereum.

### 5.1.3 Pre-Processing Data

*Dataset* yang sudah diimport ke dalam program. kemudian *dataset* tersebut akan dinormalisasikan terlebih dahulu sebelum dimasukkan ke dalam pemodelan *machine learning*. Peneliti menggunakan *MinMax scaler* untuk menormalisasikan data *history* Ethereum yang peneliti pakai. Berikut hasil data yang sudah di normalisasikan.

|   | High(d-5) | High(d-4) | High(d-3) | High(d-2) | High(d-1) | High(d)  | High(d+1) | Low(d-5) | Low(d-4) | Low(d-3) | Low(d-2) | Low(d-1) | Low(d)   | Low(d+1) |
|---|-----------|-----------|-----------|-----------|-----------|----------|-----------|----------|----------|----------|----------|----------|----------|----------|
| 0 | 0.057075  | 0.055968  | 0.054737  | 0.054667  | 0.056832  | 0.059582 | 0.059754  | 0.060552 | 0.057173 | 0.058159 | 0.058245 | 0.060544 | 0.063174 | 0.066698 |
| 1 | 0.055968  | 0.054737  | 0.054667  | 0.056832  | 0.059582  | 0.059754 | 0.058643  | 0.057173 | 0.058159 | 0.058245 | 0.060544 | 0.063174 | 0.066698 | 0.065022 |
| 2 | 0.054737  | 0.054667  | 0.056832  | 0.059582  | 0.059754  | 0.058643 | 0.058364  | 0.058159 | 0.058245 | 0.060544 | 0.063174 | 0.066698 | 0.065022 | 0.066079 |
| 3 | 0.054667  | 0.056832  | 0.059582  | 0.059754  | 0.058643  | 0.058364 | 0.061789  | 0.058245 | 0.060544 | 0.063174 | 0.066698 | 0.065022 | 0.066079 | 0.066124 |
| 4 | 0.056832  | 0.059582  | 0.059754  | 0.058643  | 0.058364  | 0.061789 | 0.066857  | 0.060544 | 0.063174 | 0.066698 | 0.065022 | 0.066079 | 0.066124 | 0.070729 |

Gambar 5. 3. Data Normalisasi

### 5.1.4 Split Data

Pemisahan data adalah pendekatan yang umum digunakan untuk validasi model, dimana membagi set data yang diberikan menjadi dua set terpisah: pelatihan dan pengujian. Rasio yang umum digunakan adalah 80:20, yang berarti 80% data untuk pelatihan dan 20% untuk pengujian. Rasio lain seperti 70:30, 60:40, dan bahkan 50:50 juga digunakan dalam praktik (Joseph, 2022). *Dataset* yang sudah didapatkan akan diuji ke dalam pemodelan *K-Nearest Neighbors* dan *Support*

*vector Machine*. Data tersebut akan di bagi menjadi 3 rasio yang berbeda 90:10, 80:20, dan 70:30. Data yang digunakan sebanyak 1541 data yang diambil dari rentang waktu 5 tahun 2017 sampai 2022. Kemudian data dibagi menjadi dua variable yaitu variable X dan y yang dimana variabel(Joseph, 2022). X adalah feature yang akan digunakan dan variabel y adalah data prediksi. Variabel pada X merupakan data *High(d-5)* sampai *High(d)* serta *Low(d-5)* sampai *Low(d)*. kemudian variabel y adalah data predictor yang dimana variable tersebut adalah data *High(d+1)* dan *Low(d+1)*. Berikut hasil dari perbandingan pembagian data yang diuji kedalam pemodelan *K-Nearest Neighbors* dan *Support vector Machine*.

Tabel 5. 1 Pembagian Data dengan Target High d+1 pada KNN

| Rasio | K-Optimal | RMSE  | R <sup>2</sup> |
|-------|-----------|-------|----------------|
| 70:30 | 3         | 0.016 | 0.992          |
| 80:20 | 5         | 0.016 | 0.991          |
| 90:10 | 4         | 0.012 | 0.993          |

*Sumber: Data diolah peneliti*

Tabel 5. 2 Pembagian Data dengan Target Low d+1 pada KNN

| Rasio | K-Optimal | RMSE  | R <sup>2</sup> |
|-------|-----------|-------|----------------|
| 70:30 | 3         | 0.019 | 0.989          |
| 80:20 | 6         | 0.018 | 0.989          |
| 90:10 | 5         | 0.015 | 0.991          |

*Sumber: Data diolah peneliti*

Tabel 5. 3 Pembagian Data dengan Target High d+1 pada SVM

| Rasio | C  | RMSE  | R <sup>2</sup> |
|-------|----|-------|----------------|
| 70:30 | 10 | 0.067 | 0.862          |
| 80:20 | 10 | 0.066 | 0.853          |
| 90:10 | 10 | 0.059 | 0.852          |

*Sumber: Data diolah peneliti*

Tabel 5. 4 Pembagian Data dengan Target Low d+1 pada SVM


| Rasio | C  | RMSE  | R <sup>2</sup> |
|-------|----|-------|----------------|
| 70:30 | 10 | 0,019 | 0.989          |
| 80:20 | 10 | 0,019 | 0.988          |
| 90:10 | 10 | 0,021 | 0.982          |

*Sumber: Data diolah peneliti*

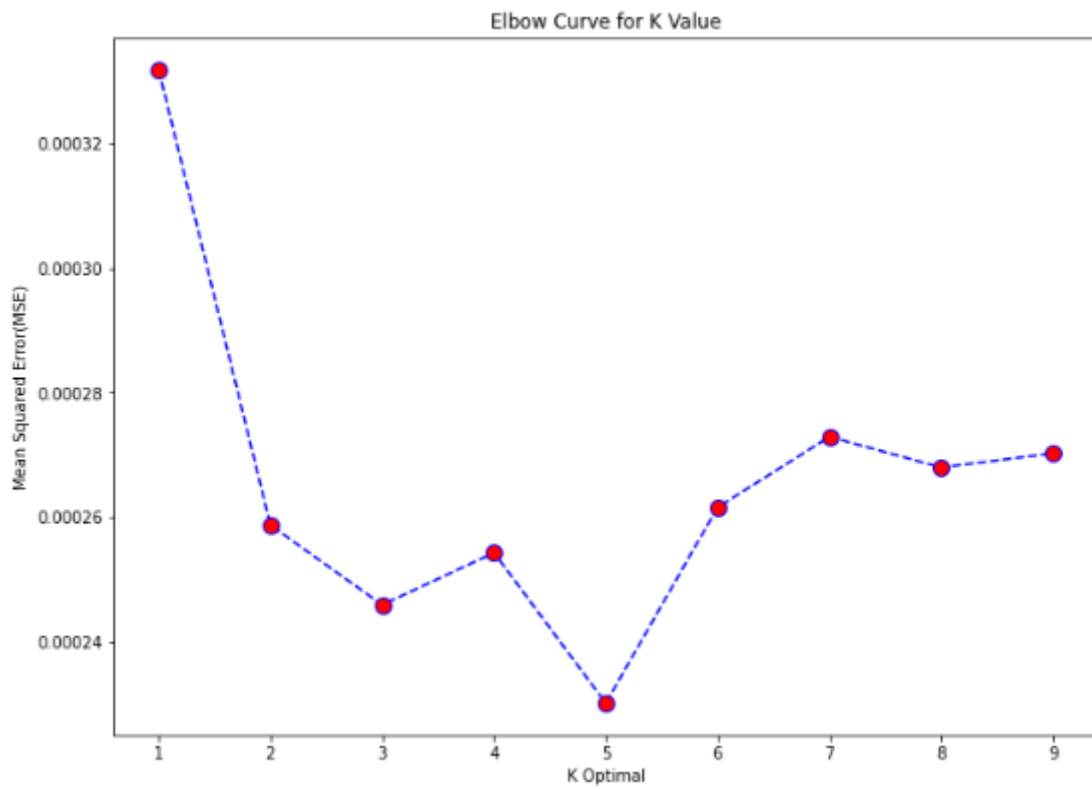
Berdasarkan tabel di atas maka data yang akan dipakai yaitu data yang memiliki RMSE terendah dan R<sup>2</sup> yang tertinggi. RMSE terendah merupakan hasil yang terbaik disebabkan jumlah data yang eror juga termasuk sedikit. R<sup>2</sup> tertinggi merupakan hasil yang baik sebab variabel independen dan dependen memiliki keterkaitan. Maka dapat disimpulkan pembagian data yang terbaik yaitu dengan rasio 90:10.

### 5.1.5 Pemodelan dengan K-Nearest Neighbors

Setelah pembagian data telah dilakukan kemudian melakukan pemodelan prediksi harga Ethereum menggunakan *K-Nearest Neighbors*. Untuk mendapatkan nilai K optimal maka harus menghitung nilai euclidean atau metode elbow. Kegunaan mencari nilai euclidean yaitu mendapatkan angka jarak antar tetangga. Berikut hasil dari K optimal yang di dapatkan dengan data split 90:10.



Gambar 5. 4. Nilai K Optimal dengan target high  $d+1$ .



Gambar 5. 5. Nilai K Optimal dengan target low  $d+1$

Berdasarkan gambar 5.4 merupakan nilai  $k$  optimal dengan target  $high\ d+1$  sebesar 7. Sedangkan nilai  $k$  optimal dengan target  $low\ d+1$  sebesar 6. Nilai  $k$  optimal tersebut menggunakan rasio yang sudah dipakai yaitu 90:10 maka  $k$  optimal tersebut memiliki nilai MSE terkecil. Berikut tersaji diagram perbandingan antara hasil prediksi  $K$ -Nearest Neighbors dengan data uji yang dipakai.



Gambar 5. 6. Grafik perbandingan  $k$ -NN dengan data uji  $High(d+1)$ ( *time-series*,  $k = 4$ , rasio data latih 90:10, data uji = 155 data)



Gambar 5. 7. Grafik perbandingan  $k$ -NN dengan data uji  $High(d+1)$ ( *time-series*,  $k = 6$ , rasio data latih 80:20, data uji = 309 data)



Gambar 5.8. Grafik perbandingan  $k$ -NN dengan data uji  $High(d+1)$ ( time-series,  $k = 3$ , rasio data latih 70:30, data uji = 463 data)



Gambar 5. 9. Grafik perbandingan  $k$ -NN dengan data uji  $Low(d+1)$ ( time-series,  $k = 5$ , rasio data latih 90:10, data uji = 155 data)



Gambar 5. 10. Grafik perbandingan  $k$ -NN dengan data uji  $Low(d+1)$ ( time-series,  $k = 6$ , rasio data latih 80:20, data uji = 309 data)




Gambar 5. 11. Grafik perbandingan  $k$ -NN dengan data uji  $Low(d+1)$  (time-series,  $k = 3$ , rasio data latih 70:30, data uji = 463 data)


### 5.1.6 Pemodelan dengan Support Vector Regression

• Untuk melakukan pemodelan *Support Vector Regression* dibutuhkan sebuah kernel. Kernel tersebut bertujuan untuk mengubah data yang awalnya non linier akan diubah menjadi data yang memiliki dimensi tinggi. Sehingga data yang memiliki dimensi tinggi dapat dibuatnya sebuah *hyperplane*. Penelitian ini menggunakan kernel *linear* sebagai pembantu mengubah data menjadi dimensi yg tinggi. Parameter yang dipakai sebesar 10 disebabkan parameter sebesar 10 akan mendapatkan hasil RMSE lebih kecil dan hasil  $R^2$  yang lebih besar. Berikut merupakan hasil pemodelan *Support Vector Regression* yang dibandingkan dengan data aktual dalam bentuk grafik.





Gambar 5. 12. Grafik perbandingan SVR  $High(d+1)$  dengan data uji (time-series, rasio data latih 90:10 data uji = 155 data)



Gambar 5. 13. Grafik perbandingan SVR  $High(d+1)$  dengan data uji (time-series, rasio data latih 80:20 data uji = 309 data)



Gambar 5. 14. Grafik perbandingan SVR  $High(d+1)$  dengan data uji (time-series, rasio data latih 70:30 data uji = 463 data)



Gambar 5. 15. Grafik perbandingan SVR Low( $d+1$ ) dengan data uji (time-series, rasio data latih 90:10 data uji = 155 data)



Gambar 5. 16. Grafik perbandingan SVR Low( $d+1$ ) dengan data uji (time-series, rasio data latih 80:20 data uji = 309 data)




Gambar 5. 16. Grafik perbandingan SVR Low( $d+1$ ) dengan data uji (time-series, rasio data latih 70:30 data uji = 463 data)

### 5.1.7 Perbandingan Hasil Algoritma


Pemodelan prediksi harga Ethereum yang diperoleh menggunakan algoritma K-Nearest Neighbors dan Support Vector Machine dibandingkan pada suatu grafik. Perbandingan hasil ini dapat memperlihatkan perbedaan model yang dihasilkan pada setiap algoritma. Perbedaan hasil di setiap algoritma merupakan suatu kewajaran dalam pemrosesan data dengan machine learning. Grafik yang akan dibandingkan yaitu membandingkan data uji dengan hasil prediksi algoritma K-Nearest Neighbors dan Support Vector Machine pada High(d+1) dan Low(d+1). Berikut merupakan hasil perbandingan dalam bentuk grafik.




Gambar 5. 17. Grafik perbandingan KNN High(d+1) dengan KNN Low(d+1) (time-series, rasio data latih 90:10, data uji = 155 data)



Gambar 5. 18. Grafik perbandingan SVR High(d+1) dengan SVR Low(d+1) (time-series, rasio data latih 90:10, data uji = 155 data)



Gambar 5. 19. Grafik perbandingan KNN  $High(d+1)$ , SVR  $High(d+1)$  dan Data Uji (time-series,  $k = 5$ , rasio data latih 80:20, data uji = 309)



Gambar 5. 20. Grafik perbandingan KNN  $Low(d+1)$ , SVR  $Low(d+1)$  dan Data Uji (time-series,  $k = 6$ , rasio data latih 80:20, data uji = 309)




Gambar 5. 21 Grafik perbandingan KNN  $High(d+1)$ , SVR  $High(d+1)$  dan Data Uji ( time-series,  $k = 3$ , rasio data latih 70:30, data uji = 463 data)




Gambar 5. 22 Grafik perbandingan KNN Low( $d+1$ ), SVR Low( $d+1$ ) dan Data Uji ( time-series,  $k = 3$ , rasio data latih 70:30, data uji = 463 data)

### 5.2.8. Perbandingan Hasil Akurasi


Pemodelan prediksi harga Ethereum yang diperoleh menggunakan algoritma K-Nearest Neighbors dan Support Vector Machine akan dihitung akurasi. Akurasi yang akan dipakai yaitu RMSE dan R2. Setiap akurasi tersebut akan dibandingkan kedalam bentuk diagram batang. Berikut hasil pengujian dari akurasi kedua algoritma.



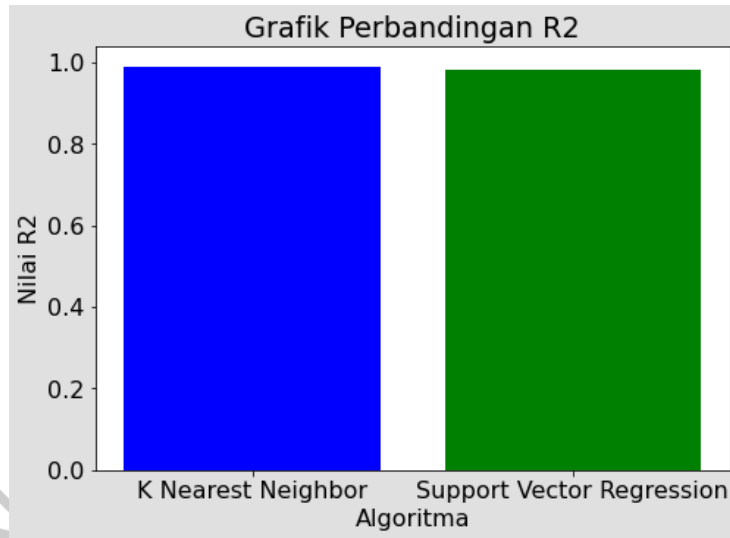
Gambar 5. 23. Grafik perbandingan akurasi RMSE KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k = 4$ , rasio data latih 90:10, data uji = 155)




Gambar 5. 24. Grafik perbandingan akurasi RMSE KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series, rasio data latih 90:10, data uji = 155)




Gambar 5. 25. Grafik perbandingan akurasi R2 KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k=5$ , rasio data latih 90:10, data uji = 155)




Gambar 5. 26. Grafik perbandingan akurasi R2 KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series, rasio data latih 90:10, data uji = 155)



Gambar 5. 27. Grafik perbandingan akurasi RMSE KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k = 5$ , rasio data latih 80:20, data uji = 309)




Gambar 5. 28. Grafik perbandingan akurasi RMSE KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series,  $k=6$ , rasio data latih 80:20, data uji = 309)




Gambar 5. 29. Grafik perbandingan akurasi R2 KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k=5$ , rasio data latih 80:20, data uji = 309)







Gambar 5. 30. Grafik perbandingan akurasi R2 KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series,  $k = 6$ , rasio data latih 80:20, data uji = 309)




Gambar 5. 31. Grafik perbandingan akurasi RMSE KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k = 4$ , rasio data latih 70:30, data uji = 463)



Gambar 5. 32. Grafik perbandingan akurasi RMSE KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series,  $k=3$ , rasio data latih 70:30, data uji = 463)



Gambar 5. 33. Grafik perbandingan akurasi R2 KNN High( $d+1$ ) dan SVR High( $d+1$ ) (time-series,  $k=4$ , rasio data latih 70:30, data uji = 463)



Gambar 5. 34. Grafik perbandingan akurasi R2 KNN Low( $d+1$ ) dan SVR Low( $d+1$ ) (time-series,  $k=3$ , rasio data latih 70:30, data uji = 463)

## 5.2 Hasil Pembahasan Pengujian Kedua Algoritma

Dilakukannya pengujian terhadap kedua algoritma. Pengujian ini bertujuan untuk melihat apakah kode program yang dimasukkan sudah menghasilkan apa yang peneliti harapkan. Berikut hasil pengujian program terhadap kedua algoritma.

Tabel 5. 5 Pengujian program K-Nearest Neighbors

| No | Kode Program   | Hasil yang Diharapkan                          | Hasil Pengujian |
|----|--|--|-----------------|
| 1. | <pre>#Import libraries import pandas as pd import numpy as np import matplotlib.pyplot as plt import sklearn.metrics as metrics from sklearn.model_selection import train_test_split</pre> | Melakukan import library yang akan digunakan . | Valid           |

- |    |   |   |       |
|----|---|---|-------|
| 2. | <pre>#Load dataset path = "/content/drive/MyDrive/Dataset/HISTORY_ETH-USD.csv" data_columns = pd.read_csv(path,index_col=0,parse_dates=True, dtype={'path':int}) data_columns.describe()</pre>                    | Dataset yang sudah ada diimport ke dalam program menjadi sebuah variabel.   | Valid |
| 3. | <pre>#Cleansing Data data_columns = data_columns.dropna(axis=0) data_columns.shape</pre>  | Data yang tidak lengkap atau bernilai nol akan dibersihkan.   | Valid |
| 4. | <pre>features_norm = ['High(d-5)', 'High(d-4)', 'High(d-3)', 'High(d-2)', 'High(d-1)', 'High(d)'] X = Data_scale[features_norm] y = Data_scale['High(d+1)']</pre>   | Menentukan fitur pertama yang akan digunakan. Serta menetapkan target High(d+1) yang akan dilakukan untuk prediksi. | Valid |
| 5. | <pre>features = ['Low(d-5)', 'Low(d-4)', 'Low(d-3)', 'Low(d-2)', 'Low(d-1)', 'Low(d)'] X1 = Data_scale[features] y1 = Data_scale['Low(d+1)']</pre>  | Menentukan fitur kedua yang akan digunakan. Serta target kedua yang akan diprediksi yaitu Low(d+1).                 | Valid |
| 6. | <pre>#Membagi Data Training dan Testing (90 10) from sklearn.model_selection import train_test_split train_X, test_X, train_y, test_y = train_test_split(X,y, random_state=0, test_size=0.1, shuffle=False)</pre> | Pada features high d+1 membagi data training dan  | Valid |

- data test sebesar 90:10.
7. 

```
#Membagi Data Training dan Testing (90 10)
from sklearn.model_selection import train_test_split
train_X1, test_X1, train_y1, test_y1 = train_test_split(X1,y1, random_state=0, test_size=0.1, shuffle=False)
```

Pada features Valid  
low d+1  
membagi data train dan data test sebesar 90:10.
  8. 

```
[ ] #Preprocessing Normalisasi dengan MINMAXSCALER
from sklearn import preprocessing
from sklearn.preprocessing import MinMaxScaler

scaler = preprocessing.MinMaxScaler()

names = X.columns
d = scaler.fit_transform(X)
scaled_df = pd.DataFrame(d, columns=names)
scaled_df.head()
```

Normalisasi Valid  
data menggunakan *min max scaler*
  9. 

```
def Elbow(K):
    test_mse = []

    for i in K:
        model = KNN_Reg(n_neighbors=i)
        model.fit(train_X, train_y)
        tmp = model.predict(test_X)
        tmp = mse(tmp, test_y)
        test_mse.append(tmp)
    return test_mse
K = range(1,10)
test = Elbow(K)

#Grafik K optimal
plt.figure(figsize=(11, 8))
plt.plot(range(1,10), test,color='blue', linestyle='dashed', marker='o',
         markerfacecolor='red', markersize=10)
plt.title('Elbow Curve for K Value')
plt.xlabel('K Optimal')
plt.ylabel('Mean Squared Error(MSE)')
```

Mencari nilai Valid  
K optimal menggunakan metode elbow
  10. 

Melakukan Valid  
pemodelan KNN dan mencari akurasi RMSE dan  $R^2$

```
[26] #define model KNN
      model_knn= KNN_Reg(n_neighbors = 2)

      # training the model KNN
      model_knn.fit(train_X, train_y)

      KNeighborsRegressor(n_neighbors=2)

[27] # test for prediction
      test_predict_knn = model_knn.predict(test_X)

[28] #RMSE
      rmse_knn = sqrt(mse(test_y,test_predict_knn))

      #R2
      r2_knn =r2_score(test_y,test_predict_knn)

[29] print('RMSE K-NN: ', rmse_knn)
      print('Skor R2 K-NN: ', r2_knn)
```

```
11. #Prediksi 1 Hari Selanjutnya
     harga_ethereum =np.array([[2510, 2548, 2627, 2631, 2697,2802]])

     #Pemodelan Prediksi
     prediction_svr = SVR_model.predict(harga_ethereum)
     prediction_knn = model_knn.predict(harga_ethereum)

     # 01 Februari 2022 :2,802.32

     #Hasil Prediksi
     print ('Prediksi High Pada 02 Februari 2022')
     print ('SVR : ', prediction_svr)
     print ('KNN : ', prediction_knn)
```

Melakukan  Valid  
 prediksi high  
 d+1 pada  
 harga  
 Ethereum di  
 tanggal 02  
 Februari 2022

```
12. #Prediksi 1 Hari Selanjutnya
     harga_ethereum1 =np.array([[2328, 2367, 2526, 2550, 2489, 2682]])

     #Pemodelan Prediksi
     prediction_svr1 = SVR_model1.predict(harga_ethereum1)
     prediction_knn1 = model_knn1.predict(harga_ethereum1)

     # 01 Februari 2022 :2,802.32

     #Hasil Prediksi
     print ('Prediksi High Pada 02 Februari 2022')
     print ('SVR : ', prediction_svr1)
     print ('KNN : ', prediction_knn1)
```

Melakukan  Valid  
 prediksi low  
 d+1 pada  
 harga  
 Ethereum di  
 tanggal 02  
 Februari 2022

Sumber: Data diolah peneliti

Tabel 5. 6 Pengujian program Support Vector Machine

| No. | Kode Program   | Hasil yang Diharapkan   | Hasil Pengujian |
|-----|--|---|-----------------|
| 1.  | <pre>#Import libraries import pandas as pd import numpy as np import matplotlib.pyplot as plt import sklearn.metrics as metrics from sklearn.model_selection import train_test_split</pre>     | Melakukan import library yang akan digunakan .  | Valid           |
| 2.  | <pre>#Load dataset path = "/content/drive/MyDrive/Dataset/HISTORY_ETH-USD.csv" data_columns = pd.read_csv(path,index_col=0,parse_dates=True, dtype={'path':int}) data_columns.describe()</pre> | Dataset sudah diimport ke dalam program menjadi sebuah variabel.  | Valid           |
| 3.  | <pre>#Cleansing Data data_columns = data_columns.dropna(axis=0) data_columns.shape</pre>   | Data tidak atau bernilai nol akan dibersihkan.  | Valid           |
| 4.  | <pre>features_norm = ['High(d-5)', 'High(d-4)', 'High(d-3)', 'High(d-2)', 'High(d-1)', 'High(d)'] X = Data_scale[features_norm] y = Data_scale['High(d+1)']</pre>                              | Menentukan fitur pertama yang akan digunakan. Serta menetapkan target High(d+1) yang akan dilakukan untuk prediksi. | Valid           |
| 5.  | <pre>features = ['Low(d-5)', 'Low(d-4)', 'Low(d-3)', 'Low(d-2)', 'Low(d-1)', 'Low(d)'] X1 = Data_scale[features] y1 = Data_scale['Low(d+1)']</pre>   | Menentukan fitur kedua yang akan digunakan. Serta target kedua yang   | Valid           |

|    |   |   |
|----|---|---|
| 6. | <pre> #Membagi Data Training dan Testing (90 10) from sklearn.model_selection import train_test_split train_X, test_X, train_y, test_y = train_test_split(X,y, random_state=0, test_size=0.1, shuffle=False) </pre>   | akan diprediksi yaitu Low(d+1). Pada features high d+1 membagi data training dan data test sebesar 90:10. Valid |
| 7. | <pre> #Membagi Data Training dan Testing (90 10) from sklearn.model_selection import train_test_split train_x1, test_x1, train_y1, test_y1 = train_test_split(X1,y1, random_state=0, test_size=0.1, shuffle=False) </pre>   | Pada features low d+1 membagi data train dan data test sebesar 90:10. Valid                                     |
| 8. | <pre> [ ] #Preprocessing Normalisasi dengan MINMAXSCALER from sklearn import preprocessing from sklearn.preprocessing import MinMaxScaler  scaler = preprocessing.MinMaxScaler()  names = X.columns d = scaler.fit_transform(X) scaled_df = pd.DataFrame(d, columns=names) scaled_df.head() </pre>  | Normalisasi data menggunakan <i>minmax scaler</i> . Valid   |
| 9. | <pre> [30] # Model SVR from sklearn.svm import SVR SVR_model = SVR(kernel = 'linear', C=10) #SVR_model = SVR(kernel = 'rbf', C=5000)  # Fit Model SVR_model.fit(train_X, train_y)  # test for prediction test_predict_SVR = SVR_model.predict(test_X)  #RMSE rmse_SVR = sqrt(mse(test_y, test_predict_SVR))  #R2 r2_SVR = r2_score(test_y, test_predict_SVR)  print('RMSE SVR: ', rmse_SVR) print('Skor R2 SVR: ', r2_SVR) </pre> | Melakukan pemodelan SVR dan mencari akurasi RMSE dan R <sup>2</sup> . Valid                                     |



- |     |  |   |       |
|-----|--|---|-------|
| 10. | <pre>#Prediksi 1 Hari Selanjutnya harga_ethereum=np.array([[2510, 2548, 2627, 2631, 2697,2802]])  #Pemodelan Prediksi prediction_svr = SVR_model.predict(harga_ethereum) prediction_knn = model_knn.predict(harga_ethereum)  # 01 Februari 2022 :2,802.32  #Hasil Prediksi print ('Prediksi High Pada 02 Februari 2022') print ('SVR : ', prediction_svr) print ('KNN : ', prediction_knn)</pre>           | Melakukan<br>prediksi high<br>d+1 pada<br>harga<br>Ethereum di<br>tanggal 02<br>Februari 2022 | Valid |
| 11. | <pre>#Prediksi 1 Hari Selanjutnya harga_ethereum1=np.array([[2328, 2367, 2526, 2550, 2489, 2682]])  #Pemodelan Prediksi prediction_svr1 = SVR_model1.predict(harga_ethereum1) prediction_knn1 = model_knn1.predict(harga_ethereum1)  # 01 Februari 2022 :2,802.32  #Hasil Prediksi print ('Prediksi High Pada 02 Februari 2022') print ('SVR : ', prediction_svr1) print ('KNN : ', prediction_knn1)</pre> | Melakukan<br>prediksi low<br>d+1 pada<br>harga<br>Ethereum di<br>tanggal 02<br>Februari 2022  | Valid |

*Sumber: Data diolah peneliti*