

OPTIMASI PORTOFOLIO DAN PREDIKSI CRYPTOCURRENCY MENGGUNAKAN DEEP LEARNING DALAM BAHASA PYTHON

Adhitho Satyo Bayangkari Karno¹, Widi Hastomo², Dodi Arif² dan
Eka Sally Moreta²

⁽¹⁾Universitas Gunadarma

Jl. Margonda Raya No. 100, Depok, Jawa Barat 16424

⁽²⁾STMIK Jakarta STI&K

Jl. BRI No.17, Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140

{adh1t10.2, widie.has}@gmail.com

ABSTRAK

Penelitian ini menggunakan 2 metode, yaitu analisa portofolio berfungsi memilih jenis saham cryptocurrency yang memberikan keuntungan dengan risiko kecil dan prediksi jenis saham terpilih menggunakan Deep Learning (DL). Untuk memperoleh prediksi akurasi tinggi dilakukan optimalisasi DL dengan mengkombinasikan model LSTM (Long Short Term Memory) dan GRU (Gated Recurrent Unit) ke dalam 5 tipe hidden layer arsitektur DL. Hasil dari penelitian ini yaitu, terpilihnya 3 saham portofolio BTC-USD, BNB-USD, dan XRP-USD yang mampu memberikan keuntungan dan risiko yang minim, serta hasil prediksi terbaik untuk BTC-USD dengan epoch = 450, RMSE=375.5336079 dengan arsitektur layer GRU, GRU, GRU, GRU. Portofolio BNB-USD, epoch 40, RMSE=0.8718438 dengan arsitektur layer GRU, GRU, GRU, GRU. Portofolio XRP-USD, epoch 45, RMSE=0.00962406 dengan arsitektur layer GRU, GRU, LSTM, LSTM.

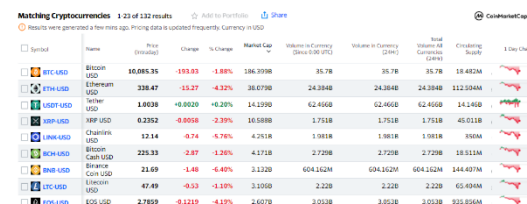
Kata Kunci : Cryptocurrency, Deep Learning, GRU, LSTM, Portofolio

PENDAHULUAN

Tahun 2008 menjadi awal mula berdirinya bitcoin dengan didaftarkannya domain bitcoin.org, yang berfungsi sebagai media transaksi antar peserta. Cryptocurrency telah mendapatkan perhatian dunia, kapitalisasi pasar yang cepat dan besar hal tersebut dibubukan dengan pendapatan pada tahun 2018 lebih dari \$700 miliar. Keberagaman cryptocurrency memberikan pilihan kepada investor untuk berinvestasi pada produk yang berbeda. Survei yang telah dilakukan oleh [1] mengungkapkan bahwa lebih dari 1.500 uang digital diperdagangkan diseluruh dunia.

Pada sepuluh bulan terakhir ini terjadi peningkatan transaksi cryptocurrency yang sangat signifikan, fenomena ini terjadi disaat pandemic covid-19, apakah lebih aman investasi di cryptocurrency? Pada gambar 1 terlihat daftar saham cryptocurrency dengan marketcap tinggi, menggambarkan minat investor yang besar untuk berinvestasi. Pada bulan desember 2019 transaksi kurang dari \$600 billion, puncaknya terjadi pada bulan

februari 2020 mencapai angka \$1200 billion [3].



Symbol	Name	Price (USD)	Change	% Change	Market Cap	Volume in Currency (24H)	Volume in Currency (24H)	Volume All Currencies (24H)	1 Day Chart
BTC	Bitcoin USD	10,085.35	153.83	1.58%	186,379M	35.78	35.78	18,482M	
ETH	Ethereum USD	238.47	15.17	6.32%	38,079M	24,384M	24,384M	112,594M	
XRP	XRP USD	1.8038	-0.0010	-0.20%	14,129M	62,466M	62,466M	14,146M	
BNB	BNB USD	0.2352	-0.0016	-2.39%	16,588M	1,711M	1,711M	46,021M	
ADA	Cardano USD	0.214	-0.14	-6.74%	4,261M	1,981M	1,981M	9,05M	
DOT	Polkadot USD	228.33	-2.87	-1.26%	4,171M	2,728M	2,728M	18,511M	
TRX	TRON USD	21.69	-1.48	-6.40%	3,122M	604,162M	604,162M	144,403M	
EOS	EOS USD	47.49	-0.53	-1.10%	3,050M	2,220	2,220	65,493M	
DOGE	Dogecoin USD	2.7859	-0.2219	-8.19%	2,607M	3,032M	3,032M	935,956M	

Gambar 1. Daftar saham Cryptocurrency dengan marketcap tinggi[2]

Penelitian terkait yang dilakukan [4] dengan metode komparasi ARIMA (Auto-Regressive Integrated Moving Average) memberikan hasil terbaik masing-masing sebesar 2,76% dan 302,53 untuk MAPE dan RMSE, namun Gated Recurrent Unit (GRU) berkinerja lebih baik daripada Long Short-term Memory (LSTM), dengan masing-masing 3,97% dan 381,34 MAPE dan RMSE, data yang digunakan hanya transaksi bitcoin sejumlah 1.639 baris. [5] berpendapat bahwa prediksi bitcoin menggunakan data periode juni-juli 2019 hasil GRU lebih baik dibanding dengan LSTM dan SARIMA. Penelitian [6] prediksi bitcoin dengan komparasi metode antara

ANN (MLP, GRU, LSTM), SVM, Ridge Regression, dan Heterogeneous Auto-Regression Realized Volatility (HARRV) dengan hasil Ridge Regression yang paling superior. Prediksi bitcoin yang dilakukan [7] menggunakan metode RNN dengan akurasi 85,40%, LSTM 92,30%, ARIMA 91% dan hasil terbaik yaitu GRU dengan akurasi mencapai 94,70% dan error rate 5,3%.

Kebaruan dari penelitian ini yaitu:

- Memprediksi saham portofolio cryptocurrency dalam 50 hari kedepan.
- Mengkombinasikan LSTM dan GRU ke dalam 4 layer arsitektur DL.
- Karakteristik grafik epoch-RMSE, untuk memudahkan memperoleh nilai epoch dan mencari susunan kombinasi layer yang tepat untuk memperoleh hasil dengan akurasi tinggi.

METODE PENELITIAN

Mean, Varian, Standar Deviasi

Karena data awal yang dipergunakan adalah 8 data saham, maka untuk mengetahui karakteristik data tersebut perlu untuk mengetahui nilai dari mean, variansi dan kovaariannya.

Mean merupakan salah satu ukuran di dalam statistik untuk menentukan pusat kecenderngan dari sekelompok nilai, dalam hal ini akan dihitung nilai mean untuk tiap data (8 data) menggunakan formula berikut:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \dots\dots(1)$$

Dimana;

$$\begin{aligned} \bar{x} &= \text{rata - rata (mean)} \\ x_i &= \text{nilai sampel ke } i \\ n &= \text{jumlah sampel} \end{aligned}$$

Varian adalah suatu nilai yang dipergunakan untuk mengetahui gambaran secara numeris seberapa jauh total sebaran data dari pusat data yang ada dari suatu kelompok data.

Formula varian:

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \dots\dots(2)$$

Formula standar deviasi:

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \dots\dots(3)$$

$$\begin{aligned} s^2 &= \text{varian} \\ s &= \text{standar deviasi} \\ \bar{x} &= \text{rata - rata (mean)} \\ x_i &= \text{nilai } x \text{ ke } i \\ n &= \text{jumlah sampel} \end{aligned}$$

Kovarian dan Korelasi

Kovarian adalah angka statistik yang umum dipergunakan untuk mengetahui pergerakan 2 data. Kovarian menunjukkan nilai positif jika 2 data bergerak bersamaan naik atau turun, menunjukkan nilai negatif jika satu data bergerak naik dan data yang lain turun atau sebaliknya.

Formula kovarian:

$$\text{cov} = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(x_j - \bar{x}_j)}{n-1} \dots\dots(4)$$

$$\begin{aligned} \bar{x}_i &= \text{rata} \\ &= \text{rata untuk data pertama} \\ \bar{x}_j &= \text{rata - rata untuk data kedua} \\ x_i &= \text{nilai } x \text{ ke } i \text{ untuk data pertama} \\ x_j &= \text{nilai } x \text{ ke } j \text{ untuk data ke dua} \\ n &= \text{jumlah sampel} \\ \text{cov} &= \text{kovarian} \end{aligned}$$

Korelasi merupakan ukuran statistik yang dipergunakan untuk mengetahui bentuk dan kekuatan hubungan antara 2 data atau variabel.

$$r_{x,y} = \frac{n(\sum X_i Y_i) - (\sum X_i)(\sum Y_i)}{\sqrt{(n(\sum X_i^2) - (\sum X_i)^2)(n(\sum Y_i^2) - (\sum Y_i)^2)}} \dots\dots(5)$$

Dimana;

$$\begin{aligned} \sum X_i &= \text{jumlah dari } X \\ \sum Y &= \text{jumlah dari } Y \\ \sum X_i Y &= \text{jumlah dari } (X_i \cdot Y) \\ \sum X_i^2 &= \text{jumlah dari } X_i^2 \end{aligned}$$

Rumus korelasi Pearson.

Hasil numerik korelasi berupa bilangan dengan rentang -1 dan 1, dimana nilai ± 1 menunjukkan hubungan yang kuat, dan nilai 0 menunjukkan hubungan yang rendah antara dua data.

Expected Return, return yang digunakan dari perjalanan historis data memilih beberapa investasi dengan memperoleh keuntungan dari suatu investasi. Menghitung expected return dengan cara menjumlahkan semua perkalian masa depan dengan kemungkinan (probabilitas) kejadian. Nilai expected portofolio ditunjukkan dengan menghitung nilai dari expected portofolio varian.

Formula expected portofolio varian (epvar)

$$epvar = WT*(cov)*W \dots\dots\dots (6)$$

Dimana;

epvar = expected portofolio varian

W = nilai bobot

WT = transpose nilai bobot

cov = matrik kovarian

Efficient Frontier, merupakan visualisasi grafik fungsi hiperbola dari kumpulan portofolio untuk menentukan nilai expected return maksimal. Nilai expected return akan terkonsentrasi di kiri atas pada grafik efficient frontier.

Sharpe ratio

Sharpe ratio merupakan nilai maksimum inestasi, menggambarkan perbandingan antara return dan risiko:[13].

$$Sharpe\ ratio = \frac{mean}{standar\ deviasi}$$

Semakin tinggi sharpe ratio, akan memberikan return yang lebih tinggi untuk tiap satuan risiko.

RMSE dan MSE

Akurasi dari hasil prediksi DL menggunakan nilai kesalahan RMSE (*Root Mean Square Error*) dan MSE (*Mean Square Error*). Nilai RMSE umumnya digunakan untuk mengetahui seberapa jauh nilai kesalahan dari suatu model terhadap garis regresi linier[10]. Sedangkan MSE merupakan kuadrat nilai dari RMSE. Perbedaannya adalah RMSE mampu meredam perubahan kesalahan yang besar, sebaliknya MSE mampu melihat perubahan kesalahan yang kecil[11].

Rumus RMSE dan MSE:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_1 - \hat{y}_1)^2}{n}} \quad MSE = \frac{1}{n} \sum_{i=1}^n (y_1 - \hat{y}_1)^2 \dots\dots\dots (7)$$

Dimana;

$$\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$$


= nilai yang diprediksi

y_1, y_2, \dots, y_n = nilai yang diamati

n = jumlah data yang diamati

Deep Learning

Berawal dari model forward neural network sederhana kemudian berkembang menjadi backpropagation neural network, recurrent neural network (RNN). Karena ketidak mampuan RNN dalam menyimpan memori jangka panjang (terutama untuk data historis), dilakukan penyempurnaan yang menghasilkan bentuk sell dengan beberapa gate kompleks didalamnya,yaitu LSTM (Long Short Term Memory). Banyaknya gate kompleks dalam LSTM tentunya akan mempengaruhi waktu proses. Penyederhanaan sel dengan jumlah gate lebih sedikit dan simple membentuk suatu model baru dinamakan GRU (Gated Recurrent Unit). Semakin meningkatnya performa komputer, mengandakan jumlah layer dan node menjadi suatu hal memungkinkan dan mudah untuk dilakukan. Proses learning dari mesin menjadi lebih dalam sehingga menjadikan mesin lebih pandai lagi. Perkembangan jumlah layer dan node ini menjadikan mesin learning dengan klasifikasi khusus yang dinamakan Deep Learning (DL).




Gambar 2. RNN , LSTM , GRU.[12]

Formula GRU

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \hat{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\ C_t &= f_t * C_{t-1} + i_t * \hat{C}_t \\ O_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t &= O_t * \tanh(C_t) \end{aligned}$$

Formula LSTM

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\
 \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\
 O_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\
 h_t &= O_t * \tanh(C_t)
 \end{aligned}$$



Skenario Penelitian



Gambar 3. Skenario Penelitian

Data mentah

Sumber data penelitian diperoleh dari “finance.yahoo.com”, berisi 9 data saham top Cryptocurrency dunia, yaitu: BCH-USD, BNB-USD, BTC-USD, EOS-USD, ETH-USD, LTC-USD, USDT-USD, XLM-USD, XRP-USD. Data mulai dari tanggal 8-8-2018 s/d 13-8-2020, jumlah 736 baris, dengan memilih satu fitur “close” dari setiap data saham.

Symbols	BCH-USD	BNB-USD	BTC-USD	EOS-USD	ETH-USD	LTC-USD	USDT-USD	XLM-USD	XRP-USD
2018-08-08	610.781006	12.8580	6568.229980	5.90231	365.588013	63.980901	1.00424	0.221435	0.346771
2018-08-09	572.437988	12.1308	6184.709951	5.27668	334.175995	59.394001	1.00158	0.225430	0.320426
2018-08-10	566.773010	11.7366	6295.729980	5.01716	322.112000	58.359100	1.00985	0.217665	0.301262

Symbols	BCH-USD	BNB-USD	BTC-USD	EOS-USD	ETH-USD	LTC-USD	USDT-USD	XLM-USD	XRP-USD
2020-08-11	287.606781	21.751450	11584.934570	3.090108	391.024170	54.968586	1.013791	0.102179	0.284930
2020-08-12	299.516388	22.075546	11784.137695	3.181062	428.741791	57.741318	1.020210	0.102137	0.297807
2020-08-13	293.398041	23.069792	11768.871094	3.254897	437.397827	56.753124	1.001024	0.104972	0.300371

Gambar 4. Data mentah cryptocurrency



Gambar5-a. Sebaran saham BTC-USD

Gambar5-b. Sebaran 8 saham XRP-USD, BCH-USD, ADA-USD, LTC-USD, BNB-USD, NEO-USD, DASH-USD, EOS-USD.



Gambar5-c. Sebaran rasio 9 saham

Analisa Portofolio

Proses selanjutnya yaitu dari 9 data mentah dilakukan pemilihan data untuk memperkirakan saham bernilai return tinggi dan resiko dapat diperkirakan untuk diinvestasikan. Pemilihan dilakukan dengan menggunakan analisa portofolio dari 9 data saham.

Ada beberapa tahap yang dilakukan dalam melakukan analisa portofolio.

1. Bobot awal

Pertama adalah memberikan nilai bobot awal dengan besar yang sama untuk 9 saham, jumlah semua bobot harus 100%. Setiap data saham akan memiliki bobot awal sebesar 11% (Gambar 6).

```

# Assign weights to the stocks. Weights must = 1
display(np.array(dataset.columns))
w_awal = 1/len(dataset.columns)
weights=np.full(
    shape=len(dataset.columns),
    fill_value=w_awal,
    dtype=np.float)

weights
array(['BCH-USD', 'BNB-USD', 'BTC-USD', 'EOS-USD', 'ETH-USD', 'LTC-USD',
       'USDT-USD', 'XLM-USD', 'XRP-USD'], dtype=object)
array([0.11111111, 0.11111111, 0.11111111, 0.11111111, 0.11111111,
       0.11111111, 0.11111111, 0.11111111, 0.11111111])
    
```

Gambar 6.. Bobot awal untuk 9 data

2. Return harian

Selanjutnya dihitung untuk proses return sederhana harian dengan cara

menghitung $(\text{new_price} - \text{old_price}) / \text{old_price}$ atau $(\text{new_price} / \text{old_price}) - 1$.

```
#Show the daily simple returns, NOTE: Formula = new_price/old_price - 1
returns = dataset.pct_change()
returns
```

Date	BCH-USD	BNB-USD	BTC-USD	EOS-USD	ETH-USD	LTC-USD	USDT-USD	XLM-USD	XRP-USD
2018-08-08	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2018-08-09	-0.062777	-0.056558	-0.058390	-0.090590	-0.085922	-0.071690	-0.002649	0.018041	-0.075972
2018-08-10	-0.009896	-0.032496	0.017951	-0.049182	-0.036101	-0.017424	0.008257	-0.034445	-0.059808
2018-08-11	0.007386	0.000443	0.004282	-0.000598	-0.007892	0.016604	-0.009269	0.027271	-0.011259
2018-08-12	-0.061269	-0.128907	-0.003973	-0.077897	-0.103498	-0.041800	0.003438	-0.000188	-0.068500
2018-08-13	-0.049763	-0.079006	-0.015539	-0.009103	-0.026398	-0.040262	-0.006362	-0.030654	-0.011511

Gambar 7. Return sederhana harian


3. Korelasi

Pergerakan antara dua data secara numeris dihitung menggunakan korelasi. Hasil perhitungan korelasi antar 2 data saham divisualisasi dalam format heatmap sebagai berikut: (Gambar 8)

```
dataset.corr()
```

Symbols	BCH-USD	BNB-USD	BTC-USD	EOS-USD	ETH-USD	LTC-USD	USDT-USD	XLM-USD	XRP-USD
BCH-USD	1.000000	0.298207	0.373456	0.800541	0.682279	0.527181	-0.423211	0.651097	0.518990
BNB-USD	0.298207	1.000000	0.726788	0.483100	0.535282	0.673623	-0.079577	-0.288264	0.025525
BTC-USD	0.373456	0.726788	1.000000	0.138820	0.689189	0.491456	-0.216213	-0.288084	-0.219819
EOS-USD	0.800541	0.483100	0.138820	1.000000	0.462037	0.778052	-0.276257	0.614778	0.730103
ETH-USD	0.682279	0.535282	0.689189	0.462037	1.000000	0.527548	-0.238399	0.276274	0.192877
LTC-USD	0.527181	0.673623	0.491456	0.778052	0.527548	1.000000	-0.117091	0.080742	0.388268
USDT-USD	-0.423211	-0.079577	-0.216213	-0.276257	-0.238399	-0.117091	1.000000	-0.320941	-0.198103
XLM-USD	0.651097	-0.288264	-0.288084	0.614778	0.276274	0.080742	-0.320941	1.000000	0.792730
XRP-USD	0.518990	0.025525	-0.219819	0.730103	0.192877	0.388268	-0.198103	0.792730	1.000000

Gambar 8-a. Hasil perhitungan korelasi



Gambar 8-b. Heatmap korelasi

4. Varian dan Kovarian


Karena varian adalah numeris mengetahui jarak sebaran data dari pusat data (mean), dan kovarian mengetahui jenis pergerakan antara 2 data yang berbeda. Maka menghitung varian dan kovarian adalah dengan menggunakan hasil perhitungan sebelumnya (return sederhana harian). Matrik kovarian tahunan ditunjukkan dengan mengkalikan matrik kovarian dengan hari perdagangan selama 1 tahun (252 hari). Bilangan diagonal dalam kotak merah (Gambar 9. Varian dan

kovarian) menunjukkan nilai varian dan lainnya adalah kovarian.

```
cov_matrix_annual = returns.cov() * 252
cov_matrix_annual
```

Symbols	BCH-USD	BNB-USD	BTC-USD	EOS-USD	ETH-USD	LTC-USD	USDT-USD	XLM-USD	XRP-USD
BCH-USD	0.965625	0.467503	0.452921	0.658260	0.601154	0.616571	-0.002746	0.491644	0.488307
BNB-USD	0.467503	0.546749	0.316708	0.445887	0.435572	0.427596	-0.004798	0.363896	0.342827
BTC-USD	0.452921	0.316708	0.353812	0.395120	0.386133	0.374614	0.000108	0.306147	0.296711
EOS-USD	0.658260	0.445887	0.395120	0.707381	0.559749	0.571174	-0.002917	0.458728	0.473577
ETH-USD	0.601154	0.435572	0.386133	0.559749	0.582136	0.516538	-0.004569	0.444857	0.449599
LTC-USD	0.616571	0.427596	0.374614	0.571174	0.516538	0.608506	-0.002649	0.427008	0.421240
USDT-USD	-0.002746	-0.004798	0.000108	-0.002917	-0.004569	-0.002649	0.007407	-0.002812	-0.003478
XLM-USD	0.491644	0.363896	0.306147	0.458728	0.444857	0.427008	-0.002812	0.559216	0.422517
XRP-USD	0.488307	0.342827	0.296711	0.473577	0.449599	0.421240	-0.003478	0.422517	0.540198

Gambar 9.a. Matrik Varian dan kovarian



Gambar 9.b. Heatmap Varian dan kovarian

5. Expected portofolio harian

Expected portofolio harian dihitung menggunakan formula epvar (formula 5). Nilai dari expected portofolio volatility harian adalah nilai akar hasil perhitungan epvar harian.

```
port_variance = np.dot(weights.T, np.dot(cov_matrix_annual, weights))
port_variance

0.37109141080110386

port_volatility = np.sqrt(port_variance)
port_volatility

0.6091727265735917
```

Gambar 10. Hasil perhitungan portofolio varian dan volatility

Hasil perhitungan expected portofolio varian harian (Gambar 10) adalah 0.3710914108 (37%) dan expected portofolio volatility harian adalah 0.60917272657 (61%)

6. Annual return, volatility dan variance

Untuk menghitung return, volatility dan varian untuk periode setahun, menggunakan hasil dari perhitungan sebelumnya untuk periode setahun (252 hari).

```
portfolioSimpleAnnualReturn = np.sum(returns.mean()*weights) * 252
portfolioSimpleAnnualReturn

0.2375895704145781

percent_var = str(round(port_variance, 2) * 100) + '%'
percent_vols = str(round(port_volatility, 2) * 100) + '%'
percent_ret = str(round(portfolioSimpleAnnualReturn, 2)*100)+'%'
print("Expected annual return : "+ percent_ret)
print("Annual volatility/standard deviation/risk : "+percent_vols)
print("Annual variance : "+percent_var)

Expected annual return : 24.0%
Annual volatility/standard deviation/risk : 61.0%
Annual variance : 37.0%
```

Gambar 11. Hasil perhitungan return, volatility dan variance tahunan

Dari gambar 11, perhitungan nilai expected return tahunan adalah 0.23758957 (24%), dengan tingkat resiko 61% dan varian 37%. Pertimbangan persentasi ini diperoleh jika menggunakan asumsi bobot awal yang sama besar di 9 data saham.

7. Optimasi Portofolio dan Efficient Frontier

Nilai persentasi awal hasil perhitungan sebelumnya, dijadikan sebagai acuan untuk merancang nilai persentasi return dan volatility yang lebih baik lagi. Optimalisasi portofolio dapat lebih menjadi maksimum dengan menghitung nilai efficient frontier dan nilai maksimal dari sharpe ratio, sehingga diperoleh nilai bobot baru untuk tiap data saham dengan expected return lebih menguntungkan dan volatility (risiko) yang lebih minim.

```
ef = EfficientFrontier(mu, S)
weights = ef.max_sharpe() #Maximize the Sharpe ratio, and get the raw weights
cleaned_weights = ef.clean_weights()
print(cleaned_weights) #Note the weights may have some rounding error,
#meaning they may not add up exactly to 1 but should be close
ef.portfolio_performance(verbose=True)


OrderedDict([('BCH-USD', 0.0), ('BNB-USD', 0.49204), ('BTC-USD', 0.50796),
('EOS-USD', 0.0), ('ETH-USD', 0.0), ('LTC-USD', 0.0),
('USD-USD', 0.0), ('XLM-USD', 0.0), ('XRP-USD', 0.0)])
Expected annual return: 43.4%
Annual volatility: 61.8%
Sharpe Ratio: 0.67

(0.43358907244749567, 0.6180409558563685, 0.6691936327656786)
```

Gambar 12. Optimasi portofolio

Hasil perhitungan nilai bobot baru (Gambar 12) yaitu: BCH-USD=0.0, BNB-USD=0.49204, BTC-USD=0.50796, EOS-USD=0.0, ETH-USD=0.0, LTC-USD=0.0, USDT-USD=0.0, XLM-USD=0.0, XRP-USD=0.0. Dengan expected return=43.4%, volatility=61.8%, sharpe ratio=67%. Dengan optimasi ini nilai return naik dari 24% menjadi 43.4% dan tingkat resiko yang tidak berubah semula 61% menjadi 61.8%. Optimasi ini telah menaikkan return walaupun risiko yang tidak berubah. Hasil perhitungan ini berada di daerah sekitar kiri

atas dari peta Efficient Frontier (titik kuning mempunyai nilai yang optimal).



Gambar13. Peta Efficient Frontier 9 data Cryptocurrency

Dengan mengambil contoh kasus untuk dana yang dimiliki adalah \$15.000 (lima belas ribu dollar), maka program akan dapat mengalokasikan secara terpisah ke saham-saham tertentu dengan lebih menguntungkan.

```
from pypfopt.discrete_allocation import DiscreteAllocation, get_latest_prices
latest_prices = get_latest_prices(dataset)
weights = cleaned_weights
da = DiscreteAllocation(weights, latest_prices, total_portfolio_value=15000)
allocation, leftover = da.lp_portfolio()
print("Discrete allocation:", allocation)
print("Funds remaining: ${:.2f}".format(leftover))

Discrete allocation: {'BNB-USD': 140.0, 'BTC-USD': 1.0, 'XRP-USD': 4.0}
Funds remaining: $0.16
```

Gambar 14. Perhitungan alokasi discrete untuk nilai portofolio \$15.000

Hasil perhitungan alokasi discrete (Gambar 14) dengan nilai portofolio \$15.000 adalah investasi saham BNB-USD sebesar 140 lembar, BTC-USD sebesar 1 lembar dan XRP-USD sebesar 4 lembar, dengan sisa dana yang tidak terpakai sebesar \$0.16. Data harga terakhir untuk BNB-USD, BTC-USD dan XRP-USD masing-masing adalah \$23.069, \$11.768,87, dan \$0,30. Untuk melakukan pengecekan dapat dihitung (140 x \$23.069)+(1 x \$11.768,87)+(4 x \$0,30) + \$0,16 = \$14.999,89 adalah sama dengan modal dana yang dipergunakan untuk investasi portofolio.


Dataset

Hasil dari analisa portofolio diperoleh 2 data saham (BNB-USD dan BTC-USD) dengan kategori mampu memberikan benefit bagi para investor. Namun dalam penelitian ini akan dilihat prediksi untuk 3 data saham (BNB-USD, BTC-USD, dan XRP-USD), dijadikan sebagai dataset dalam proses prediksi.


Agar mesin dapat melakukan proses belajar dan pengujian, maka data harus dipisahkan untuk kedua proses tersebut dalam cara membagi data yang ada menjadi dua bagian, data training (70%-80%) dan data testing (20%-30%). Pemisahan data ditampilkan (Gambar 15) dalam bentuk grafik untuk 3 data saham BNB-USD, BTC-USD, dan XRP-USD.



Gambar15-a.Sebaran data training dan data testing BTC-USD



Gambar15-b.Sebaran data training dan data testing BNB-USD




Gambar15-c.Sebaran data training dan data testing XRP-USD

Kombinasi layer

Arsitektur DL melibatkan 4 hidden layer, membentuk 5 tipe kombinasi layer menggunakan 2 model yaitu LSTM dan GRU (Gambar 12).

Type	Layer-1	Layer-2	Layer-3	Layer-4
0	LSTM	LSTM	LSTM	LSTM
1	GRU	GRU	GRU	GRU
2	LSTM	LSTM	GRU	GRU
3	GRU	GRU	LSTM	LSTM
4	GRU	LSTM	GRU	LSTM


Gambar 16.Hidden layer dengan 5 tipe




Gambar 17.Kombinasi hidden layer tipe 4

Karakteristik Epoch-RMSE


Salah satu kesulitan lain untuk menghasilkan prediksi yang akurat, adalah penetapan nilai epoch dalam proses DL. Tindakan yang umum dilakukan adalah dengan cara coba salah (try-error), yang memakan waktu lama, dan hasil yang kurang baik. Untuk itu sebelum menggunakan parameter epoch dalam proses DL, akan lebih baik diketahui dahulu karakteristik epoch dan RMSE terhadap data yang digunakan[13]. Dalam penelitian ini dibuat program untuk menghasilkan grafik dan numerik yang menunjukkan karakteristik epoch dan RMSE dari setiap data dengan tipe hidden layer yang berbeda. Dengan diketahuinya grafik dan numerik karakteristik epoch dan RMSE (Gambar 18), dapat dengan mudah menentukan nilai epoch yang akan dipergunakan dalam proses DL.



Gambar18-a.Epoch-RMSE untuk BTC-USD.



Gambar18-b.Epoch-RMSE untuk BNB-USD.



Gambar18-c. Epoch-RMSE untuk XRP-USD

HASIL DAN PEMBAHASAN

Terlihat pada gambar 18-a, 18-b, dan 18-c dengan mengambil nilai epoch dengan RMSE minimum untuk tiap tipe kombinasi layer dapat dinyatakan secara numerik dalam tabel berikut ini: (Tabel 1).

Tabell-1-a. Epoch RMSE minimum untuk BTC-USD.

Tipe Layer	Epoch	RMSE
0	40	572.7373956
1	45	375.5336079
2	25	494.3111223
3	40	474.8351978
4	35	505.1723692

Tabell-1-b. Epoch RMSE minimum untuk BNB-USD.

Tipe Layer	Epoch	RMSE
0	35	1.0908165
1	40	0.8718438
2	25	1.0668859
3	15	1.1607289
4	45	0.9358524

Tabell-1-c. Epoch RMSE minimum untuk XRP-USD.


Tipe Layer	Epoch	RMSE
0	35	0.0119218
1	25	0.0109056
2	35	0.0109347
3	45	0.00962406
4	45	0.01082122

Dari tabel 1 terlihat bahwa untuk data:

- BTC-USD hasil prediksi terbaik yang diperoleh adalah tipe 1 dengansusunan layer GRU, GRU, GRU, GRU
- BNB-USD, tipe 1 dengan susunan layer GRU, GRU, GRU, GRU
- XRP-USD, tipe 3 dengan susunan layer GRU, GRU, LSTM, LSTM.

Hasil grafik dengan prediksi terbaik sesuai dengan tabel 1-a (berwarna merah) untuk BTC-USD

terlihat pada gambar di bawah ini: (Gambar19).




Gambar19-a. Rmse-epoch tipe 1 BTC-USD




Gambar19-b. Sebaran dataset testing, prediksi dan future prediksi tipe 1, BTC-USD

Hasil grafik dengan prediksi terbaik sesuai dengan tabel 1-b (berwarna merah) untuk BNB-USD terlihat pada gambar di bawah ini: (Gambar 20).




Grafik20-a. Rmse-epoch tipe 1 BNB-USD



Grafik 20-b. Sebaran dataset testing, prediksi dan future prediksi tipe 1, BNB-USD

Hasil grafik dengan prediksi terbaik sesuai dengan tabel 1-c (berwarna merah) untuk XRP-USD terlihat pada gambar di bawah ini: (gambar 21).



Grafik 21-a. Rmse-epoch tipe 3 XRP-USD



Grafik 21-b. Sebaran dataset testing, prediksi dan future prediksi tipe 3, XRP-USD

PENUTUP

- Proses optimalisasi portofolio ini, diversifikasi investasi dapat dilakukan untuk memperoleh hasil yang lebih menguntungkan. Tentunya diversifikasi portofolio ini juga bergantung dari besar dana yang akan kita letakan dalam portofolio ini.
- Total dari 9 saham cryptocurrency setelah melalui proses optimalisasi portofolio diperoleh 3 saham yang dapat memberikan keuntungan dengan risiko minimum, yaitu BTC-USD, BNB-USD, dan XRP-USD.
- Hasil prediksi terbaik untuk BTC-USD menggunakan nilai epoch 45 diperoleh nilai $RMSE=375.5336079$ dengan arsitektur layer GRU,GRU,GRU,GRU.
- Hasil prediksi terbaik untuk BNB-USD menggunakan nilai epoch 40 diperoleh nilai $RMSE=0.8718438$ dengan arsitektur layer GRU,GRU,GRU,GRU.
- Hasil prediksi terbaik untuk BTC-USD menggunakan nilai epoch 45 diperoleh nilai $RMSE=0.00962406$ dengan arsitektur layer GRU,GRU,LSTM, LSTM.
- Trend grafik prediksi BTC-USDaagak sedikit mengalami penurunan, tindakan yang bisa diambil menjual (SELL) untuk periode pendek atau bertahan (HOLD) melihat perkembangan selanjutnya.

- Trend grafik prediksi BNB-USD terjadi kenaikan yang tajam, maka tindakan yang harus diambil investor adalah bertahan (HOLD), karena kemungkinan akan terjadi kenaikan harga yang tinggi pada saham ini di kemudian hari.
- Trend grafik prediksi XR-USD terlihat penurunan agak dalam, maka tindakan yang harus diambil investor adalah jual (SELL).

Saran

- Masih perlu dilakukan penelitian dengan menggunakan kombinasi hidden layer lain atau menambah jumlah hidden layer sehingga variasi kombinasi dapat lebih banyak lagi untuk menghasilkan prediksi yang lebih baik.
- Masih diperlukan cara yang lebih baik untuk dapat menghasilkan fluktuasi prediksi jangka panjang lebih dari sekedar penelitian ini yang hanya mampu menunjukkan trend jangka panjang.

DAFTAR PUSTAKA

- [1] M. Hileman, Garrick; Rauchs, *Global Blockchain Benchmarking Study-2017*. 2017.
- [2] Anonim, "Matching Cryptocurrencies Results List," *Yahoo Finance*, 2020. [Online]. Available: <https://finance.yahoo.com/cryptocurrencies>.
- [3] Vania, "Pembeli Bitcoin: Siapa dibalik kenaikan pesat harga Cryptocurrency?," *bitocto.com*, 2020. [Online]. Available: <https://bitocto.com/id/pembeli-bitcoin-siapa-dibalik-kenaikan-pesat-harga-cryptocurrency/>.
- [4] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A comparison between ARIMA, LSTM, and GRU for time series forecasting," *ACM Int. Conf. Proceeding Ser.*, pp. 49–55, 2019.
- [5] A. Dutta, S. Kumar, and M. Basu, "A Gated Recurrent Unit Approach to Bitcoin Price Prediction," *J. Risk Financ. Manag.*, vol. 13, no. 2, p. 23,

- 2020.
- [6] K. T. Miura R., Pichl L., “Artificial Neural Networks for Realized Volatility Prediction in Cryptocurrency Time Series,” *Adv. Neural Networks*, vol. 1, no. 1, pp. 213–222, 2019.
 - [7] M. Rizwan, S. Narejo, and M. Javed, “Bitcoin price prediction using Deep Learning Algorithm,” *MACS 2019 - 13th Int. Conf. Math. Actuar. Sci. Comput. Sci. Stat. Proc.*, pp. 1–7, 2019.
 - [8] U. Homm and C. Pigorsch, “Beyond the Sharpe ratio: An application of the Aumann-Serrano index to performance measurement,” *J. Bank. Financ.*, vol. 36, no. 8, pp. 2274–2284, 2012.
 - [9] T. T. Nguyen, L. Gordon-Brown, A. Khosravi, D. Creighton, and S. Nahavandi, “Fuzzy portfolio allocation models through a new risk measure and fuzzy sharpe ratio,” *IEEE Trans. Fuzzy Syst.*, vol. 23, no. 3, pp. 656–676, 2015.
 - [10] W. Hastomo and A. Satyo, “Long Short Term Memory Machine Learning Untuk Memprediksi Akurasi Nilai Tukar IDR Terhadap USD,” vol. 3, 2019.
 - [11] Adhitio Satyo Bayangkari Karno, “Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory),” vol. 1, no. 1, pp. 1–8, 2020.
 - [12] M. Phi, “Illustrated Guide to LSTM’s and GRU’s: A step by step explanation,” *Medium Toward Data Science*, 2018. [Online]. Available: <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>.
 - [13] A. Satyo and B. Karno, “Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python,” *Ultim. InfoSys*, vol. XI, no. 1, pp. 1–7, 2020.