

Pengaruh Pemilihan Banyak Data dan *Time Frame* dalam *Finance Forecasting* dengan *Linear Regression*

Wahyu Cahyo Utomo¹, Resty Wulanningrum², Intan Nur Farida³

^{1,2,3}Prodi Teknik Informatika, Fakultas Teknik, Universitas Nusantara PGRI Kediri
Jl. Ahmad Dahlan No.76, Mojoroto, Kec. Mojoroto, Kota Kediri, Jawa Timur 64112
E-mail: ¹wahyu.utomo@unpkdr.ac.id, ²resty0601@gmail.com, ³in.nfarida@gmail.com

ABSTRAK

Finance forecasting merupakan kegiatan yang berhubungan dengan aktifitas *trading* yang memiliki resiko yang besar. Pendekatan *forecasting* merupakan salah satu langkah yang dapat dilakukan untuk meminimalkan resiko melalui bidang ilmu komputer atau Informatika. Dalam hal ini tantangannya adalah membuat sebuah model yang memiliki akurasi yang bagus untuk meminimalkan resiko. Pemilihan *time frame* dan penggunaan banyak data akan mempengaruhi akurasi karena setiap *time frame* memiliki *range* pergerakan yang berbeda. Berdasarkan hal tersebut, penelitian ini mencoba menemukan serta melakukan analisa pengaruh *time frame* dan banyak data sehingga mendapat model evaluasi yang optimal dengan metode *linear regression*. Beberapa variasi perubahan *time frame* dan banyak data akan digunakan untuk melihat hasil *forecasting* terbaik. Dari hasil penelitian diperoleh *time frame* semakin turun maka hasil evaluasi MSE lebih baik. Sedangkan untuk penurunan jumlah data juga berpengaruh terhadap nilai evaluasi yang semakin kecil. maka dapat disimpulkan bahwa *forecasting* dalam bidang *finance* memiliki keunikan karena semakin banyak data tidak menjamin bahwa model yang dihasilkan semakin bagus.

Kata Kunci: *Finance Forecasting, Time Frame, Linear Model, Forex*

ABSTRACT

Financial forecasting is an activity related to trading activities that have a large risk. The forecasting approach is one of the steps that can be taken to minimize risk through the field of computer science or informatics. In this case the challenge is to create a model that has good accuracy to minimize risk. Choosing a time frame and using a lot of data will affect accuracy because each time frame has a different movement range. Based on this, this study tries to find and analyze the influence of time frames and lots of data so that an optimal evaluation model is obtained using the linear regression method. Several variations of time frame changes and lots of data will be used to see the best forecasting results. From the research results, the lower the time frame, the better the MSE evaluation results. Meanwhile, the decrease in the amount of data also affects the evaluation value which is getting smaller. it can be concluded that forecasting in the field of finance is unique because more data does not guarantee that the resulting model will be better.

Keywords : *Finance Forecasting, time frame, Linear Model, Forex*

1. PENDAHULUAN

Finance forecasting merupakan salah satu pendekatan dalam memprediksi atau memproyeksi pergerakan harga kedepan berdasarkan data *history* atau masa lalu (Cao et al., 2019). didalam dunia *finance* terdapat sesuatu yang diperdagangkan yang disebut dengan *asset*. *Asset* ini sangat luas, diantaranya adalah saham, *index volatility*, *mata uang*, *crypto currenccy* dan lainnya. Semua *asset* dalam perkembangannya sangat mudah untuk ditransaksikan secara *real time* dimana pun dan kapan pun. Kegiatan ini disebut dengan *trading* atau jual beli. Saat ini media atau *platform* yang cukup populer digunakan untuk transaksi adalah meta trader versi 4 dan meta trader versi 5. *Platform* ini disediakan oleh pihak ketiga yang disebut dengan *broker*. *Platform* meta trader bersifat gratis

digunakan dan data yang ada didalamnya dapat diekstraksi untuk melakukan analisa.

Data didalam *platform trading* dibagi dalam beberapa bentuk *time frame*. Satuan ini merupakan interpretasi bentuk pergerakan harga dalam *range* waktu tertentu. Dalam *platform* meta trader data dibagi menjadi *time frame default* : MN, W1, D1, H4, H1, M30, M15, M5 dan M1. Pada setiap *time frame* pergerakan harga dibentuk kedalam *candle stick* yang berisi harga *open*, *high*, *low* dan *close* (Wang et al., 2021) . Selain dalam *range time frame*, faktor lain yang perlu diperhatikan adalah ketersediaan data. Setiap *time frame* yang ada memiliki ketersediaan data yang berbeda. Selain itu jika *asset* yang diperdagangkan cenderung baru maka ketersediaan data semakin sedikit. Berikut adalah beberapa penelitian yang mencoba untuk melakukan prediksi dengan menggunakan metode

yang ada. Dalam penelitian (Handayani et al., n.d.), metode MA dan MACD yang termasuk kedalam indikator bawaan meta trader diujikan terhadap *time frame* yang berbeda. Pada penelitian (Rundo et al., 2019), juga melakukan analisa tetapi menggunakan *time frame* 1 menit. Kedua penelitian ini memiliki perbedaan dalam hal metode dan *time frame* yang digunakan.

Beberapa penelitian telah dilakukan berkaitan dengan *finace forecasting* terutama dengan metode statistikal dan *machine learning* bahkan *deep learning*. Pada penelitian (Chantarakasemchit et al., 2020) metode yang digunakan adalah MLP dan *Linear Regression*. Hasil yang diperoleh adalah penggunaan *Linear regression* lebih bagus jika dibandingkan dengan MLP. Metode ini juga digunakan didalam penelitian (Oetama et al., 2022) pada tahun 2022. Dalam penelitian Oetama dkk. Metode *linear regression* berjalan dengan baik dan dapat digunakan untuk melakukan seleksi fitur. Hal ini memiliki artian bahwa metode *linear regression* merupakan representasi model *Machine learning* dan dapat dikembangkan serta diujikan kedalam metode lainnya.

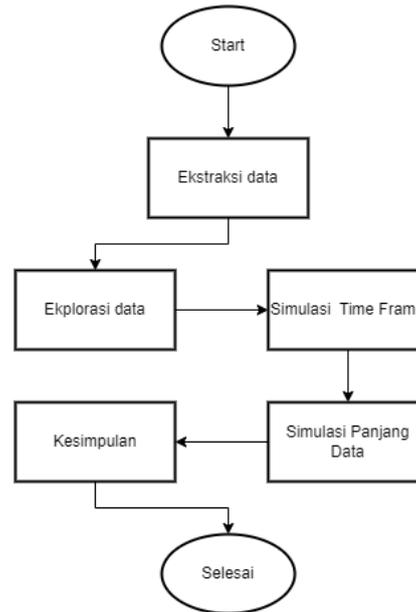
Selain dalam faktor metode yang digunakan, faktor pemilihan, penggunaan dan *time frame* data juga mempengaruhi akurasi dari suatu model. Dalam penelitian (Handayani et al., n.d.), *time frame* yang digunakan adalah *Daily* sampai dengan satu jam. Berbeda dengan penelitian (Rundo et al., 2019) yang menggunakan *time frame* satu menit. Namun ada juga yang menggunakan *time frame daily* untuk melakukan *forecasting* (Chantarakasemchit et al., 2020)(Oetama et al., 2022). Berdasarkan penelitian yang sudah ada, dapat disimpulkan tidak ada aturan baku yang digunakan untuk menentukan *time frame*. Oleh karena itu penelitian ini menganalisis pengaruh penggunaan *time frame* dan banyak data yang digunakan didalam model.

Dari uraian singkat diatas dapat disimpulkan terdapat sebuah gap penelitian berupa penggunaan *time frame* yang tepat dan banyak data yang digunakan. Kesalahan pemilihan *time frame* dan banyak penggunaan data akan mempengaruhi tingkat keberhasilan atau akurasi model yang dihasilkan. Oleh karena itu dalam penelitian ini akan berfokus untuk mengetahui efek pemilihan besar *time frame* dan banyak data yang digunakan.

2. METODE PENELITIAN

2.1 Alur Penelitian

Pada tahapan ini dirancang langkah-langkah dalam melakukan penelitian secara tersruktur. Tahapan pengumpulan data sampai dengan kesimpulan yang didapatkan dalam penelitian akan dijabarkan pada gambar 1.



Gambar 1. Alur Penelitian

Pada awal tahapan penelitian ini melaukan proses ekstraksi pada aplikasi meta trader yang sudah disediakan oleh *broker Deriv*. Data ini dapat diekstraksi melalui *API* ataupun dalam bentuk *CSV file*. Proses selanjutnya dilakukan eksplorasi data. Baik secara *visual* maupun statistik. Proses selanjutnya adalah proses inti dalam penelitian yaitu menemukan pengaruh dari penggunaan *time frame* dan panjang data yang digunakan dalam model *machine learning*. Kedua proses ini memerlukan beberapa langkah yang cukup detail. Selanjutnya adalah menyimpulkan dari beberapa data hasil yang sudah terkumpul.

2.2 Simulasi *time frame*

Time frame merupakan satuan waktu didalam bidang *trading*. Meta trader yang merupakan *platform* untuk jual beli menyediakan *time frame* MN sampai dengan M1. MN adalah *time frame* bulanan sedangkan M1 adalah satu menit. Dalam penelitian ini hanya mencoba D1 sampai dengan M5. Hal ini didasari dari penelitian sebelumnya (Chantarakasemchit et al., 2020)(Oetama et al., 2022) yang menggunakan D1. Berikut adalah detail pengujian yang akan dilakukan didalam penelitian.

Tabel 1. Simulasi *Time frame*

No	Nama Model	Time Frame
1	MD1-5000	D1 (Satu Hari)
2	MH4-5000	H4 (4 Jam)
3	MH1-5000	H1 (1 Jam)
4	MM30-5000	M30 (30 Menit)
5	MM15-5000	M15 (15 Menit)
6	MM5-5000	M5 (5 Menit)

Dalam tabel 1 terdapat 6 model yang akan diujikan. Setiap model dibedakan nilai *time frame* yang digunakan seperti M30 berarti *range* waktu

yang digunakan oleh mode adalah *candle* setiap 30 menit. Dari segi jumlah data disini masih sama semua yaitu 5000 data atau *records*.

2.3 Simulasi Banyak Data

Setelah melakukan pengujian *time frame* dan mengetahui pengaruhnya. Penelitian dilanjutkan dengan proses ujicoba untuk mendapatkan analisa tentang perubahan banyak data yang digunakan. Dalam tahapan ini data yang digunakan akan simultan dikurangi sebanyak 1000 data. Yang pertama dilakukan adalah melakukan pengujian pada *time frame* terbesar yaitu D1.

Tabel 2. Simulasi Banyak data D1

No	Nama Model	Time Frame
1	MD1-5000	D1 (Satu Hari)
2	MD1-4000	D1 (Satu Hari)
3	MD1-3000	D1 (Satu Hari)
4	MD1-2000	D1 (Satu Hari)
5	MD1-1000	D1 (Satu Hari)

Setelah melakukan ujicoba terhadap *time frame* terbesar yaitu D1. Eksperimen dilanjutkan pada tahapan kedua yaitu pada *time frame* M5 atau *candle* setiap 5 menit.

Tabel 3. Simulasi Banyak data M5

No	Nama Model	Time Frame
1	MM5-5000	M5 (5 Menit)
2	MM5-4000	M5 (5 Menit)
3	MM5-3000	M5 (5 Menit)
4	MM5-2000	M5 (5 Menit)
5	MM5-1000	M5 (5 Menit)

2.4 Linear Regression

Linear regression merupakan salah satu metode keluarga *supervised learning*. Metode ini banyak digunakan untuk menyelesaikan permasalahan prediksi regressi. Salah satu permasalahan yang dapat diatasi adalah melakukan prediksi pergerakan harga finance forecasting (Chantarakasemchit et al., 2020)(Oetama et al., 2022)(Mabrouk et al., 2022)(Soni et al., 2022). Berikut adalah definisi formula Linear Regression (Chantarakasemchit et al., 2020) :

$$y = \theta_1 + \theta_2 x$$

Dimana θ_1 adalah nilai intercept dan θ_2 merupakan nilai koefisien dari input data training. Sedangkan Y merupakan variabel output regresasi.

2.5 Mean Square Error

Mean Square Error biasa disebut *metric* MSE. *Metric* evaluasi ini merupakan metode untuk menghitung jarak antara nilai prediksi dengan nilai sesungguhnya. Semakin kecil nilai evaluasi yang dihasilkan, maka model yang dibangun semakin bagus. Metode evaluasi ini banyak digunakan untuk

menilai model-model yang dibangun atau bertipe metode regressi. Begitu juga metode ini banyak digunakan didalam penelitian yang bertemakan finance forecasting (Kurani et al., 2023)(Du et al., 2019)(Qin et al., 2021). Berikut adalah formula yang digunakan dalam metric MSE:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

Dimana N adalah banyak data sample dalam evaluasi. \hat{y}_i adalah hasil nilai prediksi model, sedangkan y_i adalah nilai aktual atau nilai asli dari data sample.

3. HASIL DAN PEMBAHASAN

Dalam bagian ini penelitian akan dibahas secara detail setiap *step* seperti pada gambar 1. Berikut adalah hasil temuan dan implementasi model *linear regression* sebagai model latihan.

1. Ekstraksi data

Sebelum melakukan pelatihan kedalam model, peneliti melakukan ekstraksi data dalam meta trader 5 dengan menggunakan *API* dan *library* dalam bahasa pemrograman python. Berikut adalah code ekstraksi data yang digunakan.

```

1. import pandas as pd
2. import MetaTrader5 as mt5
3. mt5.initialize('C:\\Program Files\\Deriv\\terminal64.exe')
4. rates = mt5.copy_rates_from_pos("Volatility 75 (1s) Index",
mt5.TIMEFRAME_D1, rdx, 5000)
5. xData = pd.DataFrame(rates)
6. xData['time']=pd.to_datetime(xData['time'], unit='s')
7. xData.tail()
    
```

Gambar 2. Code ekstraksi data

Kode yang ada dalam gambar 2 merupakan potongan *code* untuk ekstraksi data menggunakan bahasa pemrograman python. *Line* empat merupakan code *API* yang terhubung dengan meta trader 5. Asset trading yang diekstraksi pada code tersebut adalah "Volatility 75 (1s) Index". Sedangkan untuk *time frame* didefinisikan dengan code "mt5.TIMEFRAME_D1". Sesuai dengan rancangan pada subab sebelumnya, code *time frame* akan dirubah secara simultan. Begitu pula dengan banyak data yang digunakan. Pada gambar 2 line 4 data yang digunakan sebanyak 5000 *records*.

2. Eksplorasi data

Data yang didapatkan pada tahapan sebelumnya akan digunakan proses eksplorasi secara statistik maupun *visual*. Berikut adalah tampilan data yang berhasil diambil dari aplikasi meta trader 5.

	open	high	low	close
979	6550.43	6890.15	6435.74	6776.03
980	6777.13	6777.73	6402.45	6609.81
981	6607.90	6957.97	6464.76	6614.05
982	6613.07	6660.65	5971.17	6001.20
983	6002.59	6010.58	5671.85	5677.38

Gambar 3. Data Ekstraksi

Data ekstraksi (gambar 3) berisikan beberapa variabel *default API*. Data tersebut terdiri dari *open* sebagai harga pembuka disetiap *time frame*nya. *High* sebagai harga tertinggi dalam satu satuan *candle time frame*. *Low* sebagai harga terendah yang pernah dicapai oleh satu *candle time frame*. Dan *close* sebagai harga penutupan pada setiap satuan *time frame*. Jika dalam satuan *time frame* harian maka setiap harinya akan diinterpretasikan kedalam satu buah *candle stick*. Selanjutnya adalah melihat atau analisa dengan menggunakan pendekatan statistik.

	open	high	low	close
count	984.000000	984.000000	984.000000	984.000000
mean	28211.792673	29002.311240	27259.616494	28016.382470
std	41858.100741	42973.931039	40434.269719	41512.064236
min	4184.270000	4327.560000	4025.920000	4184.860000
25%	9279.135000	9548.220000	8982.175000	9273.465000
50%	12542.270000	12915.585000	12158.615000	12527.515000
75%	17912.267500	18414.922500	17355.635000	17858.485000
max	207647.870000	214194.480000	202803.760000	207680.350000

Gambar 4. Dekripsi statistik data D1

Pengamatan menggunakan pendekatan statistik bertujuan sebagai bahan awal analisa kedepan. seperti potensi hasil perolehan model dan lainnya. Pada gambar 4 terlihat ada nilai *max* dan *min* setiap variabelnya. Dari hasil pengamatan terlihat bahwa perubahan *time frame* akan mempengaruhi *range* pergerakan harga yang bisa terjadi. Berdasarkan hal tersebut maka peneliti mencoba untuk merubah *time frame* seperti yang ada dibawah ini.

	open	high	low	close
count	5000.000000	5000.000000	5000.000000	5000.000000
mean	9740.573708	9802.462996	9679.438264	9740.696000
std	3179.180050	3198.565594	3158.853799	3178.968639
min	4041.910000	4089.330000	4025.920000	4042.220000
25%	6863.780000	6899.280000	6806.675000	6863.460000
50%	10358.550000	10418.135000	10298.020000	10358.665000
75%	12629.422500	12711.665000	12546.335000	12628.030000
max	15396.140000	15457.450000	15298.890000	15398.030000

Gambar 5. Dekripsi statistik data H1

Bisa diamati pada gambar 4 dan gambar 5 terjadi perbedaan yang cukup signifikan. Nilai *min* dan *max* gambar 5 jauh lebih kecil jika dibandingkan dengan nilai pada gambar 4. Berdasarkan hal ini maka hipotesa awal adalah penurunan *time frame* pada model akan mempengaruhi nilai evaluasi dikarenakan jarak pergerakan harga semakin kecil. Selain dalam hal *range* pada tahapan eksplorasi akan membuktikan apakah metode yang digunakan sudah sesuai dengan datanya atau belum. Kesesuaian yang dimaksud adalah data bersifat *linear* atau *nonlinear*. Hal ini akan berpengaruh terhadap metode yang digunakan.

```
1 f_oneyway(xData['high'],xData['low'],xData['open'], xData['close'])
F_oneywayResult(statistic=0.3131778025956326, pvalue=0.8158767350180209)
```

Gambar 6. Nilai P-value

Gambar 6 merupakan nilai uji p-value. Dari data yang ada diujikan memperoleh 0.81. Hal ini membuktikan bahwa variabel *open*, *high*, *low* dan *close* memiliki keterkaitan yang erat atau berkorelasi. Dengan hasil tersebut maka dapat dikatakan bahwa data bersifat *linear* karena berada diatas 0.005. Sebagai gambaran bahwa nilai *open* naik maka nilai *close* naik. Hal ini dapat mendukung keputusan penggunaan *linear regression* yang semula berdasarkan literatur.

3. Simulasi Time Frame

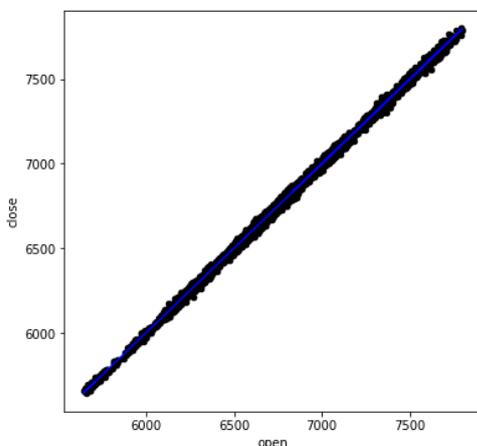
Setelah melakukan eksplorasi data untuk mengetahui tipe dan karakteristik data. Proses dilanjutkan dengan memasukan data kedalam model *Linear Regression*. Data yang digunakan dalam model sesuai dengan perencanaan simulasi pada tabel 1. Berikut adalah nilai evaluasi MSE masing-masing model.

Tabel 4. Nilai evaluasi *Time frame*

No	Nama Model	Time Frame	Evaluasi
1	MD1-5000	D1 (Satu Hari)	2560182.184
2	MH4-5000	H4 (4 Jam)	63556.671
3	MH1-5000	H1 (1 Jam)	6728.381
4	MM30-5000	M30 (30 Menit)	3930.758
5	MM15-5000	M15 (15 Menit)	1115.320
6	MM5-5000	M5 (5 Menit)	251.316

Dengan menggunakan banyak data yang sama yaitu 5000 dalam masing-masing *time frame*. Diperoleh bahwa Evaluasi terbesar berada pada *Time frame* D1 atau *Daily*. Sedangkan nilai terkecil diperoleh pada model *time frame* M5 atau setiap 5 menit. Hal ini sejalan sesuai dengan pengamatan eksplorasi data pada subab sebelumnya. Semakin kecil *time frame*

yang digunakan maka semakin kecil nilai evaluasi yang diperoleh. Berdasarkan hasil pengamatan ini maka penelitian sebelumnya yang memiliki perbedaan dalam hal *time frame* tidak bisa dibandingkan. Begitu juga ketika mata uang atau *asset* yang dibandingkan berbeda maka perbandingan tersebut tidak valid. Berikut adalah tampilan visual yang membuktikan bahwa setiap variabel dalam data saling berkorelasi atau *linear*.



Gambar 7. Linearity data

4. Simulasi Banyak Data

Diperoleh bahwa *time frame* terbaik adalah M5 atau pergerakan harga setiap 5 menit. Pada tahapan selanjutnya adalah melakukan eksperimen perubahan jumlah data yang digunakan didalam model. Hal ini juga memberikan langkah positif apabila *asset* yang diprediksi memiliki kecenderungan data yang masih sedikit. Berikut adalah hasil ujicoba perubahan jumlah data.

Tabel 5. Nilai Evaluasi perubahan M5

Nama Model	Time Frame	Evaluasi
MM5-5000	M5 (5 Menit)	251.316
MM5-4000	M5 (5 Menit)	241.116
MM5-3000	M5 (5 Menit)	228.383
MM5-2000	M5 (5 Menit)	224.330
MM5-1000	M5 (5 Menit)	207.562

Pada tabel 5 telah dijabarkan hasil evaluasi masing-masing model. Semua model menggunakan *time frame* M5 dengan perubahan jumlah data. Dalam tabel terlihat bahwa semakin turun jumlah data yang digunakan maka nilai evaluasi semakin kecil. Untuk memperkuat analisa maka dilakukan ujicoba kedua didalam *time frame Daily* sebagai *time frame* yang paling besar nilai evaluasinya.

Tabel 6. Nilai Evaluasi perubahan Daily

Nama Model	Time Frame	Evaluasi
MD1-5000	D1 (Satu Hari)	2560182.184
MD1-4000	D1 (Satu Hari)	665507.684
MD1-3000	D1 (Satu Hari)	224017.372
MD1-2000	D1 (Satu Hari)	176660.615
MD1-1000	D1 (Satu Hari)	154012.301

Dalam percobaan kedua dilakukan perubahan jumlah data yang sama seperti pada tabel 5. Hasil yang ada semakin menguatkan *statement* pada percobaan pertama. Nilai evaluasi semakin bagus ketika data yang digunakan semakin kecil.

4. KESIMPULAN

Berdasarkan hasil penelitian dan eksperimen yang telah dilakukan dapat disimpulkan bahwa semakin rendah penggunaan *time frame* menghasilkan akurasi model yang semakin bagus. Selain itu penggunaan data yang sedikit pada *Linear regression* memberikan *impact* yang cukup *significant* dalam penurunan nilai evaluasi MSE. Hal ini dapat menjadi bahan argumentasi untuk melakukan pemilihan *time frame* dan banyak data sebelum dimasukan kedalam model.

PUSTAKA

- Cao, J., Li, Z., & Li, J. (2019). Financial time series forecasting model based on CEEMDAN and LSTM. *Physica A: Statistical Mechanics and Its Applications*, 519, 127–139. <https://doi.org/10.1016/j.physa.2018.11.061>
- Chantarakasemchit, O., Nuchitprasitchai, S., & Nilsiam, Y. (2020). Forex Rates Prediction on EUR/USD with Simple Moving Average Technique and Financial Factors. *17th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, ECTI-CON 2020*, 771–774. <https://doi.org/10.1109/ECTI-CON49241.2020.9157907>
- Du, J., Liu, Q., Chen, K., & Wang, J. (2019). Forecasting stock prices in two ways based on LSTM neural network. *Proceedings of 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2019, Inec*, 1083–1086. <https://doi.org/10.1109/ITNEC.2019.8729026>
- Handayani, I., Yulius, H., Rahardja, U., Aini, Q., & Febriyanto, E. (n.d.). *Longer Time Frame Concept for Foreign Exchange Trading Indicator using Matrix Correlation Technique*.
- Kurani, A., Doshi, P., Vakharia, A., & Shah, M. (2023). A Comprehensive Comparative Study of Artificial Neural Network (ANN) and Support Vector Machines (SVM) on Stock Forecasting. *Annals of Data Science*, 10(1),

- 183–208. <https://doi.org/10.1007/s40745-021-00344-x>
- Mabrouk, N., Chihab, M., Hachkar, Z., & Chihab, Y. (2022). Intraday Trading Strategy based on Gated Recurrent Unit and Convolutional Neural Network: Forecasting Daily Price Direction. *International Journal of Advanced Computer Science and Applications*, 13(3), 585–592.
<https://doi.org/10.14569/IJACSA.2022.0130369>
- Oetama, R. S., Gaol, F. L., Soewito, B., & Warnars, H. L. H. S. (2022). Finding Features of Multiple Linear Regression On Currency Exchange Pairs. *Ultima InfoSys : Jurnal Ilmu Sistem Informasi*, 13(1), 46–53.
<https://doi.org/10.31937/si.v13i1.2683>
- Qin, J., Tao, Z., Huang, S., & Gupta, G. (2021). Stock Price Forecast Based on ARIMA Model and BP Neural Network Model. *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering, ICBAIE 2021, Icbaie*, 426–430.
<https://doi.org/10.1109/ICBAIE52039.2021.9389917>
- Rundo, F., Trenta, F., di Stallo, A. L., & Battiato, S. (2019). Grid trading system robot (GTSbot): A novel mathematical algorithm for trading FX market. *Applied Sciences (Switzerland)*, 9(9).
<https://doi.org/10.3390/app9091796>
- Soni, P., Tewari, Y., & Krishnan, D. (2022). Machine Learning Approaches in Stock Price Prediction: A Systematic Review. *Journal of Physics: Conference Series*, 2161(1).
<https://doi.org/10.1088/1742-6596/2161/1/012065>
- Wang, H., Huang, W., & Wang, S. (2021). *Forecasting open-high-low-close data contained in candlestick chart*.
<http://arxiv.org/abs/2104.00581>