

## Peramalan dan dekomposisi untuk mata uang kripto dengan model *facebook prophet*

(Forecasting and decomposition of cryptocurrency price using facebook prophet)

Dany Rahman\*, Dewi Rachmatin, Rini Marwati

Departemen Pendidikan Matematika, FPMIPA, Universitas Pendidikan Indonesia, Indonesia

\*korespondensi: danyrahman@upi.edu

Received: 06-05-2023, accepted: 14-02-2024

---

### Abstract.

Cryptocurrencies are becoming one of the hottest topics in Indonesia's society. One of those issues concerns investors who incur financial losses as a result of investing in crypto. The facebook Prophet model, one of the forecast models, can offer a solution to this problem. The Prophet model is built using four function. These variables are trend, seasonality, holidays, and additional regressions. The Prophet model benefits from a number of advantages, one of which is its ability to generate decomposition graphs. The decomposition may give analysts more insight into the data they are analyzing. The Prophet model is used to forecast and decompose the price of a cryptocurrency called Solana in this study. A multiplicative model with linear function as trend function, weekly seasonality, and daily seasonality as seasonality function is the best model for Solana price forecasting and decomposition. Additionally, hyperparameters in the model are tuned so the model won't suffer underfitting or overfitting indications. The fitted Prophet model is good at forecasting as a result of the evaluation process. As a result of the forecast and decomposition, the forecasted value and the decomposition graph of the Solana exchange rate for one hour later show that the price of Solana will remain constant.

**Keywords:** Cryptocurrency, time series, forecasting, decomposition, facebook prophet

**MSC2020:** 62M10

---

## 1. Pendahuluan

Belakangan ini, “*cryptocurrency*” atau lebih dikenal “mata uang kripto” adalah topik yang sering diperbincangkan. Pasalnya, banyak terjadi kerugian yang dialami investor mata uang kripto karena mulai berinvestasi mata uang kripto tanpa mengetahui lebih dalam mengenai dunia investasi. Sebagian besar orang merugi akibat menginvestasikan uangnya pada mata uang kripto. Bahkan belakangan ini harga tukar beberapa mata uang kripto populer seperti Bitcoin mengalami penurunan harga yang cukup tajam [1].

Selain Bitcoin, terdapat mata uang kripto lain juga yang dikenal juga sebagai Altcoins. Altcoins dibuat dengan menggunakan teknologi kriptografi yang sama dengan Bitcoin

namun menggunakan algoritma yang berbeda [2]. Layaknya yang terjadi pada Bitcoin, Solana, yaitu salah satu Altcoins ikut mengalami penurunan harga hingga 95% dibanding harganya dua tahun lalu. Penurunan ini mencapai lebih dari tiga juta rupiah per token. Namun, menurut anggota komunitas *cryptocurrency*, harga tukar Solana diperkirakan akan mencapai sekitar Rp800.000 pada Juli 2023 [3]. Data harga mata uang kripto adalah jenis data runtun waktu. Data runtun waktu adalah tipe data yang berbasis waktu dan diatur ke dalam interval waktu tertentu [4]. Oleh karena itu, investor dapat melakukan analisis runtun waktu pada data harga mata uang kripto.

Analisis runtun waktu adalah salah satu cara peramalan yang dapat dilakukan untuk meramalkan nilai di masa depan dari suatu data runtun waktu dengan mengombinasikan metode atau model berbeda untuk memperoleh informasi yang berarti [5]. Peramalan dalam analisis runtun waktu dilakukan berdasarkan nilai pada data historis yang telah diobservasi sebelumnya. Selain itu, tujuan lain dari analisis runtun waktu adalah untuk menguraikan data deret waktu menjadi komponen yang dapat dikaitkan dengan variasi temporal atau dikenal juga dengan istilah dekomposisi [6]. Dalam banyak contoh model data runtun waktu, data runtun waktu dapat didekomposisi menjadi submodel yang dapat mengidentifikasi setiap komponen data deret waktu secara individual. Hal ini dapat memberikan analisis pemahaman yang lebih baik mengenai pola musiman atau tren dari suatu data sehingga dapat meningkatkan akurasi dalam peramalan [7].

*Facebook Prophet* yang dikembangkan oleh Taylor dan Letham pada tahun 2017 merupakan model peramalan terbaru yang juga dapat melakukan analisis runtun waktu. Model *Facebook Prophet* atau juga disebut model *Prophet* adalah model yang dapat digunakan dengan mudah oleh pemula dan dapat digunakan dengan jumlah data yang besar dan bervariasi. Meskipun fokus utamanya adalah pada data terkait bisnis, model *Prophet* telah diuji dengan menggunakan berbagai tipe data [8].

Banyak penelitian telah menguji kelayakan model *Prophet* sebagai model peramalan. Model *Prophet* cocok untuk peramalan jangka pendek pada data penjualan suatu perusahaan *e-commerce* [9]. Dalam perbandingan model *Prophet* dengan model Holt-Winters, model *Prophet* dapat menghasilkan performa peramalan yang lebih baik daripada model Holt-Winters dalam peramalan beban listrik di Kuwait [10]. Model *Prophet* juga memiliki performa yang lebih baik daripada model ARIMA dalam peramalan konsumsi energi [11]. Model *Prophet* dapat bekerja dengan baik dalam peramalan jangka pendek berdasarkan data kasus COVID-19 di 21 negara di seluruh dunia [12]. Selain itu, model *Prophet* berpotensi sangat baik dalam mendeteksi efek musiman. Model ini dapat digunakan untuk menganalisis efek musiman dan peramalan jangka pendek pada data kasus Flu Singapura di Hubei [13]. Model *Prophet* memberikan peramalan yang sedikit lebih baik dari LSTM pada peramalan suhu udara [14]. Beberapa penelitian tersebut menunjukkan bahwa model *Facebook Prophet* dapat melakukan peramalan dan dekomposisi untuk berbagai macam data. Oleh karena itu, penelitian ini bertujuan untuk melakukan peramalan dan dekomposisi harga tukar salah satu

*cryptocurrency* terpopuler, Solana dengan menggunakan model *Facebook Prophet*.

## 2. Metodologi

### 2.1. Data Penelitian

Data yang digunakan dalam penelitian ini adalah data historis harga tukar Solana dengan interval 5 menit pada periode 27 Februari 2023 sampai 4 April 2023 (10656 observasi). Pada rentang waktu ini terdapat 1 hari libur, yaitu pada tanggal 22 Maret 2023. Data ini diperoleh dari situs *CoinMarketCap* yang beralamatkan pada <https://coinmarketcap.com/id/>. Data dibagi menjadi dua bagian, data latih dan data uji dengan rasio 90:10. Data latih adalah data untuk membangun model *Facebook Prophet*, sedangkan data uji adalah data untuk mengukur kemampuan model *Facebook Prophet* yang telah dibangun dengan data latih.

### 2.2. Model Analisis Data

*Facebook Prophet* merupakan model peramalan runtun waktu berdasarkan model aditif dan model multiplikatif yang dapat dilakukan proses dekomposisi. *Prophet* terdiri dari empat komponen utama, yaitu tren, musiman, liburan, dan regresor tambahan [8]. Model *Prophet* juga dapat mengakomodasi lebih dari satu jenis fungsi musiman dan regresor tambahan. Seluruh komponen tersebut dikombinasikan, sehingga diperoleh model pada persamaan (1) [8].

$$y(t) = g(t) \times (1 + m(s(t), h(t), r(t))) + a(s(t), h(t), r(t)) + \epsilon_t \quad (1)$$

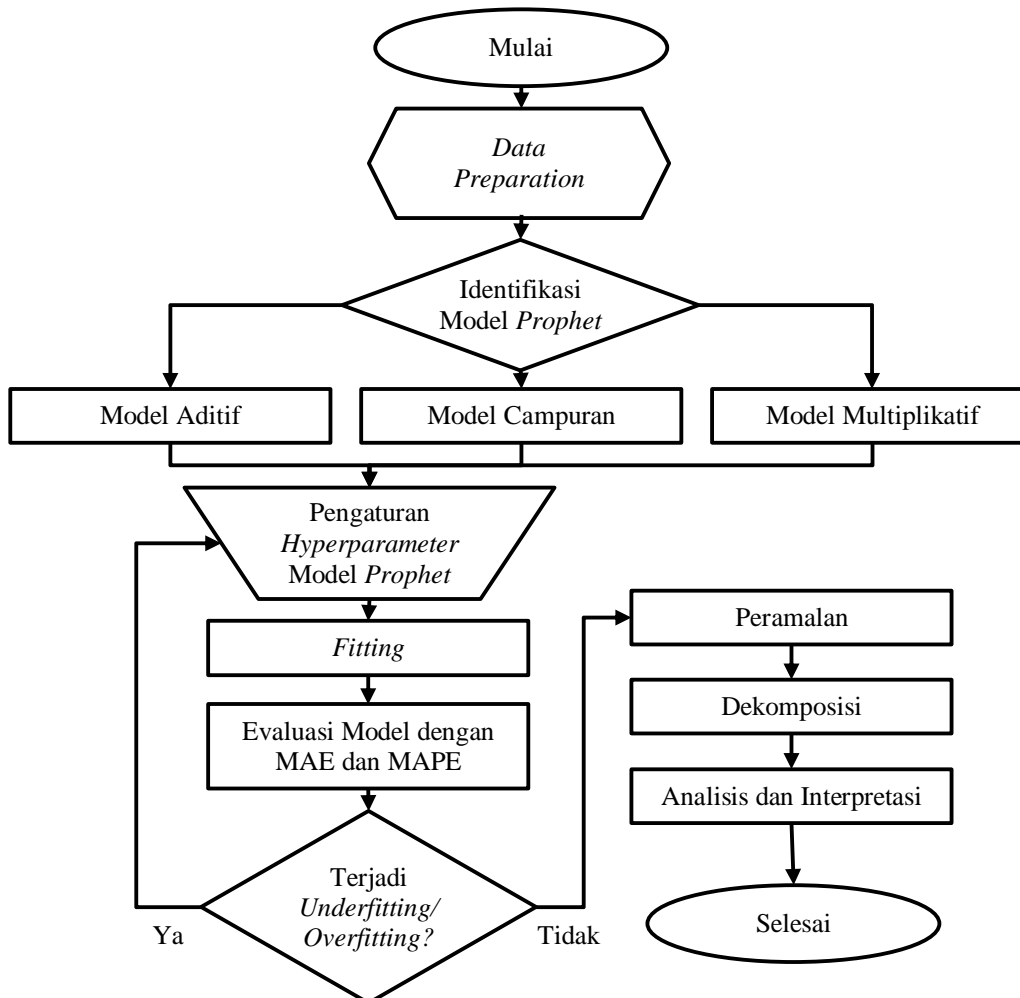
dengan  $y(t)$ : nilai pada waktu ke- $t$ ;  $g(t)$ : fungsi tren (fungsi linear bertahap atau fungsi logistik bertahap);  $s(t)$ : fungsi musiman (deret Fourier);  $h(t)$ : fungsi liburan;  $r(t)$ : fungsi regresor tambahan atau variabel eksogen;  $m(s(t), h(t), r(t))$ : bagian multiplikatif yang merupakan penjumlahan dari fungsi-fungsi dengan metode multiplikatif;  $a(s(t), h(t), r(t))$ : bagian aditif yang merupakan penjumlahan dari fungsi-fungsi dengan metode aditif;  $\epsilon_t$ : perubahan lain yang tidak diakomodasi oleh model (residu).

Dengan menggunakan Persamaan (1), model *Prophet* dapat memberikan beberapa kelebihan, di antaranya:

- Fleksibilitas.
- Tidak perlu melakukan interpolasi *missing value*.
- Proses estimasi yang sangat cepat. Hal ini memberikan analisis kesempatan untuk mengeksplorasi lebih banyak spesifikasi model.
- Model peramalan memiliki parameter yang mudah dipahami sehingga dapat diubah oleh analisis untuk memenuhi asumsi tambahan dari peramalan. Terlebih, analisis biasanya memiliki pengalaman dengan regresi dan dapat dengan mudah memperluas model untuk memasukkan komponen baru.

### 2.3. Prosedur Penelitian

Pemodelan menggunakan *library prophet* pada bahasa pemrograman Python 3.11.0 dengan JupyterLab 3.4.4 sebagai lingkungan untuk melakukan komputasi. Diagram alir pada Gambar 1 adalah rancangan penelitian yang akan dilakukan pada penelitian ini:



Gambar 1. Diagram alir penelitian

## 3. Hasil dan Pembahasan

### 3.1. Identifikasi Awal Model *Prophet*

Gambar 2 menginformasikan bahwa tren harga mata uang kripto Solana dapat dinyatakan dengan fungsi linear bertahap. Fungsi linear bertahap yang digunakan dapat dibangun dengan setidaknya 3 tahap fungsi linear atau 2 titik ubah. Kedua titik ubah tersebut dapat diletakkan di sekitar 10 Maret 2023 dan 20 Maret 2023. Oleh karena itu, fungsi tren yang diinisiasi pada model *Prophet* adalah fungsi linear bertahap.



Gambar 2 Grafik harga mata uang kripto Solana (data uji)

Berdasarkan Gambar 2, efek musiman tahunan tidak perlu dicantumkan pada model *Prophet* yang diinisiasi karena rentang data yang hanya 34 hari. Efek liburan pun tidak perlu dicantumkan karena tidak banyak hari libur yang terjadi di rentang hari pada data yang digunakan. Sehingga efek musiman yang digunakan pada model *Prophet* adalah efek musiman mingguan dan efek musiman harian.

Dari penjabaran tersebut, maka model *Prophet* yang diinisiasi dituliskan pada Persamaan (2)–(5), sebagai berikut:

$$y(t) = g(t) + s(t)_{mingguan} + s(t)_{harian}, \quad (2)$$

$$y(t) = g(t)(1 + s(t)_{mingguan} + s(t)_{harian}), \quad (3)$$

$$y(t) = g(t)(1 + s(t)_{mingguan}) + s(t)_{harian}, \quad (4)$$

$$y(t) = g(t)(1 + s(t)_{harian}) + s(t)_{mingguan}. \quad (5)$$

### 3.2. Evaluasi Awal Model *Prophet*

Setelah model diinisiasi, selanjutnya dilakukan proses *fitting*. Keempat model tersebut dievaluasi dengan menggunakan *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE). Hasil evaluasi dari model-model tersebut dapat dilihat pada Tabel 1.

Tabel 1 Evaluasi untuk model awal

Model	Ukuran Evaluasi	Latih	Uji
Model (2)	MAE	3588,814085	34167,254390
	MAPE	0,011338	0,110397
<b>Model (3)</b>	<b>MAE</b>	<b>3604,665463</b>	<b>34146,801285</b>
	<b>MAPE</b>	<b>0,011397</b>	<b>0,110327</b>
Model (4)	MAE	3589,539654	34167,796304
	MAPE	0,011343	0,110396
Model (5)	MAE	3612,106907	34162,077807
	MAPE	0,011418	0,110379

Berdasarkan nilai-nilai MAE dan MAPE pada Tabel 1, dapat disimpulkan bahwa dari keempat model yang diestimasi memberikan hasil yang tidak berbeda secara signifikan. Selain itu, hasil evaluasi menunjukkan bahwa selisih antara nilai evaluasi antara data latih dan data uji tidak berbeda secara signifikan di antara semua model sehingga dapat disimpulkan bahwa tidak ada model yang lebih mengalami *overfitting* dibanding model lainnya. Oleh karena itu, model (3) digunakan untuk pemodelan lebih lanjut karena memiliki nilai MAE dan MAPE terkecil pada data uji.

Model (3) adalah model multiplikatif yang dapat dinyatakan pada Persamaan (6)

$$y(t) = \left( (k + \mathbf{a}(t)^T \boldsymbol{\delta})t + (m + \mathbf{a}(t)^T \boldsymbol{\gamma}) \right) \left( 1 + \sum_{n=1}^N \left( a_n \cos \frac{2\pi nt}{7} + b_n \sin \frac{2\pi nt}{7} \right) \right) + \sum_{n=1}^N \left( a_n \cos \frac{2\pi nt}{1} + b_n \sin \frac{2\pi nt}{1} \right). \quad (6)$$

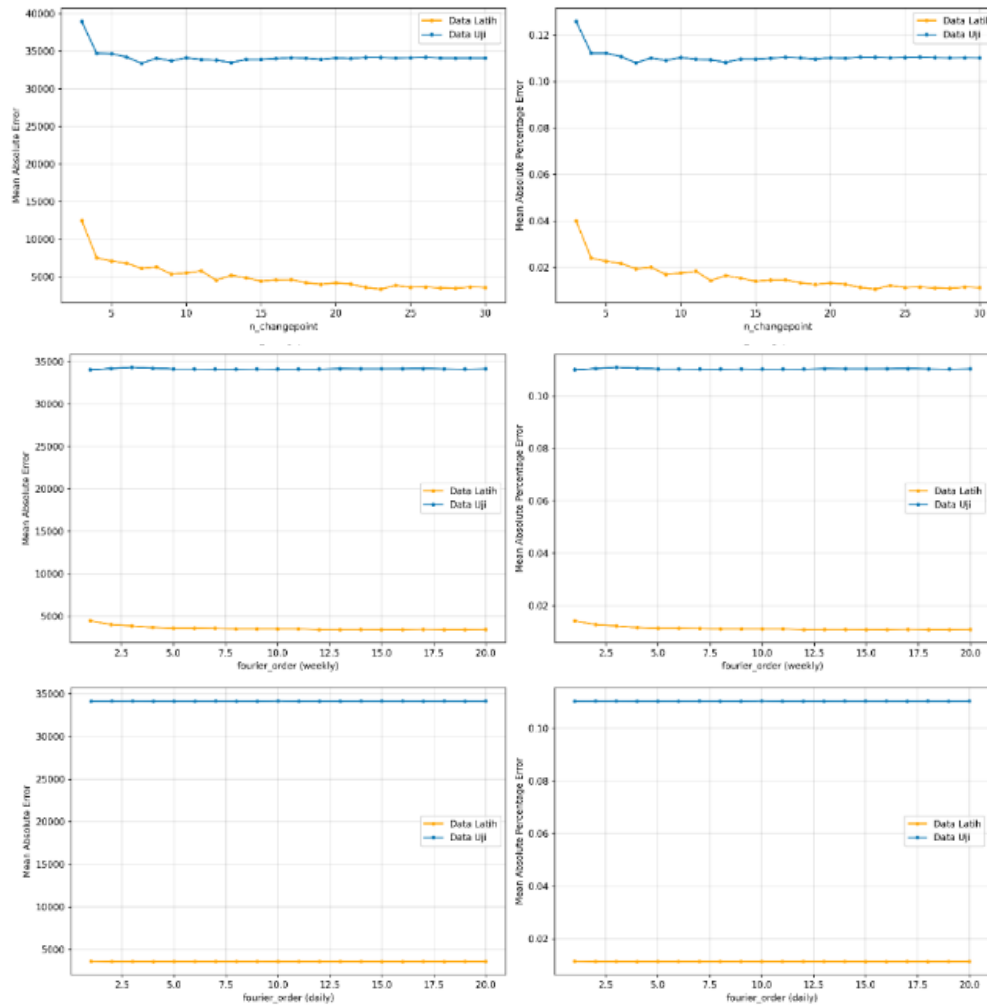
### 3.3. Pengaturan *Hyperparameter*

Untuk mengidentifikasi apakah model (6) merupakan model terbaik (*best fit*), maka perlu dilakukan pengaturan *hyperparameter*. Pengaturan *hyperparameter* ini juga dilakukan untuk meningkatkan akurasi model yang dibangun. *Hyperparameter* yang dapat diatur antara lain: *n\_changepoints*, *weekly\_seasonality*, *daily\_seasonality*, *seasonality\_prior\_scale*, dan *changepoint\_prior\_scale*.

Untuk pengaturan pertama, dilakukan pengaturan pada *n\_changepoints*, *weekly\_seasonality*, dan *daily\_seasonality* secara terpisah. Hasil evaluasi dari setiap iterasi disajikan pada Gambar 3.

Dapat dilihat pada Gambar 3, pada grafik *n\_changepoints* terdapat perubahan yang cukup signifikan pada nilai MAE dan MAPE di awal proses pengaturan. Nilai MAE dan MAPE terus menurun untuk nilai data latih tetapi, nilai pada data uji naik secara perlahan. Hal ini menunjukkan bahwa terjadi *overfitting* ketika banyak titik ubah pada fungsi tren ditingkatkan. Sebaliknya, pada grafik *fourier\_order* baik untuk mingguan ataupun harian tidak terlihat ada perbedaan yang signifikan.

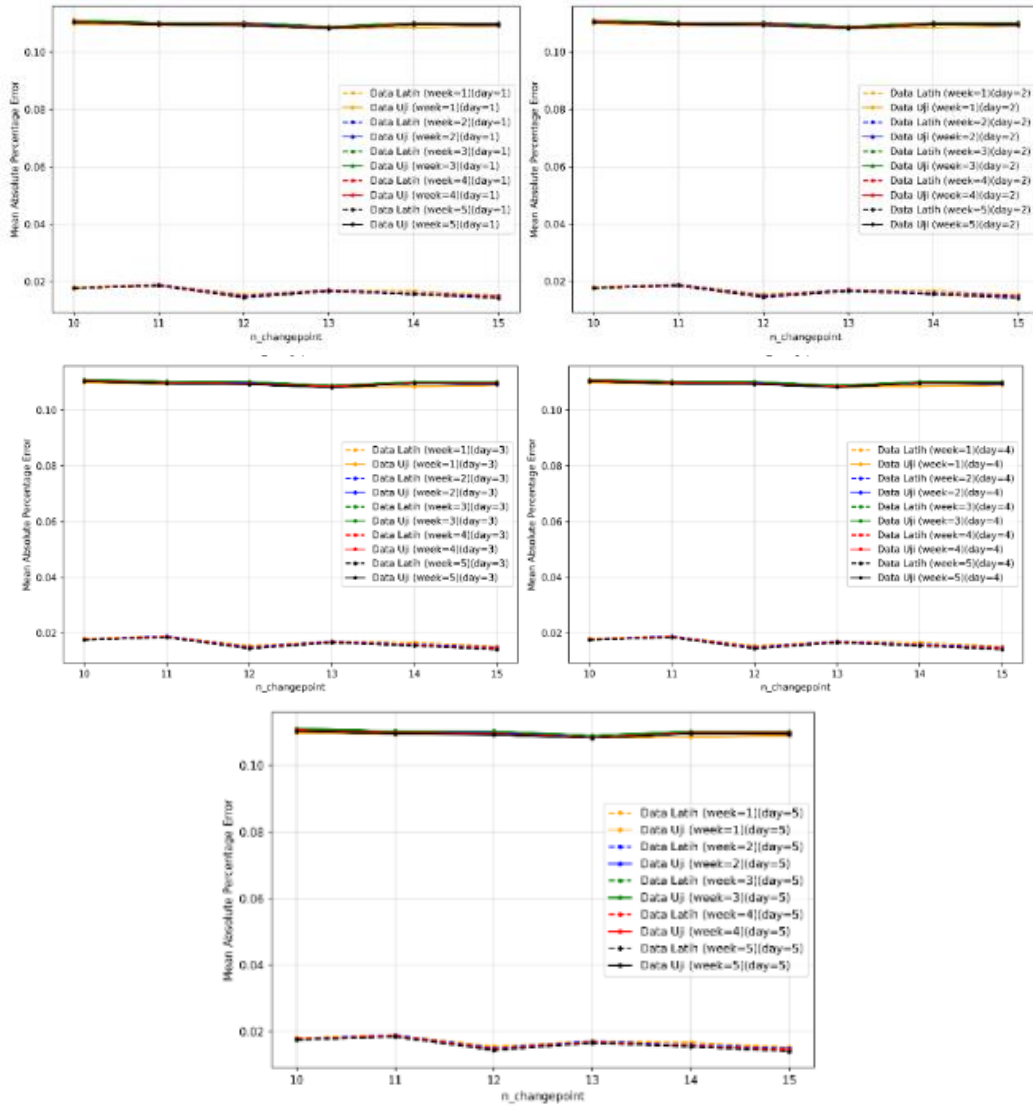
Tahap selanjutnya dilakukan pengaturan *hyperparameter* yang kedua dengan menggunakan *hyperparameter* yang sama namun dilakukan secara simultan dan rentang nilainya dibatasi berdasarkan hasil evaluasi pada pengaturan *hyperparameter* pertama. Hasil evaluasi dari setiap iterasi disajikan pada Gambar 4.



Gambar 3. Evaluasi model untuk pengaturan *hyperparameter* pertama

Berdasarkan hasil evaluasi pada Gambar 4, tidak terdapat perbedaan yang signifikan untuk perubahan nilai pada *weekly\_seasonality* ataupun *daily\_seasonality*. Berdasarkan hasil evaluasi tersebut juga menunjukkan bahwa titik ubah lebih dari 13 menurunkan MAE dan MAPE pada data latih, namun tidak menurunkan nilai MAE dan MAPE pada data uji. Hal ini menunjukkan bahwa model yang dibangun mulai mengalami *overfitting* mulai dari titik ubah sebanyak 14 buah. Selain itu, ketika titik ubah menjadi 13 buah, model mengalami peningkatan sedikit MAE dan MAPE pada data latih, namun nilai MAE dan MAPE pada data uji menurun. Hal ini menunjukkan bahwa model dapat melakukan peramalan lebih baik daripada model dengan banyak titik ubah yang lain.

Berdasarkan penjabaran tersebut, diambil MAE dan MAPE sebagai evaluasi untuk semua iterasi dengan  $n\_changepoint=13$ . Sebagian dari daftar nilai MAE dan MAPE disajikan pada Tabel 2.




Gambar 4 Hasil evaluasi pengaturan *hyperparameter* kedua

Tabel 2 Evaluasi *hyperparameter* dengan  $n\_changepoint=13$

$N_{\text{harian}}$	$N_{\text{mingguan}}$	MAE		MAPE	
		Latih	Uji	Latih	Uji
5	4	5284,144	33565,17	0,016791	0,108448
1	5	5237,866	33493,16	0,016648	0,108214
<b>2</b>	<b>5</b>	<b>5203,378</b>	<b>33468,44</b>	<b>0,01654</b>	<b>0,108128</b>
3	5	5202,503	33481,1	0,016538	0,108169
4	5	5202,822	33512,8	0,016539	0,10827

Berdasarkan Tabel 2, dipilih model dengan nilai MAE dan MAPE pada data uji yang terkecil, yaitu  $N_{\text{harian}} = 2$  dan  $N_{\text{mingguan}} = 5$ . Sehingga, nilai *hyperparameter* untuk  $n\_changepoints$ ,  $weekly\_seasonality$ , dan  $daily\_seasonality$  secara berturut-turut adalah 13, 5, dan 2. Selanjutnya akan dilakukan pengaturan *hyperparameter* yang ketiga dengan menggunakan  $seasonality\_prior\_scale$  dan  $changepoint\_prior\_scale$ . Hasil evaluasi dari pengaturan *hyperparameter* yang ketiga disajikan pada Gambar 5.





Gambar 5. Evaluasi *hyperparameter* ketiga

Berdasarkan Gambar 5, perubahan nilai pada *seasonality\_prior\_scale* dan *changepoint\_prior\_scale* tidak menunjukkan banyak perubahan pada nilai MAE dan MAPE baik pada data latih maupun data uji dan tidak menunjukkan ciri-ciri *overfitting*. Oleh karena itu, *hyperparameter* dipilih dari Tabel 3 berdasarkan nilai MAE dan MAPE paling kecil pada data uji, yaitu *seasonality\_prior\_scale*=0,01 dan *changepoint\_prior\_scale*=0,1.

Tabel 3 Evaluasi *hyperparameter* ketiga

<i>changepoint_prior_scale</i>	<i>seasonality_prior_scale</i>	MAE		MAPE	
		Latih	Uji	Latih	Uji
0.09	1	5206.234	33446.13	0.016549	0.108052
0.09	10	5204.647	33471.71	0.016545	0.108136
<b>0.1</b>	<b>0.01</b>	<b>5205.38</b>	<b>33423.96</b>	<b>0.016546</b>	<b>0.107979</b>
0.1	0.1	5206.753	33471.54	0.016552	0.108137
0.1	1	5203.614	33441.04	0.016541	0.108038

### 3.4. Evaluasi Akhir Model *Prophet*

Berdasarkan proses pengaturan *hyperparameter*, *hyperparameter* terbaik untuk model *Prophet* yang dibangun adalah *n\_changepoints*=13, *weekly\_seasonality*=5, dan *daily\_seasonality*=2 *seasonality\_prior\_scale*=0,01 dan *changepoint\_prior\_scale*=0,1, sehingga model yang diperoleh disajikan pada persamaan (7),


$$\begin{aligned}
 y(t) = & \left( (-0,45600892 + \mathbf{a}(t)^T \boldsymbol{\delta})(365521)t + (0,96667952 + \mathbf{a}(t)^T \boldsymbol{\gamma}) \right) \left( 1 + \right. \\
 & \left( 0,00389027 \cos \frac{2\pi t}{7} - 0,00503811 \sin \frac{2\pi t}{7} \right) + \left( -0,00711963 \cos \frac{4\pi t}{7} + \right. \\
 & \left. 0,0011199 \sin \frac{4\pi t}{7} \right) + \left( -0,0011199 \cos \frac{6\pi t}{7} + 0,00637988 \sin \frac{6\pi t}{7} \right) + \\
 & \left( -0,00292675 \cos \frac{8\pi t}{7} - 0,00641701 \sin \frac{8\pi t}{7} \right) + \left( -0,00418566 \cos \frac{10\pi t}{7} + \right. \\
 & \left. 0,00060283 \sin \frac{10\pi t}{7} \right) + (-0,00100017 \cos 2\pi t + 0,00019012 \sin 2\pi t) + \\
 & \left. (-0,0026017 \cos 4\pi t + 0,00169175 \sin 4\pi t) \right) + \epsilon_t \tag{7}
 \end{aligned}$$

dengan nilai  $\boldsymbol{\delta}$  dan  $\boldsymbol{\gamma}$  serta titik ubah yang berseuaian dengannya disajikan pada Tabel 4.

Tabel 4 Nilai  $\delta_j$  dan  $\gamma_j$  untuk setiap titik ubah yang bersesuaian

Waktu	$t$	$\delta_j$	$\gamma_j$
2023-03-01 01:10:00	0.061529	0.083228	-0.00512
2023-03-03 02:20:00	0.123058	-0.4073	0.050121
2023-03-05 03:30:00	0.184587	1.107793	-0.20448
2023-03-07 04:40:00	0.246115	-1.84291	0.453568
2023-03-09 05:50:00	0.307644	0.257655	-0.07927
2023-03-11 07:00:00	0.369173	3.006752	-1.11001
2023-03-13 08:15:00	0.430806	-0.86254	0.371586
2023-03-15 09:25:00	0.492335	-1.71497	0.844341
2023-03-17 10:35:00	0.553864	2.547936	-1.41121
2023-03-19 11:45:00	0.615393	-1.37251	0.844632
2023-03-21 12:55:00	0.676921	-0.93986	0.636211
2023-03-23 14:05:00	0.73845	-0.52778	0.389739
2023-03-25 15:15:00	0.799979	1.132659	-0.9061

Gambar 6 adalah grafik dari model *Prophet* yang dibangun.



Gambar 6 Grafik hasil prediksi model *Prophet* terbaik

Nilai MAE dan MAPE untuk model terbaik ini adalah:


Tabel 5 Nilai MAE dan MAPE model *Prophet* terbaik

	Latih	Uji
MAE	5205,380222	33423,957697
MAPE	0,016546	0,107979

Berdasarkan Gambar 6, dapat dilihat bahwa model *Prophet* dapat memprediksi tren dari data harga Solana dengan tepat, hanya saja model masih belum dapat memprediksi efek musiman dari data harga Solana dengan tepat meski sudah dilakukan beberapa kali pengaturan *hyperparameter*. Berdasarkan Tabel 5, pengaturan *hyperparameter* dapat meningkatkan sedikit akurasi dari model *Prophet*. Bila diperhatikan pengaturan *hyperparameter* yang telah dilakukan dapat menurunkan gejala *overfitting* dengan mengecilnya selisih nilai evaluasi antara data latih dengan data uji tanpa menaikkan MAE dan MAPE pada data uji.

### 3.5. Peramalan dan Dekomposisi

Dengan menggunakan model *Prophet* yang telah dibangun sebelumnya, maka langkah selanjutnya adalah melakukan peramalan dan dekomposisi untuk harga tukar Solana. Peramalan dilakukan untuk 60 menit ke depan. Berikut disajikan Gambar 7 untuk grafik peramalan harga Solana dan Gambar 8 adalah grafik dekomposisi harga Solana.

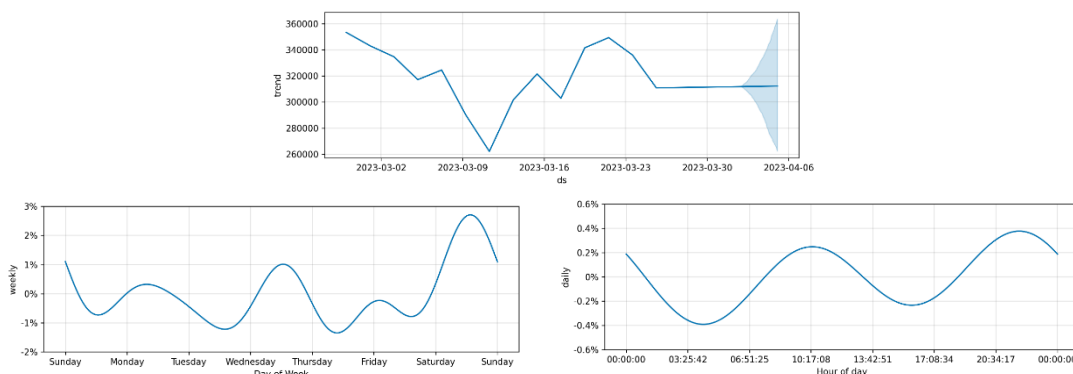


Gambar 7. Peramalan harga tukar Solana

Gambar 7 menginformasikan bahwa harga Solana akan menurun dengan perlahan. Selanjutnya berdasarkan grafik tren yang pada Gambar 8, harga Solana akan konstan dan tidak mengalami kenaikan maupun penurunan yang signifikan. Oleh karena itu, investor direkomendasikan untuk tidak melakukan transaksi jual-beli Solana karena harga Solana yang cenderung konstan tidak cukup menguntungkan untuk berinvestasi.

Berdasarkan grafik mingguan dan harian pada Gambar 8, harga Solana termahal dalam seminggu terjadi pada Sabtu malam. Harga Solana termahal juga terjadi di antara pukul 21.00 dan 22.00 setiap harinya. Oleh karena itu, jika investor ingin melakukan penjualan Solana, maka direkomendasikan untuk melakukan penjualan Solana pada waktu tersebut.

Berdasarkan grafik pada Gambar 8 juga, harga tukar Solana termurah dalam seminggu terjadi pada Selasa malam dan Kamis malam. Harga tukar Solana termurah pun akan terjadi di antara pukul 03.00 dan 04.00 setiap harinya. Sehingga, jika investor ingin melakukan pembelian Solana, maka direkomendasikan untuk melakukan pembelian Solana pada waktu tersebut.



Gambar 8. Dekomposisi harga tukar Solana

Keterbatasan dari penelitian ini adalah tidak dipertimbangkannya panjang efek musiman yang kurang dari 1 hari, sehingga model *Prophet* tidak dapat melakukan prediksi pada efek musiman data dengan tepat. Selain itu, pada penelitian ini tidak dipertimbangkan untuk mencantumkan regresor tambahan. Oleh karena itu, untuk penelitian selanjutnya dapat mencantumkan regresor tambahan yang memiliki korelasi tinggi terhadap mata uang kripto seperti mata uang nyata [15] untuk meningkatkan akurasi peramalan.

#### 4. Kesimpulan

Peramalan dan dekomposisi untuk harga tukar mata uang kripto merupakan hal yang penting dilakukan untuk para investor mata uang kripto. Hal ini merupakan salah satu upaya untuk memperkecil resiko kerugian serta memaksimalkan keuntungan yang diperoleh. Berdasarkan hasil peramalan dan dekomposisi dengan model *Facebook Prophet* multiplikatif dengan *hyperparameter*  $n\_changepoints=13$ ,  $weekly\_seasonality=5$ , dan  $daily\_seasonality=2$   $seasonality\_prior\_scale=0,01$  dan  $changepoint\_prior\_scale=0,1$ , diperoleh informasi bahwa harga tukar Solana terhadap Rupiah akan tetap. Selain itu, harga tukar termahal Solana dalam sepekan terjadi pada Sabtu malam serta di antara pukul 21.00 sampai 22.00 setiap harinya. Harga tukar termurah Solana dalam sepekan terjadi pada Selasa malam dan Kamis malam serta di antara pukul 03.00 hingga 04.00 setiap harinya.

#### Daftar Pustaka

- [1] CNN, “Cerita pemain kripto pernah raup cuan dan gigit jari,” *CNN*, 21 Juli 2022 (diakses 22 April 2023). [[WebLink](#)]
- [2] D. L. Kuo Chuen, L. Guo, dan Y. Wang, “Cryptocurrency: A new investment opportunity?,” *The Journal of Alternative Investments*, vol. 20, no. 3, pp. 16–40, 2017. [[CrossRef](#)]
- [3] Indah Handayani, “Terlambat beli solana? Pakar kripto berikan prediksi harga SOL,” *Investor.Daily*, 5 Januari 2023 (diakses 22 April 2023). [[WebLink](#)]
- [4] D. N. Gujarati dan D. C. Porter, *Dasar-dasar Ekonometrika*. Jakarta: Salemba Empat, 2010.
- [5] Z. Z. OO dan S. PHYU, “Time series prediction based on facebook prophet: A case study, temperature forecasting in Myintkyina,” *International Journal of Applied Mathematics Electronics and Computers*, pp. 263–267, 2020. [[CrossRef](#)]
- [6] E. B. Dagum, “Time series modelling and decomposition,” *Statistica*, vol. 70, no. 4, pp. 433–457, 2010. [[CrossRef](#)]

- [7] M. Alam, M. Rahman, S. A. Sumy, dan Y. A. Parh, "Time series decomposition and seasonal adjustment," *Global Journal of Science Frontier Research: F*, vol. 15, no. 9, pp. 10–20, 2015. [[CrossRef](#)]
- [8] S. J. Taylor dan B. Letham, "Forecasting at scale," *Am Stat*, vol. 72, no. 1, pp. 37–45, 2017. [[CrossRef](#)]
- [9] M. Navratil dan A. Kolkova, "Decomposition and forecasting time series in the business economy using prophet forecasting model," *Central European Business Review*, vol. 8, no. 4, pp. 26–39, 2019. [[CrossRef](#)]
- [10] A. I. Almazrouee, A. M. Almeshal, A. S. Almutairi, M. R. Alenezi, dan S. N. Alhajeri, "Long-term forecasting of electrical loads in Kuwait using prophet and Holt–Winters models," *Applied Sciences*, vol. 10, no. 16, pp. 5627, 2020. [[CrossRef](#)]
- [11] F. Gong, N. Han, D. Li, dan S. Tian, "Trend analysis of building power consumption based on prophet algorithm," dalam *2020 Asia Energy and Electrical Engineering Symposium (AEEES)*, IEEE, Mei 2020, pp. 1002–1006. ([CrossRef](#))
- [12] P. Furtado, "Epidemiology SIR with regression, ARIMA, and prophet in forecasting covid-19," dalam *The 7th International conference on Time Series and Forecasting*, Basel Switzerland: MDPI, Jul 2021, pp. 52. ([CrossRef](#))
- [13] C. Xie *dkk.*, "Trend analysis and forecast of daily reported incidence of hand, foot and mouth disease in Hubei, China by prophet model," *Sci Rep*, vol. 11, no. 1, pp. 1445, Jan 2021. [[CrossRef](#)]
- [14] T. Toharudin, R. S. Pontoh, R. E. Caraka, S. Zahroh, Y. Lee, dan R. C. Chen, "Employing long short-term memory and facebook prophet model in air temperature forecasting," *Commun Stat. Simul. Comput.*, vol. 52, no. 2, pp. 279–290, 2023. [[CrossRef](#)]
- [15] I. Yenidogan, A. Cayir, O. Kozan, T. Dag, dan C. Arslan, "Bitcoin forecasting using ARIMA and prophet," dalam *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, IEEE, Sep 2018, pp. 621–624. [[CrossRef](#)]