

# Analisis Perbandingan Model PSO-LSTM dan LSTM Konvensional untuk Prediksi Harga Bitcoin di Market *Cryptocurrency*

**<sup>1\*</sup>Kresna Aprianto, <sup>2</sup>Umi Mahdiyah, <sup>3</sup>Resty Wulanningrum**

<sup>1,2,3</sup> Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: [\\*1kresnaaprianto87@gmail.com](mailto:*1kresnaaprianto87@gmail.com), [2umimahdiyah@gmail.com](mailto:2umimahdiyah@gmail.com), [3restyw@unpkdr.ac.id](mailto:3restyw@unpkdr.ac.id)

**Penulis Korespondens : Kresna Aprianto**

**Abstrak**—*Cryptocurrency* merupakan salah satu inovasi dalam sistem keuangan digital yang mengalami pertumbuhan pesat, dengan Bitcoin sebagai aset kripto yang paling banyak diminati. Di Indonesia, berdasarkan survei *GlobalWebIndex* tahun 2019, sekitar 10% pengguna internet telah memiliki aset kripto, menjadikan negara ini sebagai salah satu pasar terbesar di dunia. Namun, fluktuasi harga yang tinggi membuat prediksi harga Bitcoin menjadi aspek krusial dalam pengambilan keputusan investasi. Model *Long Short-Term Memory* (LSTM) sebagai salah satu metode *deep learning* unggul dalam memproses data deret waktu, namun performanya sangat dipengaruhi oleh konfigurasi *hyperparameter*. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi harga Bitcoin dengan mengoptimalkan *hyperparameter* LSTM menggunakan algoritma *Particle Swarm Optimization* (PSO). Evaluasi dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Root Mean Squared Error* (RMSE). Hasil eksperimen menunjukkan bahwa model PSO-LSTM memberikan performa yang lebih baik dibandingkan model LSTM konvensional. MSE menurun sebesar 4,90% dari 1.142.860,6 menjadi 1.086.861,4; MAE menurun sebesar 11,78% dari 603,1 menjadi 532 dan RMSE menurun sebesar 2,48% dari 1.069 menjadi 1.042,5. Temuan ini membuktikan bahwa integrasi PSO sebagai metode optimasi dapat meningkatkan akurasi model prediksi, serta memperkuat validitas pendekatan kombinasi algoritmik dalam pengembangan sistem prediksi harga Bitcoin berbasis deep learning.

**Kata Kunci**—*Cryptocurrency, Bitcoin, LSTM, Optimasi Hyperparameter, Particle Swarm Optimization*

**Abstract**—*Cryptocurrency* is one of the innovations in the digital financial system that has experienced rapid growth, with Bitcoin being the most popular crypto asset. In Indonesia, according to a 2019 *GlobalWebIndex* survey, around 10% of internet users already own crypto assets, making the country one of the largest markets in the world. However, the high price volatility makes Bitcoin price prediction a crucial aspect in investment decision-making. The *Long Short-Term Memory* (LSTM) model, as one of the deep learning methods, excels in processing time series data, but its performance is highly influenced by hyperparameter configuration. This study aims to improve the accuracy of Bitcoin price prediction by optimizing the LSTM hyperparameters using the *Particle Swarm Optimization* (PSO) algorithm. Evaluation is conducted using *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), and *Root Mean Squared Error* (RMSE) metrics. The experimental results show that the PSO-LSTM model performs better than the conventional LSTM model. MSE decreased by 4.90% from 1,142,860.6 to 1,086,861.4; MAE decreased by 11.78% from 603.1 to 532; and RMSE decreased by 2.48% from 1,069 to 1,042.5. These findings demonstrate that integrating PSO as an optimization method can enhance prediction model accuracy and strengthen the validity of algorithmic combination approaches in developing deep learning-based Bitcoin price prediction systems.

**Keywords**—*Cryptocurrency, Bitcoin, LSTM, Optimasi Hyperparameter, Particle Swarm Optimization*

This is an open access article under the CC BY-SA License.



## I. PENDAHULUAN

Investasi dalam *cryptocurrency*, khususnya Bitcoin, telah menarik perhatian banyak orang di era digital ini. Berdasarkan survei yang dilakukan oleh *GlobalWebIndex*, sekitar 10% pengguna internet di Indonesia memiliki mata uang digital, menjadikan Indonesia sebagai negara dengan pengguna *cryptocurrency* terbanyak kelima di dunia[1]. Bitcoin sendiri merupakan aset digital yang paling dominan di pasar *crypto*, dengan nilai kapitalisasi yang jauh melampaui aset digital lainnya. Harga Bitcoin mengalami fluktuasi yang sangat tinggi, mencerminkan volatilitas pasar yang ekstrem. Berdasarkan data dari *CoinMarketCap*, harga Bitcoin pada 7 Januari 2025 tercatat \$101.702 (sekitar Rp1,64 miliar) dengan volume perdagangan dalam 24 jam terakhir mencapai \$51,67 miliar. Kenaikan harga ini sangat signifikan jika dibandingkan dengan awal tahun 2024, di mana Bitcoin hanya bernilai sekitar Rp668 juta. Lonjakan ini juga didukung oleh meningkatnya volume perdagangan pada *platform* Binance, yang mencatat kenaikan dari 8.653 BTC (\$585 juta USDT) pada 27 Oktober 2024 menjadi 104.127 BTC (\$7,7 miliar USDT) pada 6 November 2024.

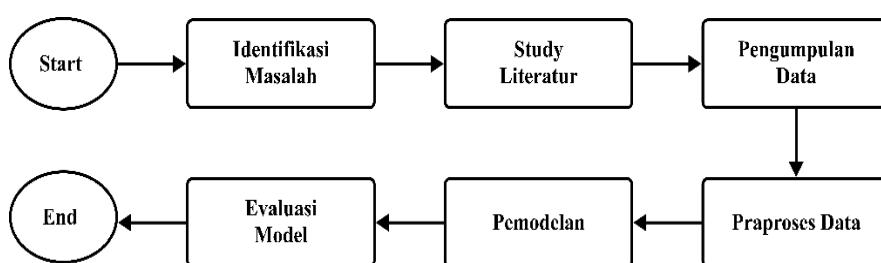
Tren peningkatan investasi ini didorong oleh minat yang besar dari investor muda, terutama generasi Z, yang dikenal adaptif terhadap teknologi dan investasi digital. Faktor psikologis seperti *Fear of Missing Out* (FoMO) juga berperan dalam mendorong mereka untuk terlibat dalam pasar *cryptocurrency*[2]. Namun, meskipun menawarkan potensi keuntungan yang besar, tingginya volatilitas harga Bitcoin membuat prediksi harga menjadi tantangan bagi investor, terutama bagi mereka yang masih pemula. Seiring berkembangnya teknologi kecerdasan buatan, penggunaan algoritma untuk analisis dan prediksi harga *cryptocurrency* semakin meningkat. Salah satu metode yang paling banyak digunakan adalah *Long Short-Term Memory* (LSTM), yang merupakan jenis jaringan saraf tiruan (*Neural Network*) yang dirancang untuk mengenali pola dalam data berurutan. Studi oleh Oxaichiko Arissinta dkk. (2022) menunjukkan bahwa metode LSTM dan GRU memiliki akurasi terbaik dalam pemodelan *time series* dibandingkan metode ARIMA[3].

Meskipun LSTM memiliki performa yang cukup baik dalam memprediksi pergerakan harga Bitcoin, akurasinya sangat bergantung pada konfigurasi *hyperparameter* yang digunakan. Studi oleh Nuke dkk.(2022) membahas optimasi *hyperparameter* LSTM dalam prediksi penjualan dengan konfigurasi terbaik berupa 3 *hidden layer*, *dropout rate* 3, 150 *epoch*, dan *batch size* 30, menghasilkan nilai RMSE sebesar 0,0855 pada data pelatihan dan 0,0846 pada data pengujian[4]. Dalam penelitian ini, akan dilakukan optimasi *hyperparameter* pada model LSTM menggunakan Particle Swarm Optimization (PSO). PSO merupakan algoritma optimasi berbasis *swarm intelligence* yang mampu mencari kombinasi *hyperparameter* terbaik untuk meningkatkan performa prediksi model. Dengan menggabungkan LSTM dan PSO, penelitian ini bertujuan untuk meningkatkan akurasi prediksi harga Bitcoin, sehingga dapat memberikan wawasan lebih baik bagi investor dalam mengurangi risiko dan memaksimalkan keuntungan dalam investasi *cryptocurrency*.

## II. METODE

Metode penelitian analisa prediksi harga bitcoin menggunakan *model Long Short Term Memory* dengan optimasi *hyperparameter* menggunakan *Particle Swarm Optimization*. Alur tahapan seperti pada gambar 1 agar terarah, teratur sehingga menghasilkan hasil penelitian yang

baik dan dapat digunakan sebagai rekomendasi dalam pengambilan keputusan memprediksi harga bitcoin



Gambar 1. Diagram Alir Penelitian

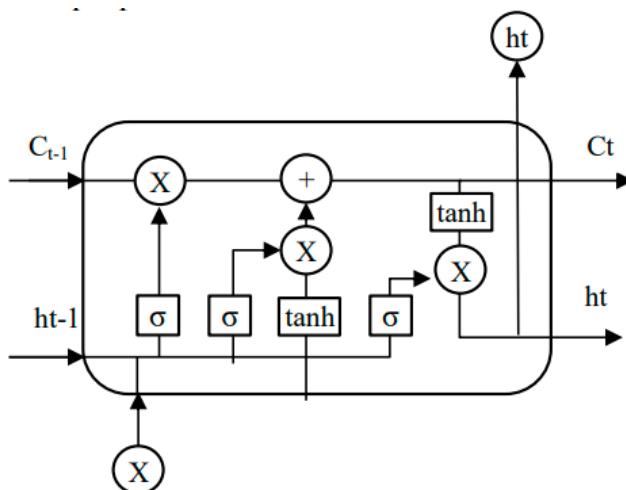
## 2.1. Identifikasi Masalah

Untuk mendapatkan prediksi harga bitcoin yang tepat sehingga dapat memaksimalkan profit atau keuntungan, maka diperlukan prediksi harga bitcoin dengan metode algoritma yang tepat dengan memanfaatkan data histori bitcoin di masa lampau, data tersebut akan di latih menggunakan algoritma *forecasting* yaitu *Long Short Term Memory* yang mampu mengenali pola data *time series* dengan baik dan di optimalkan dengan optimasi *Particle Swarm Optimization* untuk memberikan *hyperparameter* yang optimal untuk proses pelatihan model LSTM yang kemudian akan di evaluasi dengan metrik performa model yaitu dengan *Mean Squared Error*, *Mean Absolute Error* dan *Root Mean Squared Error* dengan nilai *error* yang paling minimum atau paling kecil.

## 2.2. Study Literatur

### 2.2.1. Long Short Term Memory

*Long Short-Term Memory* (LSTM) merupakan salah satu jenis *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah pada gradien dan ketergantungan jangka panjang saat memproses atau memprediksi data deret waktu. RNN sering menghadapi kendala berupa gradien yang menumpuk, sehingga nilai gradien saling berbenturan, menyebabkan ketidak jelasan dalam nilainya dan berpotensi kehilangan akumulasi informasi. LSTM dirancang untuk mengatasi permasalahan ini[5].



Gambar 1. Arsitektur Model LSTM

### 2.2.2. Particle Swarm Optimization

*Particle Swarm Optimization* (PSO) merupakan salah satu algoritma *metaheuristik* yang banyak digunakan dalam berbagai penelitian. Algoritma ini meniru perilaku sosial burung dalam sebuah kawanan. Setiap partikel dalam PSO diberikan nilai awal secara acak sebagai solusi sementara. Selama iterasi, posisi dan kecepatan partikel diperbarui dengan mempertimbangkan pengalaman terbaik individu serta pengalaman terbaik kelompok secara keseluruhan. Proses ini dilakukan secara berulang dalam beberapa iterasi untuk menemukan solusi yang optimal[6]. Setiap partikel dalam algoritma PSO memiliki dua atribut utama, yaitu kecepatan (V) dan posisi (X). Kecepatan dan posisi partikel diperbarui pada setiap iterasi menggunakan Persamaan 2.7 dan Persamaan 2.8

Rumus persamaan 2.7 :

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (Pbest_i - x_i^t) + c_2 \cdot r_2 \cdot (Gbest - x_i^t) \dots (1)$$

Rumus persamaan 2.8 :

$$x_i^{t+1} = v_i^t + v_i^{t+1} \dots (2)$$

Dalam hal ini,  $v_i^t$  mewakili kecepatan partikel ke-i pada iterasi ke-t, dan  $x_i^t$  adalah posisi partikel ke-i pada iterasi yang sama. Parameter  $w$  digunakan sebagai bobot *inversia* untuk mengatur perubahan kecepatan partikel, sedangkan  $c_1$  dan  $c_2$  adalah konstanta akselerasi dengan nilai positif. Selain itu,  $r_1$  dan  $r_2$  merupakan variabel acak yang berdistribusi uniform dalam rentang 0 hingga 1. Nilai  $Pbest$  merujuk pada pengalaman terbaik partikel secara individu, sementara  $Gbest$  merepresentasikan pengalaman terbaik seluruh kawanan.

### 2.3. Pengumpulan Data

Pengumpulan data dilakukan dengan mengamati dan menganalisis data historis harian harga Bitcoin dari Yahoo Finance menggunakan pustaka *yfinance*. Data mencakup variabel seperti *date*, *open*, *high*, *low*, *close*, dan *volume*, dengan periode 17 September 2014 hingga tanggal pelatihan model. Data ini digunakan untuk membangun dan menguji model prediksi harga Bitcoin.

Tabel 1. Sampel data Perdagangan harian periode 17 September 2014 – 13 Maret 2025

Date	Open	High	Low	Close	Volume
2014-09-17	465.864014	468.174011	452.421997	457.334015	21056800
2014-09-18	456.859985	456.859985	413.104004	424.440002	34483200
2014-09-19	424.102997	427.834991	384.532013	394.795990	37919700
.....	.....	.....	.....	.....	.....
2025-03-12	82857.375000	84358.578125	80635.250000	83722.359375	40353484454
2025-03-13	83724.921875	84301.695312	79931.851562	81066.703125	31412940153

### 2.4. Pra proses Data

#### 2.4.1. Reduksi Atribut Dataset

Sebelum data yang ada dilakukan pemrosesan maka data perlu dilakukan praproses data dengan tujuan untuk mempermudah memahami data sehingga mempermudah pemilihan teknik dan metode data mining yang tepat, meningkatkan kualitas data sehingga hasil data mining menjadi lebih baik, dan meningkatkan efisiensi dan kemudahan proses penambangan data [7]. Pemrosesan data dapat menggunakan cara pembersihan, integrasi, reduksi, penambahan dan transformasi. Cara-cara tersebut dapat dilakukan secara bersamaan atau sekaligus atau hanya satu cara saja. Dari data tabel 1, akan dilakukan praproses data dengan cara reduksi yaitu variabel *date*, *open*, *high*, *low*, dan *volume* akan dihilangkan, karena data yang akan digunakan adalah variabel *close*

Tabel 2.Sampel data Perdagangan harian setelah dilakukan reduksi

<b>Date</b>	<b>Close</b>
2014-09-17	457.334015
2014-09-18	424.440002
2014-09-19	394.795990
.....	.....
2025-03-12	83722.359375
2025-03-13	81066.703125

#### 2.4.2. Normalisasi Data

Normalisasi data adalah langkah penting dalam pemrosesan untuk model pembelajaran mesin, dengan tujuan menyelaraskan skala data ke rentang tertentu, biasanya 0 hingga 1. Dalam prediksi harga Bitcoin menggunakan metode LSTM, normalisasi dilakukan pada data harga penutupan (*close price*) dengan mengubahnya ke rentang [0, 1] menggunakan metode seperti *MinMaxScaler*, agar sesuai dengan kebutuhan model dan meningkatkan stabilitas serta efisiensi pelatihan.

$$x_{new} = \frac{x_1 - \min(x)}{\max(x) - \min(x)} \dots (3)$$

Tabel 3.Sampel data setelah di normalisasi *MinmaxScaler*

<b>Date</b>	<b>Close</b>	<b>Hasil Normalisasi</b>
2014-09-17	457.334015	0.00510
2014-09-18	424.440002	0.00465
2014-09-19	394.795990	0.00345
.....	.....	.....
2025-03-12	83722.359375	0.97567
2025-03-13	81066.703125	0.94332

#### 2.6. Evaluasi Model

Evaluasi secara umum merujuk pada proses yang terstruktur untuk menilai nilai dari sesuatu, seperti ketentuan, aktivitas, keputusan, performa, proses, individu, objek, atau lainnya, berdasarkan kriteria tertentu melalui proses penilaian[9].

##### 2.6.1. Mean Squared Error

*Mean Square Error* (MSE) adalah *Mean Squared Error* (MSE) merupakan rata-rata dari kuadrat selisih antara nilai prediksi model dengan nilai aktual. MSE memberikan bobot yang lebih besar pada kesalahan yang lebih besar karena kuadratnya, sehingga sangat sensitif terhadap outlier.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \dots (4)$$

##### 2.6.2. Mean Absolute Error

*Mean Absolute Error* (MAE) adalah rata-rata nilai absolut dari selisih antara prediksi model dan nilai aktual. MAE memberikan gambaran yang lebih intuitif tentang seberapa besar rata-rata kesalahan peramalan tanpa memberikan bobot lebih pada kesalahan besar.

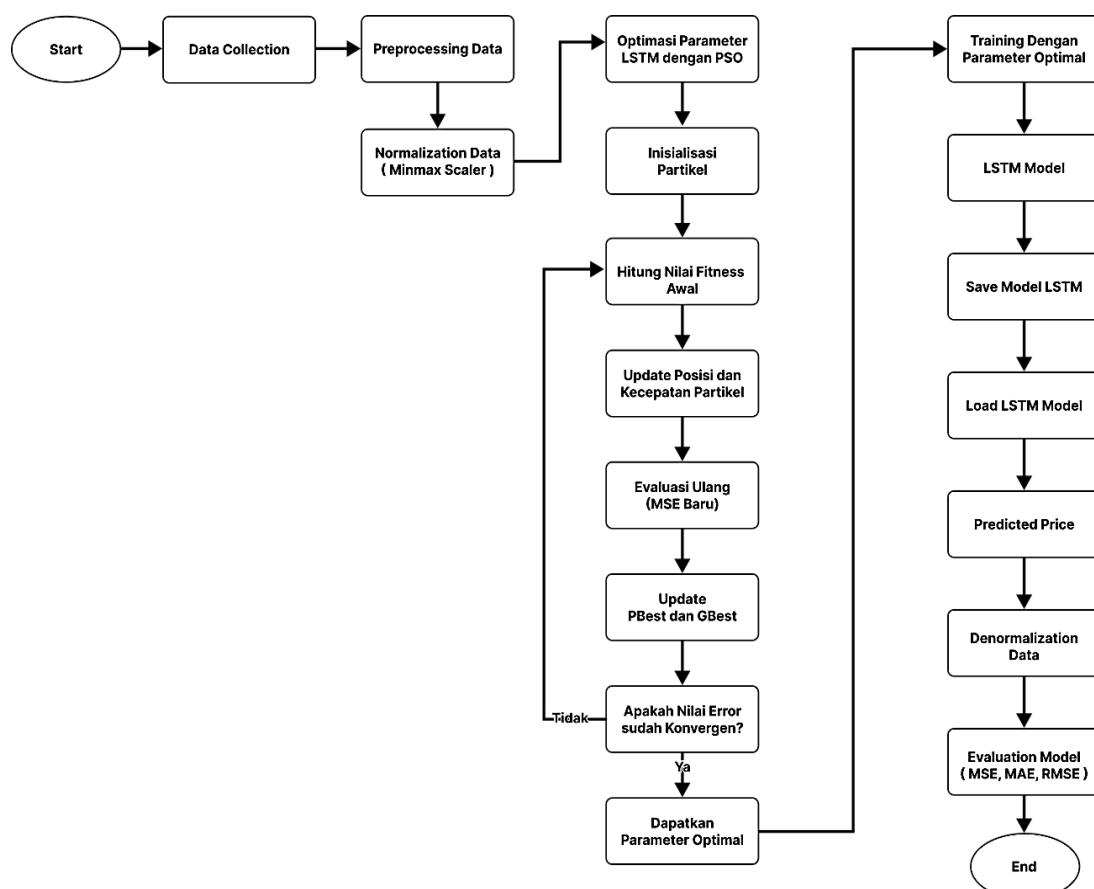
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots (5)$$

#### 2.6.3. Root Mean Absolute Error

*Root Mean Squared Error* (RMSE) adalah akar kuadrat dari MSE. Metrik ini memberikan *interpretasi* yang lebih langsung dalam satuan yang sama dengan data aslinya. Semakin kecil nilai RMSE, semakin baik kinerja model peramalan.

$$RMSE = \sqrt{MSE} \dots (6)$$

Proses pemodelan bisa di lihat pada gambar 3, dimana pemodelan tersebut terdapat beberapa proses sebagai berikut :



Gambar 2. Diagram Alir Pemodelan

#### 2.7. Data Collection

*Data collection* merupakan proses pengambilan data histori dari *website yahoo finance* dari periode 17 september 2014 hingga dimana model ingin di *training*, proses tersebut melibatkan pustaka python yaitu *yfinance* yang memudahkan untuk pengambilan data histori harga bitcoin.

#### 2.8. Preprocessing Data

Pada tahap ini data histori bitcoin akan dilakukan normalisasi data dengan *Min Max Scaler*, ini bertujuan untuk mengubah data histori bitcoin tersebut menjadi rentan 0 sampai 1 yang bertujuan untuk mempermudah model pada saat proses training.

### 2.9. Optimasi *Hyperparameter* LSTM dengan PSO

Pada tahap ini *hyperparameter* pada model LSTM akan di optimalkan yaitu *batch size*, *epoch*, *units*, *learning rate*, *sequence length* dan *dropout rate*. Pertama inisialisasi partikel dan kecepatan awal kemudian evaluasi partikel dengan menghitung nilai *error* dari *objective function* dalam konteks ini nilai *error* di ukur dengan metrik evaluasi model yaitu *Mean Squared Error* (MSE) kemudian update posisi dan kecepatan partikel dan dapatkan parameter yang optimal yang nantinya akan di masukkan ke konfigurasi model LSTM yang akan di *training*.

### 3.0. Split Data Training dan Testing

Pada tahap ini pembagian data training dan data testing dengan perbandingan 90:10, 80:20 dan 70:30, data training 70% - 90% dan data testing 10% - 30%, data training digunakan untuk training model dengan hyperparameter yang dioptimalkan dengan optimasi PSO sebelumnya dan kemudian model yang sudah di training di simpan untuk nantinya di gunakan untuk prediksi harga, load model yang di simpan dan gunakan data testing untuk prediksi harga bitcoin pastikan data sudah di denormalisasi ke ukuran aslinya

### 3.1. Evaluasi Model

Pada tahap ini di lakukan evaluasi model yang bertujuan untuk mengukur seberapa baik model mengenali pola data histori bitcoin dengan metrik evaluasi model yaitu *Mean Squared Error*, *Mean Absolute Error* dan *Root Mean Squared Error*.

## III. HASIL DAN PEMBAHASAN

Berdasarkan eksperimen algoritma *Particle Swarm Optimization* (PSO), parameter seperti jumlah partikel, iterasi,  $c_1$ ,  $c_2$ , dan bobot *inersia* ( $w$ ) digunakan untuk mencari nilai *error* terkecil (*best loss*). Nilai *global best* dari proses ini mewakili parameter optimal (*epoch*, *batch size*, *unit*, *sequence length*, *dropout rate*, dan *learning rate*) yang kemudian diterapkan pada pelatihan model LSTM untuk meningkatkan akurasi dan menurunkan error. Hasil *best loss* dan *global best* ditampilkan pada Tabel 3.

Tabel 3. Hasil *Global Best* atau Parameter Optimal PSO

No.	Best Loss	Epochs	Batch size	Units	LR	SeqLen	Dropout
1	0.000362	333	67	34	0.0073	52	0.12
2	0.000395	287	90	23	0.0094	45	0.10
3	0.000344	350	47	33	0.0076	21	0.13
4	0.000322	274	106	45	0.0085	43	0.11
5	0.000400	219	37	36	0.0072	29	0.15
6	0.000285	247	105	35	0.0072	32	0.15
7	0.000319	304	29	17	0.0029	44	0.11
8	0.000306	247	57	32	0.0052	34	0.11

No.	Best Loss	Epochs	Batch size	Units	LR	SeqLen	Dropout
9	0.000340	277	125	43	0.0095	16	0.15
10	0.000276	309	81	42	0.0078	24	0.11

Hasil optimasi dengan algoritma PSO menghasilkan kombinasi parameter terbaik dengan nilai *loss* terendah. Untuk menilai efektivitasnya, dilakukan perbandingan antara model PSO-LSTM dan LSTM dengan parameter acak (*random*), guna melihat peningkatan akurasi dan penurunan *error*. Parameter acak diperoleh melalui proses *random generation*, seperti ditampilkan pada Tabel 4.

Tabel 4. Rata-rata matrik evaluasi model PSO-LSTM

No.	Epochs	Batch size	Units	LR	SeqLen	Dropout
1	220	16	12	0.006	10	0.10
2	210	32	15	0.0083	12	0.12
3	230	20	10	0.0086	11	0.15
4	205	128	13	0.0019	10	0.10
5	240	64	14	0.0078	13	0.11
6	250	16	11	0.0062	10	0.10
7	235	40	12	0.0081	12	0.13
8	217	60	15	0.0016	10	0.12
9	215	96	14	0.0025	10	0.14
10	225	128	15	0.0044	13	0.12

### 3.1. Evaluasi Model PSO-LSTM

Eksperimen pertama mengevaluasi kinerja model LSTM yang dioptimasi dengan PSO, di mana parameter seperti *epoch*, *batch size*, *learning rate*, *unit neuron*, *sequence length*, dan *dropout rate* diperoleh melalui proses optimasi. Nilai *error* terkecil dapat pada pembagian dataset 80:20 pada pengujian 10 kombinasi parameter hasil optimasi PSO tersebut. Evaluasi dilakukan menggunakan nilai MAE, MSE, dan RMSE pada data *training*, *testing*, dan keseluruhan, sebagaimana ditampilkan pada Tabel 5.

Tabel 5. Rata-rata matrik evaluasi model PSO-LSTM 20 Parameter Uji

Rata-rata ( <i>Training</i> )		Rata-rata ( <i>Testing</i> )		Rata Rata ( <i>Train &amp; Test</i> )	
MSE	914460,32	MSE	7648024,455	MSE	1536657,555
MAE	592,005	MAE	2103,385	MAE	731,805
RMSE	950,465	RMSE	2711,525	RMSE	1228,805

Pemilihan kombinasi *hyperparameter* terbaik untuk skenario ini mengacu pada nilai error terendah yang dihasilkan model PSO-LSTM pada pembagian dataset 80:20 yaitu: epoch sebanyak 247 ,batch size sebesar 105, learning rate sebesar 0.0072, jumlah unit neuron sebanyak 35, sequence length sebesar 32 dan dropout rate sebesar 0.15 dan menghasilkan nilai evaluasi pada keseluruhan data training dan testing dengan MSE sebesar 1086861.4, MAE sebesar 532 dan RMSE sebesar 1042.5

### 3.2. Evaluasi Model LSTM Konvensional

Eksperimen kedua mengevaluasi model LSTM dengan parameter acak (tanpa optimasi), yang ditentukan dalam rentang umum pelatihan LSTM. Nilai *error* terkecil di dapat pada pembagian dataset 80:20 pada pengujian 10 kombinasi parameter acak tersebut. Evaluasi menggunakan MAE, MSE, dan RMSE pada data *training*, *testing*, dan keseluruhan, untuk membandingkan performanya dengan model PSO-LSTM. Hasil ditampilkan pada Tabel 6.

Tabel 6. Rata-rata matrik evaluasi model LSTM Konvensional 20 Parameter Uji

<b>Rata-rata (<i>Training</i>)</b>		<b>Rata-rata (<i>Testing</i>)</b>		<b>Rata Rata (<i>Train &amp; Test</i>)</b>	
MSE	948877,925	MSE	10059051,18	MSE	768,515
MAE	591,005	MAE	2412,48	MAE	768,515
RMSE	966,375	RMSE	3099,505	RMSE	1338,155

Pemilihan kombinasi *hyperparameter* terbaik untuk skenario ini mengacu pada nilai *error* terendah yang dihasilkan model LSTM Konvensional pada pembagian dataset 80:20 yaitu: *epoch* sebanyak 217, *batch size* sebesar 60, *learning rate* sebesar 0.0016, jumlah *unit neuron* sebanyak 15, *sequence length* sebesar 10, dan *dropout rate* sebesar 0.12 dan menghasilkan nilai evaluasi pada keseluruhan data *training* dan *testing* dengan MSE sebesar 1142860.6, MAE sebesar 603.1 dan RMSE sebesar 1069.

### 3.3 Hasil Perbandingan PSO-LSTM dan LSTM Konvensional

Berdasarkan eksperimen dengan tiga skema pembagian data (90:10, 80:20, dan 70:30), dipilih salah satu parameter terbaik baik itu dari model LSTM dengan optimasi PSO atau model LSTM Konvensional dengan paramater acak. Tabel 7 dan 8 menyajikan parameter tersebut beserta metrik evaluasi MAE, MSE, dan RMSE.

Tabel 7. Parameter Terbaik Dari Model PSO-LSTM Dengan Error Terbaik Dengan 3 Experimen Pembagian Dataset

<b>Parameter</b>	<b>Pembagian dataset</b>	<b>Metrik evaluasi (Overall)</b>
Epochs : 247, Batch Size : 105, Units : 35, Learning Rate : 0.0072, Sequence Length : 32, Dropout Rate : 0.15	80% data training dan 20% data testing	MSE : 1086861.4, MAE : 532, RMSE : 1042,5

Tabel 8. Parameter Terbaik Dari Model PSO-Konvensional Dengan Error Terbaik Dengan 3 Experimen Pembagian Dataset

<b>No.</b>	<b>Parameter</b>	<b>Pembagian dataset</b>	<b>Metrik Evaluasi (Overall)</b>
1.	Epochs : 217, Batch Size : 60, Units : 15, Learning Rate : 0.0016, Sequence Length : 10, Dropout Rate : 0.12	80% data training dan 20% data testing	MSE : 1142860.6, MAE : 603.1, RMSE : 1069

#### IV. KESIMPULAN

Berdasarkan hasil perhitungan evaluasi ,Model PSO-LSTM menunjukkan performa yang lebih baik dibandingkan dengan model LSTM konvensional. Hal ini dibuktikan melalui penurunan nilai error pada ketiga metrik evaluasi. Mean Squared Error (MSE) menurun sebesar 4,90%, dari 1.142.860,6 menjadi 1.086.861,4. Mean Absolute Error (MAE) juga turun sebesar 11,78%, dari 603,1 menjadi 532. Sedangkan Root Mean Squared Error (RMSE) menurun sebesar 2,48%, dari 1069 menjadi 1042,5. Penurunan nilai error ini menunjukkan bahwa penggunaan algoritma Particle Swarm Optimization (PSO) dalam mengoptimalkan parameter LSTM efektif dalam meminimalkan kesalahan prediksi, sehingga model PSO-LSTM memiliki akurasi yang lebih baik dalam memprediksi harga Bitcoin. Dengan demikian, integrasi metode PSO dalam proses tuning hyperparameter memberikan kontribusi positif terhadap peningkatan akurasi prediksi model, sekaligus memperkuat validitas pendekatan kombinasi algoritmik dalam pengembangan sistem prediksi berbasis deep learning.

#### DAFTAR PUSTAKA

- [1] Huda, N., & Hambali, R. (2020). Risiko dan Tingkat Keuntungan Investasi Cryptocurrency. *Jurnal Manajemen dan Bisnis: Performa*, 17(1), 72-84.
- [2] Pramukti, A. M., PD., M. M., Isfaatun, E., & Kholisoh, L. (2024). Faktor-faktor yang mempengaruhi minat investasi cryptocurrency: Studi empiris pada mahasiswa di Daerah Istimewa Yogyakarta. *Simposium Manajemen dan Bisnis III*, Program Studi Manajemen - FEB UNP Kediri, 3, 75
- [3] Arissinta, I. O., Sulistiyawati, I. D., Kurnianto, D., & Kharisudin, I. (2022). Pemodelan time series untuk peramalan web traffic menggunakan algoritma ARIMA, LSTM, dan GRU. *PRISMA*, 5(2022), 693-700. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [4] Chusna, N. L., Tari, D. M. R., & Khumaidi, A. (2022). Konfigurasi hyperparameter long short-term memory untuk optimalisasi prediksi penjualan. *Faktor Exacta*, 15(4), 290-300. <https://doi.org/10.30998/faktorexacta.v15i4.15286>
- [5] Cholissodin, I., Sutrisno, S., & AA, H. U., & Febiola, YI (2019). Buku Ajar AI. Machine Learning & Deep Learning. Malang: Fakultas Ilmu Komputer (FILKOM), Universitas Brawijaya (UB).
- [6] Kennedy, J., & Eberhart, R. (1995, November). Particle swarm optimization. In Proceedings of ICNN'95-international conference on neural networks (Vol. 4, pp. 1942-1948). ieee.
- [7] Kennedy, J., & Eberhart, R. (1995, November). Particle swarm optimization. In Proceedings of ICNN'95-international conference on neural networks (Vol. 4, pp. 1942-1948). ieee.
- [8] Suyanto, Data Mining Untuk Klasifikasi dan Klasterisasi Data. Bandung: Penerbit Informatika, 2019
- [9] Magdalena, H. N. Fauzi, dan R. Putri, "Pentingnya Evaluasi dalam Pembelajaran dan Akibat Memanipulasinya," *Bintang: Jurnal Pendidikan dan Sains*, vol. 2, no. 2, pp. 244–257, Aug. 2020. [Online]. Available: <https://ejournal.stitpn.ac.id/index.php/bintang>