

PERAMALAN HARGA BITCOIN CASH-USD (BCH-USD) PADA TIME FRAME HARIAN MENGGUNAKAN LSTM

Jiwa Akbar¹, Muchtar Ali Setyo Yudono², Ivana Lucia Kharisma³

^{1,2} Teknik Elektro, Universitas Nusa Putra

³ Teknik Informatika, Universitas Nusa Putra

jiwa.akbar_te20@nusaputra.ac.id

ABSTRAK

Perkembangan teknologi yang pesat, terutama di sektor keuangan, telah mendorong pergeseran dari mata uang konvensional ke mata uang digital seperti Bitcoin Cash (BCH). BCH adalah mata uang kripto yang menggunakan teknologi *blockchain*, yaitu rantai blok yang berfungsi sebagai tempat pencatatan transaksi tanpa sentralisasi, berbeda dengan sistem bank tradisional. Namun, harga BCH sangat fluktuatif sehingga diperlukan peramalan harga masa depan. Penelitian ini mengusulkan penggunaan algoritma *Long Short Term Memory* (LSTM) untuk meramalkan harga BCH. LSTM, sebuah algoritma jaringan saraf tiruan, mampu memahami data deret waktu yang kompleks seperti pergerakan harga BCH. Studi sebelumnya menunjukkan bahwa LSTM berhasil digunakan untuk meramalkan harga saham dan umur transformator, dengan penurunan *Root Mean Square Error* (RMSE) yang signifikan dibandingkan algoritma lain. Berdasarkan pendekatan ini, penelitian bertujuan menyajikan proyeksi harga BCH yang bermanfaat bagi pelaku pasar keuangan. Penelitian ini melibatkan lima skenario peramalan. Skenario pertama menggunakan *epoch* 10 dan *hidden layer* 10, skenario kedua *epoch* 20 dan *hidden layer* 20, skenario ketiga *epoch* 30 dan *hidden layer* 30, skenario keempat *epoch* 40 dan *hidden layer* 40, dan skenario kelima *epoch* 50 dan *hidden layer* 50. Panjang *sequence* di setiap skenario yaitu 30. Hasil terbaik diperoleh pada skenario kedua menghasilkan nilai *Mean Squared Error* (MSE) sebesar 1654,40 dan RMSE sebesar 40,67.

Keyword : Teknologi, Cryptocurrency, Bitcoin Cash, Peramalan, Long Short Term Memory, Proyeksi

1. PENDAHULUAN

Dewasa ini, perkembangan teknologi semakin pesat dan mengubah cara konvensional di sektor keuangan menuju mata uang digital [1]. Salah satu bentuk mata uang digital yang berkembang adalah *Cryptocurrency*, yang digunakan untuk pembayaran *online* dengan tingkat keamanan tinggi [2]. Mata uang ini menggunakan sistem kriptografi untuk memproses transaksi tanpa pihak ketiga [3].

Bitcoin adalah salah satu instrumen utama dalam *Cryptocurrency* [4]. *Bitcoin* berfungsi sebagai sistem pembayaran elektronik yang menggunakan bukti kriptografi untuk menggantikan kebutuhan pihak ketiga, memungkinkan transaksi langsung antara dua pihak tanpa perantara [5]. *Bitcoin* diperkenalkan pada 3 Januari 2009 oleh Satoshi Nakamoto dan beroperasi di atas teknologi *Blockchain*, yang mencatat setiap transaksi secara terdesentralisasi, sehingga data tidak mudah dimanipulasi [6][7].

Kemunculan *Bitcoin* memicu munculnya *Bitcoin Cash* (BCH), yang memiliki dasar yang sama tetapi dengan perbedaan signifikan seperti ukuran blok yang lebih besar (8 MB) dibandingkan *Bitcoin* (1 MB). BCH menawarkan kapasitas transaksi lebih besar dan kecepatan lebih tinggi, meskipun harga kedua mata uang ini sangat fluktuatif [8]. Oleh karena itu, peramalan harga menjadi penting untuk meminimalkan risiko kerugian investasi.

Algoritma *Long Short Term Memory* (LSTM) dapat digunakan untuk meramalkan pergerakan

harga BCH. LSTM adalah algoritma jaringan saraf tiruan yang mampu memproses data deret waktu dan mempelajari pola data untuk prediksi masa depan [9]. LSTM memiliki komponen sel memori yang menyimpan informasi jangka panjang, memungkinkan pemahaman data yang kompleks seperti pergerakan harga BCH.

Beberapa penelitian sebelumnya menggunakan LSTM untuk peramalan. Penelitian berjudul “Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan *Long Short Term Memory* (LSTM)” menggunakan data harga saham dari tahun 2016 hingga 2020, menunjukkan penurunan *Root Mean Square Error* (RMSE) pada peningkatan jumlah *epoch*, dengan RMSE terkecil pada emiten TINS sebesar 31,76 [10].

Penelitian lain yang mengangkat tema yang sama berjudul penelitian, “Algoritma *Deep Learning-LSTM* Untuk Memprediksi Umur *Transformer*”, menggunakan empat algoritma pembelajaran mesin: *Multilayer Perceptron*, *Deep Learning-LSTM*, *Linear Regression*, dan *Gradient Boosting Regressor*. Penelitian ini menunjukkan bahwa *Deep Learning-LSTM* memiliki kinerja terbaik dengan nilai RMSE 0,0004 dan *Squared Correlation* 0,9690 [11].

Fluktuasi harga *Bitcoin Cash* yang tinggi membuat peramalan harga menjadi penting. Penelitian ini bertujuan menggunakan metode LSTM untuk meramalkan pergerakan harga *Bitcoin Cash*, dengan harapan memberikan proyeksi peramalan harga BCH yang akurat dan bermanfaat bagi pelaku

pasar keuangan dalam pengambilan keputusan investasi.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian sebelumnya yang menerapkan tema yang sama dengan judul 'Optimasi Prediksi Cryptocurrency Menggunakan Pendekatan Deep Learning' tahun 2023 [12] telah menerapkan LSTM untuk meramalkan pergerakan harga *cryptocurrency*, terutama Bitcoin. Studi tersebut memusatkan perhatian pada data historis Cardano dari 2017 hingga 2021. Model LSTM digunakan dengan pembagian data latih 80% dan uji 20%. Hasilnya menunjukkan *optimizer* Adam memiliki RMSE terendah (0.391), lebih baik daripada RMSProp (0.434). Temuan ini menegaskan keefektifan Deep Learning dalam prediksi harga *cryptocurrency*.

Penelitian selanjutnya dengan judul "Penerapan LSTM pada Data Time Series untuk Prediksi Penjualan Produk di PT. Metiska Farma" pada tahun 2019 [13] bertujuan memprediksi penjualan produk perusahaan. Menggunakan data Time Series penjualan produk X dari 2017 hingga 2019, model LSTM diuji dalam tiga skenario pembagian data latih-ujii: 70%-30%, 80%-20%, dan 90%-10%. Dengan menganalisis variabel tunggal, yaitu harga penjualan, hasil menunjukkan MAPE terendah (12%) pada skenario 90%-10%, menegaskan potensi LSTM dalam meramalkan penjualan produk perusahaan.

2.2. Bitcoin Cash

Bitcoin Cash adalah mata uang digital yang menggunakan sistem pembayaran *peer-to-peer* (P2P), memungkinkan transaksi langsung tanpa lembaga keuangan atau pemerintah, sehingga pengguna dapat menghindari biaya pihak ketiga. Bitcoin Cash memiliki dasar yang mirip dengan Bitcoin, keduanya beroperasi di atas jaringan *blockchain* dengan konsensus *proof of work* dan transaksi P2P [5], [14]. Perbedaan utama adalah ukuran blok, Bitcoin Cash memiliki ukuran blok 8 MB untuk meningkatkan kapasitas dan kecepatan transaksi, sedangkan Bitcoin hanya 1 MB, yang membatasi kapasitas dan memperlambat transaksi.




Gambar 1. Data time series harga bitcoin cash [16]

Selain perbedaan teknis, harga Bitcoin dan Bitcoin Cash juga berbeda. Bitcoin Cash tetap aman karena teknologi *blockchain* yang tidak dapat dimanipulasi dan menawarkan transaksi yang aman. Namun, tingginya minat menyebabkan harga Bitcoin menjadi sangat fluktuatif dan sulit diprediksi [15].

2.3. Deep Learning dan Peramalan


Peramalan merupakan proses memperkirakan suatu kejadian di masa yang akan datang menggunakan metode tertentu [17]. Salah satu metode yang bisa digunakan untuk peramalan adalah *deep learning*, yang secara khusus menggunakan jaringan saraf tiruan dengan banyak lapisan untuk secara otomatis memahami dan mengekstraksi pola rumit dari data. Deep learning mencerminkan cara kerja otak manusia, walaupun modelnya jauh lebih sederhana dibandingkan kompleksitas otak manusia. Dengan kemampuan pembelajaran yang baik pada pola data yang rumit, deep learning dapat efektif digunakan untuk meramalkan berbagai kejadian di masa depan tergantung pada data input yang diberikan [18]. Deep learning memiliki lebih banyak hidden layer dibandingkan model *machine learning* sederhana yang hanya memiliki satu layer. Hidden layer yang dimiliki pada deep learning berfungsi untuk mempelajari pola rumit pada data, terutama pada data non linier atau data tidak terstruktur untuk menghasilkan representasi yang lebih baik berdasarkan data latih dari data tersebut.



Gambar 2. perbedaan deep learning dan machine learning sederhana [19]

2.4. Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) merupakan salah satu arsitektur jaringan saraf tiruan yang berfungsi untuk mengatasi masalah menghilang dan meledaknya gradien pada arsitektur *Recurrent Neural Network* (RNN). LSTM sering digunakan pada tugas-tugas pemrosesan urutan data seperti data time series atau data teks. LSTM dapat mengingat informasi jangka panjang sehingga ini yang membedakannya dengan RNN konvensional. LSTM memiliki unit memori khusus atau disebut (*Cell State*) dan memiliki tiga gerbang (*gate*) yaitu *forget gate*, *input gate*, dan *output gate*.



Gambar 3. Arsitektur LSTM [20]

Berdasarkan Gambar 3. Dapat dilihat urutan proses pada arsitektur LSTM yaitu *forget gate* yang berfungsi untuk melupakan informasi yang tidak relevan pada vektor input (x_t) dan output jangka pendek pada langkah sebelumnya (h_{t-1}) melalui proses aktivasi sigmoid (σ). Maka jika ditulis persamaan matematis, akan jadi seperti berikut.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Yang dimana f_t merupakan *forget gate* (gerbang lupa), σ merupakan fungsi aktivasi sigmoid, W_f merupakan bobot pada *forget gate*, h_{t-1} , x_t merupakan penggabungan *output* vektor pada langkah waktu sebelumnya, dan b_f merupakan nilai bias dari *forget gate*.

Komponen selanjutnya yang berfungsi untuk mengupdate informasi baru dari hasil proses langkah waktu sebelumnya adalah *cell state* (sel memori). Pada cell ini, keputusan untuk mengingat atau melupakan informasi jangka panjang diputuskan melalui hasil *forget gate*. Sehingga, jika ditulis persamaan matematisnya akan jadi seperti berikut.

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2)$$

Yang dimana C_t merupakan sel memori, $\tanh$ merupakan fungsi aktivasi tangen hiperbolik, W_c merupakan bobot sel memori, $[h_{t-1}, x_t]$ merupakan penggabungan *output* vektor pada langkah waktu sebelumnya dengan *input* vektor baru, dan b_c merupakan bias pada sel memori.

Langkah selanjutnya yaitu *input gate* (gerbang masukan). Fungsi utama gerbang ini adalah memilih dan mengontrol seberapa banyak data yang akan dimasukkan pada sel memori. Persamaan untuk *input gate* sebagai berikut.

$$i_g = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

yang dimana i_g merupakan gerbang *input*, σ merupakan fungsi aktivasi *sigmoid*, W_i merupakan bobot pada *input gate*, $[h_{t-1}, x_t]$ merupakan penggabungan *output* vektor pada langkah waktu sebelumnya dengan *input* vektor baru, dan b_i merupakan bias pada *input gate*.

Kemudian hasil keluaran dari gerbang *input* akan menghasilkan sel memori baru dengan

kombinasi linier dari kandidat sel dan hasil keluaran dari gerbang lupa. Sehingga akan membentuk persamaan sebagai berikut.

$$C_t = f_t \cdot C_{t-1} + i_g \cdot C_t \quad (4)$$

Yang dimana C_t merupakan sel memori baru dan C_{t-1} sel memori pada langkah waktu sebelumnya.

Kemudian *forget gate* (gerbang lupa), berfungsi untuk mengontrol seberapa banyak informasi yang akan dikeluarkan dari sel memori untuk menjadi *output* selanjutnya. Persamaan untuk gerbang ini adalah sebagai berikut.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

Yang dimana O_t merupakan *output gate*, W_o merupakan bobot pada *output gate*, $[h_{t-1}, x_t]$ merupakan penggabungan *output* vektor pada langkah waktu sebelumnya dengan *input* vektor baru, dan b_o merupakan bias pada *output gate*.

Kemudian keluaran aktual (h_t) yang dihasilkan melalui proses sebelumnya memiliki persamaan sebagai berikut.

$$h_t = O_t \cdot \tanh(C_t) \quad (6)$$

yang dimana, (h_t) adalah *output* yang dihasilkan oleh sel LSTM pada waktu t , O_t adalah *output gate*, yang menentukan seberapa banyak informasi dari sel LSTM akan disampaikan ke *output* dan $\tanh(C_t)$ adalah nilai *cell state* yang telah diperbarui dan terkendali oleh gerbang *input* dan gerbang pengingat

2.5. Perhitungan Kesalahan

Untuk mengukur kesalahan atau nilai galat pada model yang dibuat, diperlukan evaluasi untuk mengukur sejauh mana model mampu melakukan peramalan dengan nilai galat yang rendah. Terdapat beberapa *metrix* yang bisa digunakan untuk mengukur nilai galat yang dihasilkan oleh model contohnya *Mean Squared Error* (MSE) [21]. Nilai MSE dapat dirumuskan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (7)$$

Yang mana n adalah jumlah data, x_i adalah nilai data sebenarnya, dan $\hat{x}_i$ adalah nilai peramalan.

Selain MSE, menghitung nilai galat bisa menggunakan *Root Mean Squared Error* (RMSE). RMSE merupakan akar kuadrat dari MSE, sehingga jika dirumuskan ke dalam persamaan akan menghasilkan persamaan sebagai berikut.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (8)$$


Jika dilihat dari persamaan (8), nilai RMSE mengkuadratkan nilai dari MSE. Dengan demikian dapat ditulis dengan persamaan berikut. Semakin

rendah nilai galat yang dihasilkan sebuah model, maka bisa dikatakan model tersebut melakukan peramalan dengan sangat baik [22].

3. Metode Penelitian

3.1. Alur Penelitian

Penelitian ini menggunakan data numerik sebagai bahan kajian yaitu data historis dari BCH-USD pada rentang waktu 2017 sampai 2024. Yang mana secara definisi, penelitian ini berarti menggunakan metode kuantitatif karena alasan pendekatan data yang digunakan. Adapun alur yang dilakukan pada penelitian ini seperti terdapat pada Gambar 4.



Gambar 4. Alur penelitian

Penjelasan alur penelitian seperti yang tertera pada Gambar 4. di atas adalah sebagai berikut:

a. Identifikasi Masalah

Identifikasi masalah pada penelitian ini melihat bagaimana peramalan pada data deret waktu untuk koin BCH-USD menggunakan *Long Short Term Memory* (LSTM) belum banyak dilakukan oleh peneliti sebelumnya. Fenomena ini berdasarkan hasil penelusuran informasi berupa jurnal terkait yang membahas tema tersebut.

b. Studi Literatur

Studi literatur merupakan proses yang penting dilakukan karena, untuk memperkaya pemberdayaan wawasan mengenai spesifik tema yang akan diangkat dalam penelitian ini melalui penelitian terdahulu yang mengangkat tema yang sama. Studi literatur yang dilakukan

yaitu mencari dan membaca jurnal mengenai LSTM dan belajar dari sumber-sumber lain yang membahas mengenai LSTM dan data *Time series*.

c. Pengambilan Data

Data yang digunakan pada penelitian ini diambil dari website *yahoo finance* yaitu berupa data historis Bitcoin Cash atau BCH-USD dari rentang 2017 sampai 2024. Data terdiri dari 7 kolom yaitu kolom, *Date*, *Open*, *High*, *Low*, dan *Close*, serta terdapat 2284 baris.

Tabel 1. Contoh Data BCH (USD).

Date	Close
2017-12-16	1801.88
2017-12-17	1862.88
2017-12-18	2196.64
2017-12-19	2805.89
2017-12-20	3923.07
2017-12-21	3267.17
2017-12-22	2696.69
2017-12-23	3257.08
2017-12-24	2903.12
2017-12-25	2954.69

d. Pra-Pengolahan Data

Setelah melewati proses pengambilan data, data kemudian dinormalisasikan dengan melakukan penskalaan antara rentang 0 dan 1. Penskalaan data penting untuk dilakukan dengan tujuan untuk menghasilkan proses pelatihan yang lebih stabil dan lebih cepat saat dalam proses komputasi. Normalisasi data yang digunakan menggunakan min-max scaller dengan persamaan seperti berikut.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (10)$$

Yang dimana X_{norm} merupakan nilai data yang dinormalisasi, X merupakan data yang dinormalisasi, X_{min} merupakan nilai terkecil dalam data, dan X_{max} merupakan nilai terbesar dalam data. Kemudian, untuk mengembalikan (*invers scalling*) nilai data menjadi bentuk aslinya dapat dilakukan dengan persamaan berikut.

$$X_a = X_{norm} * (X_{max} - X_{min}) + X_{min} \quad (11)$$

Yang dimana X_a merupakan nilai data asli.

e. Input Data

Setelah tahap pra-pengolahan data, data kemudian dimasukkan ke dalam lembar kerja atau *fream work* untuk diproses lebih dalam.

f. Pembagian Data Latih dan Validasi

Data kemudian dibagi menjadi dua yaitu data untuk pelatihan (*Training*) dan validasi. Pada penelitian ini data latih yang digunakan yaitu dari rentang tahun 26 Desember 2017 sampai 26 Maret 2014. Data latih yang digunakan yaitu sebanyak 2284 data *Closing* BCH dan validasi

yang dilakukan yaitu meramalkan data 7 hari berikutnya.

g. LSTM

Setelah melakukan proses sebelumnya, kemudian data dimasukkan ke dalam model LSTM untuk proses peramalan. LSTM mampu melakukan peramalan karena arsitekturnya memungkinkan untuk melakukan peramalan pada data deret waktu.

h. Hasil Analisis dan Evaluasi

Untuk mengukur keakuratan dari hasil peramalan, maka perlu dilakukan analisis dan evaluasi model. Evaluasi model yang akan dilakukan yaitu melihat dan meminimalisir nilai galat yang dihasilkan oleh model. Adapun perhitungan nilai galat pada penelitian ini menggunakan persamaan (7) dan persamaan (8).

4. Hasil dan Pembahasan

4.1. Akusisi Fitur pada Data

Data pada penelitian ini diambil dari *website* yahoo finance yaitu data historis Bitcoin Cash atau BCH-USD. Data terdiri dari 2 kolom yaitu kolom, *Date* dan *Close* yang dimana terdapat 2284 baris. Fitur data yang digunakan pada penelitian ini yaitu hanya fitur harga penutupan (*Close*) dari BCH-USD. Grafik harga penutupan dapat dilihat pada Gambar 5. Berikut.

Grafik Harga Bitcoin Cash (BCH)



Gambar 5. Grafik harga penutupan BCH

Gambar 5. merupakan harga penutupan (*Close*) BCH dari rentang 26 Desember 2017 sampai 26 Maret 2024 pada *time frame* harian. Harga tertinggi yang tercatat pada data tersebut terdapat tanggal 26 Desember 2017 dengan harga penutupan yaitu 3108.889893 USD dan harga penutupan terendah pada tanggal 15 Desember 2018 dengan harga penutupan yaitu 77.365776 USD. Fitur harga penutupan diambil sebagai data latih model peramalan karena merupakan informasi yang paling penting yang bisa digunakan sebagai acuan untuk meramalkan harga penutupan pada hari selanjutnya.

4.2. Analisis Losses pada Data Latih

Data latih yang digunakan seperti yang disebutkan pada halaman sebelumnya yaitu sebanyak 2284 data. Contoh data latih yang digunakan dapat dilihat pada Tabel 2.

Tabel 2. Contoh data latih.

Tanggal	Close
2024-03-22	431.536346
2024-03-23	456.816650
2024-03-24	484.753632
2024-03-26	488.045959
2024-03-26	489.794830

Tabel 2. merupakan contoh lima data dari harga penutupan BCH yang digunakan sebagai data untuk peramalan. Sebelum melakukan proses pelatihan, data terlebih dahulu dinormalisasi yang dapat dilakukan menggunakan persamaan (10). Tabel 3. berikut merupakan bentuk data yang sudah dinormalisasi menggunakan persamaan (10).

Tabel 3. Data setelah normalisasi.

Tanggal	Close
2024-03-22	0.116829
2024-03-23	0.125168
2024-03-24	0.134383
2024-03-26	0.135469
2024-03-26	0.136046

Tabel 3. di atas merupakan data setelah proses normalisasi menggunakan *min-max scaler*. Rentang jarak dari data tersebut yaitu antara 0 dan 1 dengan tujuan untuk mengefisiensi proses pelatihan model.

Setelah melalui proses normalisasi, kemudian dilakukan skenario pelatihan seperti yang terdapat pada Tabel 4.

Tabel 4. Skenario pelatihan.


Epoch	Hidden Layer	Panjang Sequence	RMSE
10	10	30	402.184
20	20	30	300.943
30	30	30	391.030
40	40	30	561.432
50	50	30	247.513

Tabel 4 menunjukkan skenario pelatihan untuk mendapatkan nilai *loss* terbaik. Skenario melibatkan peningkatan jumlah *epoch* hingga 50, yang berarti model telah mempelajari seluruh dataset sebanyak satu kali per *epoch*. Hal yang sama juga dilakukan untuk jumlah *hidden layer*, sementara panjang *sequence* disesuaikan untuk efisiensi pelatihan dan keterbatasan perangkat. Parameter yang lebih tinggi meningkatkan beban komputasi dan mempengaruhi kinerja perangkat. Hasil skenario menunjukkan nilai *loss* terendah 247.213 pada *epoch* dan *hidden layer* yang masing-masing berjumlah 50. Ketidakstabilan nilai *loss* disebabkan oleh pola data yang kompleks, dan menambah jumlah *epoch* dapat membantu, asalkan perangkat mendukung proses pelatihan.

4.3. Analisis Validasi (Hasil Peramalan)


Setelah melatih model, proses validasi menjadi diperlukan dengan tujuan menganalisis hasil peramalan harga penutupan BCH dalam tujuh

hari kedepan berdasarkan skenario yang dilakukan. Gambar 6. merupakan grafik perbandingan harga peramalan dan harga aktual penutupan BCH skenario pertama.



Gambar 6. Harga peramalan dan aktual penutupan BCH


Gambar 6. merupakan perbandingan harga peramalan (merah) dan harga aktual (biru) penutupan BCH yang dihasilkan dari pengujian skenario pertama. Parameter yang digunakan pada skenario pertama yaitu menggunakan *epoch* 10, *hidden layer* 10, dan panjang *sequence* 30 sehingga menghasilkan data peramalan penutupan BCH seperti yang dapat dilihat pada Gambar 6. Dari gambar di atas kita dapat melihat bahwa, harga peramalan yang paling mendekati harga aktual terjadi pada tanggal 1 Maret 2014 dengan selisih 5.79 angka. Nilai MSE yang dihasilkan sebesar 2179.75 USD², yang artinya angka tersebut menunjukkan tingkat kesalahan rata-rata kuadrat antara nilai peramalan dan harga aktual model. Angka tersebut cukup tinggi karena harga peramalan cukup jauh dengan harga aktualnya. Kemudian RMSE digunakan untuk menilai seberapa baik model prediksi mencocokkan data aktual, mirip dengan MSE, namun lebih mudah dipahami karena memiliki satuan yang sama dengan data asli. Nilai RMSE 46.68 USD menunjukkan bahwa rata-rata kesalahan hasil peramalan dan harga asli BCH sebesar 46.68 USD



Gambar 7. Harga peramalan dan aktual BCH skenario kedua


Gambar 7. merupakan grafik dari harga peramalan dan aktual BCH pada skenario kedua. Parameter yang digunakan pada skenario kedua yaitu, *epoch* 20, *hidden layer* 20, dan panjang *sequence* 30. Adapun nilai *losses* yang dihasilkan

berdasarkan perhitungan persamaan (7) dan (8) yaitu MSE= 1654.40 dan RMSE = 40.67



Gambar 8. harga peramalan dan aktual BCH skenario ketiga


Gambar 8. merupakan grafik dari harga peramalan dan aktual BCH pada skenario ketiga. Parameter yang digunakan pada skenario kedua yaitu, *epoch* 30, *hidden layer* 30, dan panjang *sequence* 30. Adapun nilai *losses* yang dihasilkan berdasarkan perhitungan persamaan (7) dan (8) yaitu MSE= 110655.39 dan RMSE = 332.64. Berdasarkan grafik di atas, dapat dilihat bahwa hasil peramalan sangat jauh dari data aktual dari penutupan BCH.



Gambar 9. Harga peramalan dan aktual BCH skenario keempat.

Gambar 9. merupakan grafik dari harga peramalan dan aktual BCH pada skenario keempat. Parameter yang digunakan pada skenario kedua yaitu, *epoch* 40, *hidden layer* 40, dan panjang *sequence* 30. Adapun nilai *losses* yang dihasilkan berdasarkan perhitungan persamaan (7) dan (8) yaitu MSE= 206606.12 dan RMSE = 454.53. Nilai *losses* yang tinggi menunjukkan bahwa hasil peramalan pada skenario keempat yang dilakukan tidak terlalu baik.

Perbedaan antara nilai MSE dan RMSE juga menunjukkan bahwa model memiliki variabilitas yang cukup besar dalam kesalahan prediksi, yang mengindikasikan adanya peluang untuk perbaikan model lebih lanjut. Dengan menurunkan nilai MSE dan RMSE, model dapat memberikan prediksi yang lebih dekat dengan nilai aktual, sehingga meningkatkan kehandalan peramalan.



Gambar 10. Harga peramalan dan aktual bch skenario kelima

Gambar 10. merupakan grafik dari harga peramalan dan aktual BCH pada skenario kelima. Parameter yang digunakan pada skenario kedua yaitu, *epoch* 50, *hidden layer* 50, dan panjang *sequence* 30. Adapun nilai *losses* yang dihasilkan berdasarkan perhitungan persamaan (7) dan (8) yaitu $MSE = 18649.99$ dan $RMSE = 136.56$.

Berdasarkan skenario yang dilakukan, hasil peramalan yang memiliki nilai *losses* paling rendah yaitu terdapat pada skenario kedua. Nilai *losses* yang rendah berarti hasil peramalan hampir mendekati nilai aktualnya. Tabel 5. merupakan selisih data data aktual dan peramalan yang dihasilkan oleh skenario kedua.

Tabel 5. Selisih data Aktual dan Peramalan Skenario Kedua (USD).

Tanggal	Harga Aktual	Harga Peramalan	Selisih
2024-03-27	539.79	541.52	1.73
2024-03-28	569.16	558.68	10.48
2024-03-29	621.78	574.15	47.63
2024-03-30	597.11	588.18	8.93
2024-03-31	680.42	599.51	80.91
2024-04-01	649.06	607.30	41.76
2024-04-02	689.14	610.35	78.79
Rata-rata			38.60

Hasil peramalan sangat dipengaruhi oleh parameter yang digunakan karena ini menentukan cara kerja jaringan dan kemampuan belajarnya dari data. Selain itu, jumlah data yang digunakan juga penting; semakin banyak data, semakin baik model dalam mempelajari informasi dan menghasilkan peramalan yang akurat.

Tabel 6. Nilai *losses* setiap skenario.

Skenario	MSE	RMSE
Pertama	2179.75	46.68
Kedua	1654.40	40.67
Ketiga	110655.39	332.64
Keempat	206606.12	454.53
Kelima	18649.99	136.56

Tabel 5. memberikan gambaran tentang performa model peramalan dalam lima skenario yang berbeda, diukur dengan nilai MSE dan RMSE. Dalam skenario pertama dan kedua, nilai MSE dan RMSE relatif rendah, menunjukkan tingkat kesalahan yang lebih rendah dalam memprediksi

harga. Namun, skenario ketiga dan keempat menampilkan nilai MSE dan RMSE yang jauh lebih tinggi, menandakan kesalahan yang signifikan dalam prediksi harga. Skenario kelima, meskipun memiliki nilai MSE dan RMSE yang lebih rendah dibandingkan dengan skenario ketiga dan keempat, tetap menunjukkan tingkat kesalahan yang cukup besar

5. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan, bahwa kesimpulan yang berhasil didapatkan yaitu: Model LSTM mampu melakukan peramalan dari data deret waktu BCH yang tidak linier jika melakukan prosedur yang tepat, seperti pengambilan data, sampai tahap validasi, Tingkat akurasi atau nilai *losses* terbaik yang dihasilkan oleh model untuk hasil peramalan yaitu terdapat pada skenario kedua, yang dimana menggunakan *epoch* 20, *hidden layer* 20, dan panjang *sequence* 30 dengan nilai MSE adalah 1654.40 dan RMSE adalah 40.67 USD, dan proyeksi harga peramalan BCH untuk tujuh hari kedepan yang paling mendekati harga aktualnya terdapat pada skenario kedua pada Gambar 7.

DAFTAR PUSTAKA

- [1] M. I. P. N. Hakim, Abdu Rahman. Nasution, "Eksistensi Transaksi Uang Digital Sebagai Alat Keuangan Modern Di Era Sekarang," *Ilmu Manaj.*, vol. Volume. 2, no. e-ISSN: 3025-440X; p-ISSN: 3025-4396, Hal 191-199 DOI: <https://doi.org/10.59603/ppiman.v2i1.304> Eksistensi, 2024.
- [2] P. Kinanti, R. Mahesa, F. Hariz, P. S. Ramadhani, and Y. Sobikhoh, "Melintasi Era Digital Dengan Menganalisis Hukum Cryptocurrency dan Blockchain Dalam Yurisprudensi Modern," vol. 4, pp. 920-932, 2023.
- [3] R. Verma, T. Nagar, and M. K. Sharma, "Cryptography encryption algorithm for augmented security □," vol. 050003, 2024.
- [4] Budi Dharma, Putri Gusniati, and Tria Wardani, "Analisis Pemanfaatan Cryptocurrency Bitcoin Sebagai Alat Alternatif Investasi," *J. Publ. Sist. Inf. dan Manaj. Bisnis*, vol. 2, no. 1, pp. 175-182, 2023, doi: 10.55606/jupsim.v2i1.858.
- [5] S. Nakamoto, "Bitcoin: Sebuah Sistem Uang Tunai Elektronik Peer-to-Peer," *Bitcoin*, pp. 1-10, 2008, [Online]. Available: www.bitcoin.org
- [6] H. Utama, "Pendekatan Deep Learning Menggunakan Metode Lstm Untuk Prediksi Harga Bitcoin," *Indones. J. Comput. Sci. Res.*, vol. 2, no. 2, pp. 43-50, 2023, doi: 10.59095/ijcsr.v2i2.77.

- [7] S. P. Ikrima and Surya Darmawan, "Analisis Volatily Spillover Bitcoin Terhadap Ethereum, Tether, dan Emas Dunia Menggunakan Metode EGARCH," *J. Manaj. dan Perbank.*, vol. 10, no. 2, pp. 47–60, 2023, doi: 10.55963/jumpa.v10i2.555.
- [8] I. Ramadhani, "Analisis Faktor-Faktor Yang Mempengaruhi Harga Cryptocurrency (Mata Uang Kripto) Di Indonesia Studi Pada Bitcoin," *EKOMA J. Ekon. Manajemen, Akunt.*, vol. 2, no. 1, pp. 46–54, 2022, doi: 10.56799/ekoma.v2i1.752.
- [9] A. Saepulrohman and S. Z. Pratama, "Prediksi Arah Harga Bitcoin Berdasarkan Manipulasi Metode Long Short-Term Memory (LSTM)," *INTERVAL J. Ilm. Mat.*, vol. 3, no. 1, pp. 15–24, 2023.
- [10] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1570–1580, 2021, doi: 10.35957/jatisi.v8i3.1159.
- [11] A. A. Ningrum, I. Syarif, A. I. Gunawan, E. Satriyanto, and R. Muchtar, "Algoritma Deep Learning-Lstm Untuk Memprediksi Umur Deep Learning-Lstm Algorithm for Power Transformer Lifetime," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 3, pp. 539–548, 2021, doi: 10.25126/jtiik.202184587.
- [12] I. Nurhaida, M. Sobiri, and S. Jaya, "Optimasi Prediksi Cryptocurrency Menggunakan Pendekatan Deep Learning," *JSIAI (Journal Sci. Appl. Informatics)*, vol. 6, no. 2, pp. 197–204, 2023, doi: 10.36085/jsai.v6i2.5288.
- [13] L. Wiranda and M. Sadikin, "Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma," *J. Nas. Pendidik. Tek. Inform.*, vol. 8, no. 3, pp. 184–196, 2019.
- [14] N. Tripathy, P. Satapathy, S. Hota, S. K. Nayak, and D. Mishra, "Empirical Forecasting Analysis of Bitcoin Prices : A Comparison of Machine Learning , Deep Learning , and Ensemble Learning Models," pp. 21–29.
- [15] M. A. S. Yudono *et al.*, "Bitcoin USD Closing Price (BTC-USD) Comparison Using Simple Moving Average And Radial Basis Function Neural Network Methods," *Fidel. J. Tek. Elektro*, vol. 4, no. 2, pp. 29–34, 2022, doi: 10.52005/fidelity.v4i2.74.
- [16] indodax, "Bitcoin Cash Market," *Indodax*, 2024. <https://indodax.com/market/BCHIDR> (accessed Feb. 27, 2024).
- [17] B. A. Septian and U. T. Kartini, "Pemodelan Peramalan Beban Jangka Pendek untuk Subsistem Krian Gresik Menggunakan Deep Learning LSTM-NN," *J. Tek. Elektro*, vol. 12, no. 2, pp. 1–5, 2023, doi: 10.26740/jte.v12n2.p1-5.
- [18] T. Bastian Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [19] S. Savalia and V. Emamian, "Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks," *Bioengineering*, vol. 5, no. 2, 2018, doi: 10.3390/bioengineering5020035.
- [20] S. Zaheer *et al.*, "A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model," *Mathematics*, vol. 11, no. 3, pp. 1–24, 2023, doi: 10.3390/math11030590.
- [21] R. Y. Hayuningtyas and T. Informatika, "Peramalan Persediaan Barang Menggunakan Metode Weighted Moving Average Dan Metode Double Exponential," vol. 13, no. 2, pp. 217–222, 2017.
- [22] N. Noor, K. Sari, R. Priskila, P. Bagus, and A. Anugrah, "IMPLEMENTASI CONTENT-BASED FILTERING MENGGUNAKAN TF-IDF AND COSINE SIMILARITY," vol. 18, no. 1, pp. 43–51, 2024.