

Optimising Bitcoin Price Forecasting Using Lstm, Gru, Prophet, Var, And Es Multi-Model Approaches

Anggito Karta Wijaya^{*1}, Amalan Fadil Gaib², I Gusti Ngurah Bagus Ferry Mahayudha³, Nurul Andini⁴, Tegar Fadillah Zanestri⁵

¹ Information Systems Department, Faculty of Computer Science, University of Jember, Indonesia

² Industrial Engineering Department, Faculty of Engineering, State University of Gorontalo, Indonesia

³ Informatics Department, Faculty of Mathematics and Natural Sciences, Udayana University, Indonesia

⁴ Information Systems and Technology Departement, Faculty of Engineering, State University of Jakarta, Indonesia

⁵ Informatics Engineering, Faculty of Engineering, Telkom University, Indonesia

Email: whafie7@gmail.com

Received : Nov 5, 2024; Revised : Nov 17, 2024; Accepted : Nov 27, 2024; Published : Jun 10, 2025

Abstract

This study aims to optimize Bitcoin price forecasting by integrating several multi-model approaches, including Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Prophet, as well as risk analysis using Value at Risk (VaR) and Expected Shortfall (ES). The daily Bitcoin price data from the period of July 17, 2010, to June 28, 2024, obtained from Kaggle, were analyzed using accuracy metrics such as Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE), as they provide a more objective and reliable evaluation of prediction effectiveness. The results show that the LSTM model performed the best, with an MSE of 535,419.12, RMSE of 731.72, MAE of 310.72, and MAPE of 159.01. The GRU model produced similar evaluation values with an MSE of 558,868.06 and RMSE of 747.57. In contrast, Prophet demonstrated lower performance, with an MSE of 59,309,927.76 and RMSE of 7,701.29. The risk analysis indicated that at a 95% confidence level, VaR reached 61,676.43, while ES reached 61,737.58, reflecting additional risk in extreme conditions. This study provides valuable insights into the advantages of the LSTM and GRU models for Bitcoin price forecasting, while also emphasizing the importance of risk analysis in supporting cryptocurrency investment decisions.

Keywords: *Bitcoin, ES, Forecasting, GRU, LSTM, Prophet, Risk Analysis, VaR.*

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Revolusi teknologi finansial mengalami lompatan signifikan dengan munculnya Bitcoin pada tahun 2009. Konsep ini pertama kali diperkenalkan melalui makalah berjudul *Bitcoin: A Peer-to-Peer Electronic Cash System* yang diterbitkan oleh entitas anonim bernama Satoshi Nakamoto [1]. Bitcoin merupakan wujud dari visi sistem keuangan terdesentralisasi yang beroperasi tanpa otoritas pusat, dengan mengandalkan kriptografi dan jaringan *peer-to-peer* untuk memvalidasi transaksi.

Dalam konteks Indonesia, Bitcoin dan mata uang kripto lainnya telah menarik perhatian yang besar. Bank Indonesia, sebagai otoritas moneter tertinggi, mendefinisikan Bitcoin sebagai aset digital yang

menerapkan teknologi blockchain untuk memfasilitasi transaksi langsung antara pengguna tanpa perantara pihak ketiga [2]. Fenomena ini telah menyebabkan peningkatan signifikan dalam partisipasi investor domestik, dengan data dari Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti) menunjukkan adanya ekspansi sebesar 83% dalam jumlah investor kripto [3].

Karakteristik volatilitas Bitcoin yang tinggi menimbulkan tantangan kompleks bagi pelaku pasar dan regulator. Sebuah studi komprehensif yang dilakukan oleh Wijaya et al. menggunakan model GARCH (Generalized Autoregressive Conditional Heteroskedasticity) untuk menganalisis volatilitas Bitcoin. Hasil penelitian mereka mengungkapkan bahwa fluktuasi harga Bitcoin yang ekstrem memiliki potensi untuk menyebabkan kerugian besar bagi investor individu dan dapat mengganggu stabilitas sistem keuangan nasional, dengan tingkat volatilitas mencapai 3,5 kali lipat dibandingkan aset tradisional [4]. Masalah ini menjadi fokus perhatian Otoritas Jasa Keuangan (OJK), yang menekankan urgensi penerapan strategi manajemen risiko yang efektif dalam konteks investasi aset kripto.

Salah satu isu mendasar dalam ekosistem Bitcoin adalah keterbatasan model peramalan konvensional dalam mengakomodasi kompleksitas pasar. Penelitian yang dilakukan oleh Putra dan Hakim menggunakan metode ARIMA (Autoregressive Integrated Moving Average) menunjukkan bahwa metodologi peramalan tradisional sering kali tidak mampu memprediksi dinamika harga Bitcoin dengan akurasi yang memadai, terutama selama periode volatilitas tinggi. Hasil penelitian mereka menunjukkan bahwa model ARIMA hanya mampu mencapai akurasi peramalan sebesar 65% untuk periode satu bulan ke depan [5].

Dalam upaya mengatasi keterbatasan tersebut, pendekatan multi-model yang mengintegrasikan berbagai teknik peramalan canggih muncul sebagai solusi potensial. Penelitian terbaru yang dilakukan oleh Suharto et al. menunjukkan bahwa sinergi antara model deep learning seperti Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dapat secara signifikan meningkatkan akurasi peramalan harga Bitcoin. Penelitian sebelumnya menggunakan data harga Bitcoin selama lima tahun dan mencapai akurasi peramalan hingga 89% untuk periode satu minggu ke depan [6]. Secara paralel, studi yang dilakukan oleh Wicaksono dan Astuti mengonfirmasi efektivitas model Prophet dalam mengidentifikasi pola musiman pada data harga historis Bitcoin. Dengan menggunakan data harian selama tiga tahun, model Prophet mereka mampu mendeteksi pola musiman mingguan dan bulanan dengan akurasi sebesar 78% [7].

Dalam ranah machine learning, relevansi pendekatan ekonometrik konvensional seperti Vector Autoregression (VAR) dan Exponential Smoothing (ES) tetap signifikan dalam analisis deret waktu finansial. Penelitian yang dilakukan oleh Hidayat dan Nugroho mengilustrasikan kemampuan model VAR dalam mengeksplorasi hubungan antara fluktuasi harga Bitcoin dan indikator makroekonomi Indonesia. Dengan menggunakan data bulanan selama dua tahun, model VAR mereka mampu menjelaskan 72% variasi harga Bitcoin berdasarkan perubahan nilai tukar rupiah, inflasi, dan indeks harga saham [8].

Berdasarkan kompleksitas intrinsik pasar Bitcoin, penelitian ini bertujuan untuk mengoptimalkan akurasi peramalan harga melalui penerapan pendekatan multi-model yang mengintegrasikan LSTM, GRU, Prophet, VAR, dan ES. Melalui konvergensi berbagai metodologi ini, diharapkan dapat menghasilkan proyeksi yang lebih akurat dan kuat, serta memberikan perspektif yang komprehensif mengenai dinamika harga Bitcoin dalam konteks pasar keuangan Indonesia.

Hasil penelitian ini diharapkan dapat memberikan kontribusi yang substansial tidak hanya bagi komunitas akademik, tetapi juga bagi pemangku kepentingan di sektor keuangan Indonesia. Bappebti, sebagai badan pengawas yang bertanggung jawab atas pengawasan perdagangan mata uang kripto di Indonesia, telah menekankan pentingnya inovasi dalam manajemen risiko dan teknik peramalan harga untuk melindungi kepentingan investor. Dalam laporan terbarunya, Bappebti menyoroti pentingnya pengembangan model peramalan yang dapat meningkatkan akurasi prediksi harga hingga 90% untuk periode satu bulan ke depan [9].

Sebagai langkah selanjutnya, penelitian ini akan mengeksplorasi berbagai teknik machine learning dan deep learning lainnya yang dapat diintegrasikan dalam sistem peramalan harga Bitcoin, termasuk penggunaan model ensemble yang menggabungkan beberapa metode untuk meningkatkan stabilitas dan ketepatan hasil peramalan [10]. Selain itu, penting untuk menggali lebih dalam mengenai penerapan teknik-teknik terbaru seperti *reinforcement learning* dalam meramalkan pergerakan harga jangka panjang, yang dapat menjadi inovasi penting di masa depan [11].

Selain itu, penekanan pada pentingnya pemilihan dan kualitas data dalam model peramalan juga tidak dapat diabaikan. Penelitian yang dilakukan oleh Aditya et al. menyoroti bahwa kualitas data historis yang digunakan dalam pelatihan model memiliki pengaruh besar terhadap akurasi prediksi, terutama dalam konteks peramalan harga Bitcoin yang sangat bergantung pada pola volatilitas yang tidak terduga [12]. Oleh karena itu, perlu dilakukan penyaringan dan pemrosesan data yang hati-hati agar model yang dikembangkan dapat menghasilkan prediksi yang lebih akurat.

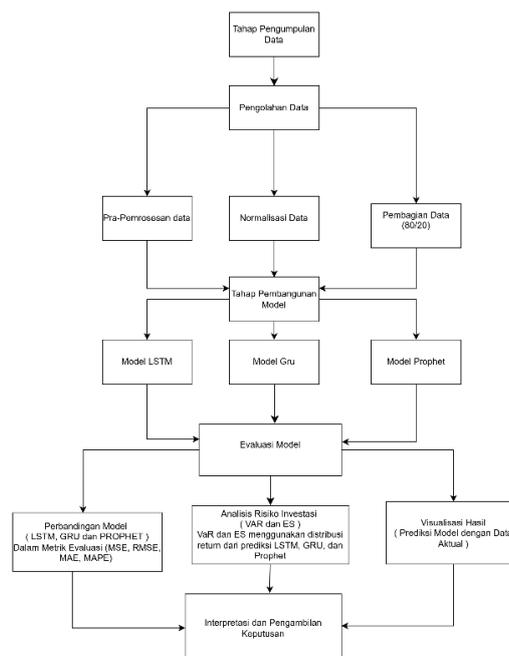
Teknologi blockchain yang mendasari Bitcoin dan mata uang kripto lainnya juga terus berkembang. Beberapa penelitian mengindikasikan bahwa integrasi teknologi blockchain dengan teknologi AI dapat mempercepat proses validasi transaksi dan memperkuat prediksi harga, mengurangi potensi manipulasi pasar, dan meningkatkan transparansi di seluruh ekosistem pasar kripto [13]. Penelitian ini berencana untuk mengeksplorasi potensi integrasi tersebut dalam meningkatkan hasil peramalan harga Bitcoin.

Akhirnya, peran pemerintah dan regulasi di Indonesia sangat penting dalam mendorong inovasi dan memastikan pasar Bitcoin beroperasi secara aman dan transparan. Sebuah studi oleh Rahardjo et al. menunjukkan bahwa kebijakan yang jelas dan regulasi yang ketat dapat memberikan rasa aman bagi investor dan mendorong perkembangan pasar kripto di Indonesia [14]. Penelitian ini akan membahas implikasi dari regulasi yang ada terhadap peramalan harga dan pengelolaan risiko di pasar Bitcoin.

Secara keseluruhan, penelitian ini bertujuan untuk memberikan kontribusi yang berarti bagi pengembangan teknik peramalan harga Bitcoin yang lebih canggih, dengan mengintegrasikan berbagai metodologi, teknologi, dan pendekatan baru yang dapat diterapkan untuk pasar keuangan Indonesia dan global di masa mendatang [15].

2. METODE PENELITIAN

Penelitian ini bertujuan untuk meramalkan fluktuasi harga Bitcoin menggunakan model prediktif canggih seperti LSTM, GRU, Prophet, VaR, dan ES. Metode penelitian meliputi pengumpulan data dari Kaggle, prapemrosesan data, pemilihan fitur, pelatihan model, dan evaluasi kinerja model menggunakan Visual Studio Code. Dataset yang digunakan mencakup data historis harga Bitcoin beserta variabel terkait yang memengaruhi fluktuasinya. Penelitian ini bertujuan menghasilkan model yang akurat dan andal dalam memprediksi pergerakan harga Bitcoin di masa depan, dengan evaluasi hasil analisis untuk mencapai tujuan penelitian.



Gambar 1. Diagram alir penelitian

Flowchart pada Gambar 1 menggambarkan metodologi penelitian untuk meramalkan harga Bitcoin menggunakan model pembelajaran mesin dan manajemen risiko. Proses dimulai dengan pengumpulan data harga Bitcoin harian dari Kaggle (2010-2024) dan tinjauan literatur terkait model LSTM, GRU, Prophet, VaR, dan ES. Selanjutnya, dilakukan prapemrosesan data, termasuk pembersihan, transformasi waktu, penanganan nilai hilang, dan normalisasi dengan Min-Max Scaler. Dataset dibagi menjadi data pelatihan (80%) dan pengujian (20%). Model deep learning LSTM dan GRU digunakan untuk data deret waktu, sementara Prophet untuk peramalan tren jangka panjang. Evaluasi model dilakukan dengan metrik MSE, RMSE, MAE, dan MAPE. Hasil dievisualisasikan untuk menilai kinerja model. Manajemen risiko diterapkan dengan model VaR dan ES untuk menghitung potensi kerugian. Penelitian ini menyajikan hasil prediksi dan analisis risiko terkait fluktuasi harga Bitcoin.

2.1 Pengumpulan Dataset

Data Pengumpulan data adalah tahap pertama dalam penelitian ini. Data harga Bitcoin diperoleh dari Kaggle, sebuah platform yang menyediakan berbagai macam dataset untuk keperluan analisis [10]. Tabel 1 di atas menunjukkan contoh dataset harga Bitcoin yang digunakan dalam penelitian ini. Dataset tersebut memiliki beberapa atribut penting seperti Start dan End yang menggambarkan rentang waktu dari setiap transaksi, Open yang menunjukkan harga pembukaan, High yang mencerminkan harga tertinggi, dan Low yang menunjukkan harga terendah pada setiap periode waktu tertentu, selain itu juga terdapat atribut Close yang merepresentasikan harga penutupan, serta Volume yang menunjukkan jumlah transaksi Bitcoin pada periode tersebut, dan Market Cap yang menunjukkan kapitalisasi pasar Bitcoin [10].

Table 1. Dataset Bitcoin

Start	End	Open	High	Low	Close	Volume	Market Cap
2024-06-27	2024-06-28	60882.90	6233.843	6066.619	61646.05	1.215887e+11	1.208392e+12
2024-06-26	2024-06-27	61733.99	6235.758	6076.124	60761.24	1.017576e+11	1.210544e+12
2024-06-25	2024-06-26	60317.99	6223.116	6027.258	61789.98	1.050312e+11	1.208415e+12
2024-06-24	2024-06-25	63168.03	6331.601	5894.624	60382.81	8.828355e+10	1.211101e+12
2024-06-23	2024-06-24	64276.04	6452.103	6329.043	63290.43	6.853945e+10	1.265327e+12

Dataset ini terdiri dari 5095 titik data dengan rentang waktu dari tahun 2010 hingga 2024 [10]. Data ini dipilih karena kelengkapan informasinya, yang memungkinkan penelitian ini untuk melakukan peramalan harga Bitcoin serta analisis volatilitas secara lebih komprehensif. Setiap perubahan signifikan pada harga Bitcoin dalam rentang waktu tersebut dapat digunakan untuk melatih model prediksi sehingga dapat mengidentifikasi pola tren yang berulang dan dalam.

2.2 Pra-Pemrosesan Data

Pada tahap pra-pemrosesan data, serangkaian langkah dilakukan untuk memastikan data siap digunakan dalam proses peramalan harga Bitcoin. Langkah pertama adalah transformasi tipe data, seperti mengubah format tanggal agar dapat diproses oleh model deret waktu. Selain itu, data diurutkan berdasarkan waktu untuk menjaga kesinambungan temporalnya. Langkah selanjutnya adalah interpolasi, yang digunakan untuk mengisi nilai yang hilang agar dataset tetap konsisten dan tidak ada kesenjangan dalam deret waktu yang dapat mempengaruhi kualitas prediksi [10].

2.3 Normalisasi Data

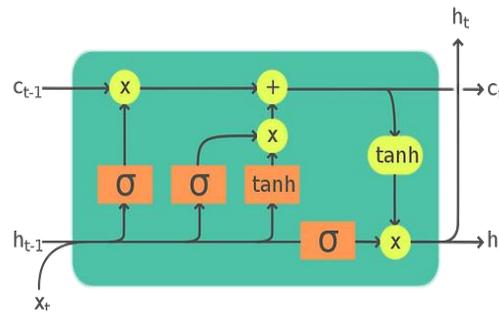
Pada proses normalisasi diterapkan pada data terutama untuk fitur-fitur seperti harga, volume, dan kapitalisasi pasar. Normalisasi ini bertujuan untuk menyesuaikan rentang nilai agar lebih sesuai untuk pelatihan model machine learning. Normalisasi dilakukan dengan menggunakan metode Min-Max Scaling, dimana nilai data dikonversi ke dalam rentang angka desimal dari 0 hingga 1. Hal ini penting dilakukan agar perbedaan skala antar fitur tidak mempengaruhi hasil pembelajaran model [11].

2.4 Pembagian Data

Setelah normalisasi data, data dibagi menjadi dua bagian: data training dan data testing. Pembagian ini dilakukan untuk melatih model pada data historis dan mengevaluasi performa model pada data yang belum pernah dilihat sebelumnya. Rasio yang digunakan dalam pembagian ini adalah 80:20, dimana 80% data digunakan untuk pelatihan model, sedangkan 20% sisanya dialokasikan untuk pengujian model [11]. Data training berfungsi sebagai dasar bagi model untuk memahami pola dalam deret waktu, sedangkan data testing digunakan untuk mengukur kemampuan generalisasi model pada data baru. Hal ini sangat penting untuk meminimalisir risiko overfitting, di mana model mempelajari terlalu banyak detail dari data pelatihan dan tidak dapat bekerja dengan baik pada data pengujian.

2.5 Implementasi Model LSTM dan GRU

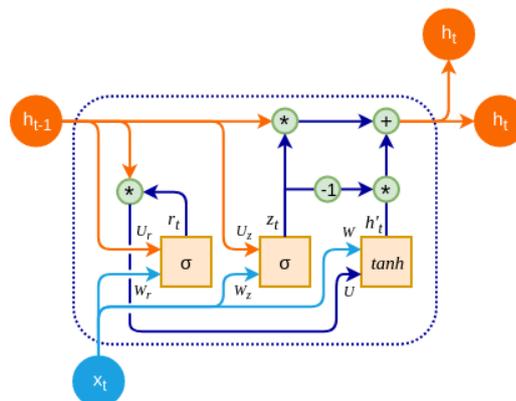
Model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) merupakan arsitektur jaringan saraf tiruan yang sangat cocok untuk digunakan dalam analisis deret waktu. LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, sedangkan GRU, yang merupakan varian yang lebih sederhana, diperkenalkan oleh Cho dan rekan-rekannya pada tahun 2014. Kedua model ini dirancang khusus untuk menangani ketergantungan temporal atau pola jangka panjang pada data time series, sehingga menjadi pilihan yang ideal untuk memprediksi pergerakan harga Bitcoin yang dinamis dari waktu ke waktu [12]. Struktur model LSTM terdiri dari tiga komponen utama yang disebut gerbang, yaitu Gerbang Lupa, Gerbang Masukan, dan Gerbang Keluaran. Masing-masing gerbang ini berfungsi untuk memutuskan informasi apa yang perlu disimpan, diingat, atau dibuang dari memori unit LSTM. Hal ini memungkinkan LSTM untuk menangkap dan menyimpan informasi jangka panjang yang penting untuk prediksi. Di sisi lain, GRU memiliki struktur yang lebih sederhana dibandingkan LSTM, hanya menggunakan dua gerbang, yaitu Update Gate dan Reset Gate, yang didesain untuk mempercepat proses komputasi tanpa mengorbankan kemampuan untuk menangkap hubungan temporal [13]. Sebelum menampilkan Gambar 2, berikut ini adalah penjelasan mengenai struktur internal Long Short-Term Memory (LSTM). LSTM adalah jenis jaringan syaraf tiruan yang dirancang untuk menangani urutan data berurutan dengan cara yang efisien. Pada gambar ini, komponen utama unit LSTM diperlihatkan, termasuk Gerbang Lupa, Gerbang Masukan, Gerbang Keluaran, dan Status Sel. Masing-masing komponen ini memiliki peran penting dalam mengelola aliran informasi, baik untuk mempertahankan data jangka panjang maupun untuk memproses informasi baru. Struktur ini memungkinkan LSTM untuk memodelkan pola yang kompleks dalam deret waktu atau data berurutan dengan akurasi yang lebih tinggi.



Gambar 2. Architecture of long short team memory (LSTM)

Pada Gambar 2, ditunjukkan struktur internal unit LSTM, yang terdiri dari beberapa komponen utama seperti Forget Gate, Input Gate, Output Gate, dan Cell State. Komponen-komponen ini bekerja bersama untuk memproses data berurutan atau deret waktu dengan cara yang memungkinkan model LSTM menangkap informasi jangka panjang dan jangka pendek dalam data. Arsitektur Long Short-Term Memory (LSTM) menggunakan serangkaian gerbang yang saling berhubungan menggunakan forget, Input, dan Output bersama dengan pembaruan status secara selektif memproses, menyimpan, dan mengeluarkan informasi dari data berurutan. Mekanisme ini memungkinkan jaringan untuk secara efektif menangkap ketergantungan jangka pendek dan jangka panjang. Rangkaian ini memastikan bahwa LSTM dapat secara selektif menyimpan informasi penting dari input terbaru dan sebelumnya, sehingga memungkinkannya untuk secara efektif memodelkan ketergantungan jangka panjang pada data yang berurutan.

Arsitektur Gated Recurrent Unit (GRU) terdiri dari dua gerbang utama, yaitu gerbang reset dan gerbang pembaruan. Gambar 3 mengilustrasikan bagaimana kedua gerbang ini berfungsi dalam struktur GRU. Gerbang reset menentukan berapa banyak informasi dari langkah sebelumnya yang harus dilupakan, sedangkan gerbang update mengontrol keseimbangan antara informasi baru dari input saat ini dan informasi lama yang tersimpan dalam keadaan tersembunyi. Keadaan tersembunyi pada waktu t , h_t , dihitung dengan menggabungkan informasi baru dari input saat ini x_t dengan informasi lama h_{t-1} . GRU didesain lebih sederhana daripada LSTM dengan hanya menggunakan dua gerbang tetapi tetap efektif dalam menangani ketergantungan temporal pada data yang berurutan.



Gambar 3. Architecture of gated recurrent unit (GRU)

Kedua model ini digunakan untuk meramalkan data berurutan dalam waktu, seperti deret waktu harga Bitcoin. Penggunaan utamanya adalah untuk memodelkan pola kompleks yang mungkin bersifat musiman atau jangka panjang. Keduanya juga mengatasi masalah gradien yang hilang yang sering menghambat kinerja jaringan saraf tradisional. Dalam konteks dataset Bitcoin, model LSTM dan GRU menerima data yang diurutkan berdasarkan waktu. Prosesnya melibatkan tahap input di mana data yang telah diproses dimasukkan ke dalam model dalam bentuk urutan, dan kemudian model dilatih untuk

mempelajari pola perubahan harga Bitcoin. Setelah proses pelatihan, model akan menghasilkan prediksi harga berdasarkan pola yang dipelajari dari data historis [12].

2.6 Implementasi Model Prophet

Prophet adalah model peramalan deret waktu yang dikembangkan oleh Facebook. Model ini sangat cocok untuk memprediksi data yang memiliki pola musiman yang kuat dan tren jangka panjang. Prophet bekerja dengan cara menguraikan data time series menjadi tiga komponen utama, yaitu trend, musiman, dan efek hari libur yang dapat mempengaruhi pola pergerakan data [12]. Prophet sangat efektif dalam menangani data yang memiliki missing value atau perubahan tren yang tiba-tiba, karena model dapat secara otomatis mendeteksi perubahan tren yang mungkin terjadi di masa depan. Struktur model Prophet memisahkan komponen trend, yang menggambarkan arah pergerakan data secara keseluruhan, dengan komponen musiman, yang menggambarkan pola fluktuasi yang berulang, baik harian, mingguan, maupun tahunan. Selain itu, Prophet juga memiliki kemampuan untuk menyesuaikan pergerakan data berdasarkan peristiwa tertentu, seperti hari libur atau peristiwa penting lainnya yang dapat mempengaruhi harga pasar, termasuk harga Bitcoin [12]. Model Prophet digunakan dalam penelitian ini untuk meramalkan pergerakan harga Bitcoin jangka menengah dan panjang. Dalam prosesnya, data harga Bitcoin dimasukkan ke dalam model Prophet, yang kemudian secara otomatis mendeteksi tren dan pola musiman dari data tersebut. Setelah itu, Prophet akan membuat prediksi harga dengan mempertimbangkan tren dan komponen musiman. Prophet juga menyediakan interval kepercayaan untuk mengukur ketidakpastian hasil prediksi. Dengan demikian, Prophet sangat berguna dalam menangkap pola musiman dan tren jangka panjang yang mungkin tidak terdeteksi oleh model lain seperti LSTM atau GRU [14].

2.7 Implementasi Model VAR dan ES

Value at Risk (VaR) dan Expected Shortfall (ES) merupakan dua metode manajemen risiko yang digunakan dalam penelitian ini untuk mengukur potensi risiko kerugian dalam pergerakan harga Bitcoin. VaR adalah pendekatan statistik yang digunakan untuk mengukur kerugian maksimum yang mungkin terjadi dengan tingkat kepercayaan tertentu (misalnya 95%) dalam jangka waktu tertentu. Sebaliknya, ES memberikan estimasi kerugian rata-rata yang mungkin terjadi di luar batas yang ditetapkan oleh VaR, terutama dalam kondisi pasar yang sangat tidak stabil [13]. Model VaR dan ES tidak berfokus pada prediksi harga, tetapi lebih kepada pengukuran risiko yang terkait dengan fluktuasi harga Bitcoin. Model ini digunakan untuk membantu investor atau manajer portofolio memahami potensi kerugian yang dapat mereka hadapi. Struktur kedua model ini melibatkan penghitungan return harian atau keuntungan/kerugian dari harga Bitcoin, dan kemudian memperkirakan distribusi statistik dari perubahan harga. Berdasarkan distribusi ini, VaR menghitung batas kerugian maksimum dengan tingkat kepercayaan tertentu, sedangkan ES memberikan estimasi kerugian rata-rata yang mungkin melebihi batas VaR [13]. Dalam implementasinya pada dataset Bitcoin, return dari perubahan harga harian Bitcoin terlebih dahulu dihitung. Kemudian, distribusi dari return tersebut dianalisis untuk menentukan batas kerugian maksimum (VaR) dengan tingkat kepercayaan 95%. ES juga dihitung untuk memperkirakan kerugian yang dapat terjadi dalam kondisi pasar yang sangat tidak stabil. VaR dan ES membantu penelitian ini dengan memberikan informasi mengenai potensi risiko yang terkait dengan pergerakan harga Bitcoin, terutama dalam menghadapi fluktuasi harga yang tiba-tiba dan tidak terduga [13].

2.8 Evaluasi Performa Model

Setelah model LSTM, GRU, Prophet, VaR, dan ES diaplikasikan, dilakukan evaluasi terhadap performa masing-masing model untuk mengetahui seberapa akurat prediksi yang dihasilkan. Beberapa metrik evaluasi yang digunakan dalam penelitian ini antara lain: Mean Squared Error (MSE) yang mengukur rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual. Root Mean Squared Error (RMSE), akar kuadrat dari MSE, memberikan indikasi yang lebih jelas tentang besarnya kesalahan prediksi. Mean Absolute Error (MAE) dapat mengukur rata-rata perbedaan absolut antara nilai prediksi dan aktual. Mean Absolute Percentage Error (MAPE) karena metrik ini mengukur seberapa besar kesalahan prediksi dalam bentuk persentase dibandingkan dengan nilai aktual [12]. Evaluasi ini

bertujuan untuk membandingkan kinerja model dalam hal akurasi prediksi dan kemampuan untuk menangkap pola jangka panjang dan risiko pasar.

3. HASIL DAN ANALISIS

Pada tahapan kali ini menjelaskan secara rinci model yang digunakan, parameter yang diterapkan, dan optimasi yang dilakukan untuk meningkatkan kinerja model dalam penelitian ini. Dua model digunakan dalam penelitian ini, yaitu model deep learning dengan kombinasi lapisan Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), serta model Prophet yang dikembangkan oleh Meta. Kedua model ini digunakan untuk melakukan prediksi dan mengevaluasi kinerja model berdasarkan nilai kesalahan (error) yang dihasilkan setelah prediksi dilakukan. Informasi yang diperoleh kemudian digunakan untuk membandingkan kinerja kedua model tersebut.

Model deep learning yang digunakan memiliki arsitektur kombinasi lapisan LSTM dan GRU yang dioptimalkan dengan algoritma optimasi Adam. Adam, atau Adaptive Moment Estimation, dikenal sebagai algoritma yang efisien dan memiliki kinerja yang baik dalam berbagai tugas optimasi. Pada proses pelatihan model, penelitian ini menggunakan 50 epoch dan ukuran batch (batch size) sebesar 64. Fungsi kerugian (loss function) yang digunakan adalah Mean Squared Error (MSE), yang berfungsi untuk mengukur kesalahan pada setiap epoch. Nilai kesalahan ini kemudian digunakan oleh algoritma Adam untuk memperbarui parameter model, sehingga dapat meningkatkan akurasi prediksi.

Model kedua yang digunakan dalam penelitian ini adalah model peramalan Prophet dari Meta. Prophet menggunakan pendekatan mirip regresi untuk memprediksi data deret waktu dan dirancang untuk menangani permasalahan umum dalam analisis deret waktu, seperti pola musiman dan permasalahan non-linear yang sering muncul. Dengan menggunakan pendekatan prediksi Prophet, penelitian ini bertujuan untuk memahami pola-pola musiman dan fluktuasi yang kompleks dalam data.

3.1. Evaluasi Model LSTM

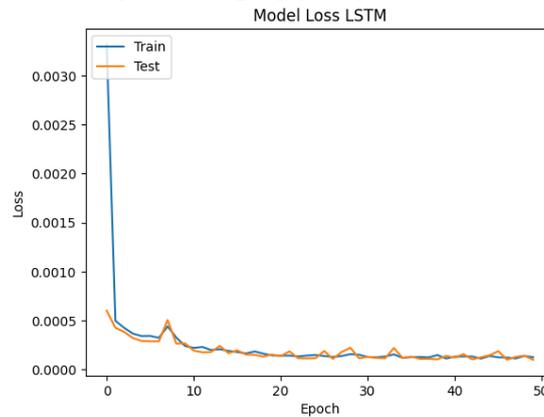
Pada tahapan ini, dijelaskan hasil evaluasi performa model LSTM yang digunakan untuk memprediksi harga Bitcoin. Evaluasi dilakukan untuk memahami sejauh mana model LSTM mampu menghasilkan prediksi yang akurat serta mendekati harga aktual Bitcoin. Dengan analisis yang mendalam pada arsitektur model, grafik loss selama proses pelatihan, dan perbandingan antara harga aktual dengan hasil prediksi, diharapkan dapat diketahui kekuatan dan kelemahan model ini dalam menangkap pola waktu pada data harga Bitcoin. Penggunaan LSTM dalam penelitian ini didasari oleh kemampuannya dalam mengenali pola data deret waktu yang kompleks, yang sesuai dengan karakteristik fluktuasi harga Bitcoin yang cenderung volatile.

Tabel 2 menampilkan arsitektur model LSTM yang telah dirancang secara khusus untuk penelitian ini. Model ini terdiri dari dua lapisan LSTM berturut-turut dengan jumlah neuron 100 dan 50, yang diikuti oleh dua lapisan Dense untuk mengonversi hasil keluaran menjadi prediksi harga akhir. Dengan total parameter sebesar 72.301, model ini dioptimalkan secara penuh agar dapat memprediksi harga dengan akurasi tinggi. Struktur berlapis pada model memungkinkan LSTM untuk menangkap pola data waktu yang kompleks dan mengurangi kesalahan prediksi yang disebabkan oleh variabilitas harga. Setiap lapisan berfungsi sebagai alat untuk menyaring informasi penting dari data historis Bitcoin, sehingga model mampu memberikan prediksi yang lebih tepat.

Tabel 2. LSTM Arsitektur Model

Layer (Type)	Output Shape	Param #
lstm_ (LSTM)	(None, 60,100)	40800
Lstm_1 (LSTM)	(None, 50)	30200
dense_ (Dense)	(None, 25)	1275
dense_1 (Dense)	(None, 1)	26

Pada gambar 4 menunjukkan grafik loss model selama proses pelatihan, baik pada data latih maupun data uji selama 50 epoch. Pada grafik ini, terlihat bahwa nilai loss mengalami penurunan signifikan pada beberapa epoch awal, yang kemudian stabil seiring bertambahnya jumlah epoch. Kurva loss yang stabil menunjukkan bahwa model berhasil mencapai konvergensi tanpa mengalami overfitting, yang berarti model mampu belajar pola data dengan baik tanpa kehilangan generalisasi pada data uji. Nilai loss yang rendah baik pada data latih maupun data uji mengindikasikan bahwa model telah terlatih secara optimal dan mampu menangkap pola pada data deret waktu secara akurat.



Gambar 4. Model Loss LSTM

Pada gambar 5 memperlihatkan perbandingan antara harga aktual Bitcoin dengan hasil prediksi dari model LSTM. Pada grafik ini, garis biru mewakili harga aktual, sementara garis hitam menggambarkan hasil prediksi dari model. Secara keseluruhan, garis prediksi mengikuti pola harga aktual dengan cukup akurat, khususnya dalam menangkap tren utama dan fluktuasi harga yang terjadi dalam periode penelitian. Kesamaan pola ini menunjukkan bahwa model LSTM mampu mengenali dan mempelajari pola waktu yang terjadi pada harga Bitcoin, sehingga memberikan prediksi yang mendekati nilai harga sesungguhnya.



Gambar 5. Perbandingan LSTM vs Data Aktual

Berdasarkan penelitian terkait evaluasi kinerja algoritma LSTM dapat disimpulkan bahwa model LSTM memiliki performa yang cukup baik dalam memprediksi harga Bitcoin. Arsitektur model yang tepat, hasil grafik loss yang stabil, serta kedekatan antara prediksi dan harga aktual menunjukkan bahwa model ini mampu menangkap pola harga Bitcoin dengan akurat. Evaluasi ini menunjukkan potensi LSTM sebagai alat prediksi yang andal dalam analisis pasar keuangan, terutama dalam menghadapi fluktuasi harga yang dinamis seperti pada aset kripto.

3.2. Evaluasi Model GRU

Pada tahap ini, hasil evaluasi kinerja model GRU dalam memprediksi harga Bitcoin dijelaskan secara rinci. Evaluasi ini bertujuan untuk menilai sejauh mana model GRU mampu menghasilkan prediksi yang akurat dan mendekati nilai harga aktual Bitcoin. Melalui analisis arsitektur model, grafik

loss selama proses pelatihan, serta perbandingan antara harga aktual dan prediksi model, diharapkan dapat diidentifikasi kelebihan dan kekurangan model dalam menangkap pola waktu pada data harga Bitcoin. Pemilihan model GRU dalam penelitian ini didasarkan pada kemampuannya dalam mengenali pola yang kompleks dalam data deret waktu, yang cocok dengan karakteristik pergerakan harga Bitcoin yang fluktuatif dan cenderung volatil.

Pada tabel 3 menunjukkan arsitektur jaringan model GRU yang digunakan dalam penelitian ini. Model ini terdiri dari dua lapisan GRU, di mana lapisan pertama memiliki 100 unit dan lapisan kedua memiliki 50 unit. Setelah kedua lapisan GRU, terdapat dua lapisan Dense, yaitu lapisan Dense pertama dengan 25 unit dan lapisan Dense kedua yang berfungsi sebagai lapisan keluaran dengan 1 unit. Jumlah total parameter yang dapat dilatih dalam model ini adalah 55.001, yang menunjukkan bahwa keseluruhan parameter dapat dioptimalkan selama proses pelatihan. Dengan arsitektur seperti ini, model GRU diharapkan mampu menangkap pola dan tren kompleks pada data historis harga yang digunakan.

Tabel 3. GRU Arsitektur Model

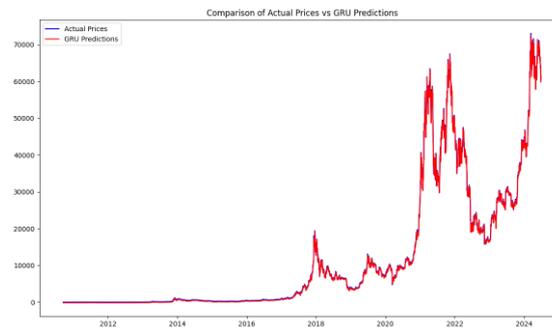
Layer (Type)	Output Shape	Param #
gru (GRU)	(None, 60,100)	30900
gru_1 (GRU)	(None, 50)	22800
dense_2 (Dense)	(None, 25)	1275
dense_3 (Dense)	(None, 1)	26

Pada tahap evaluasi kinerja model GRU, Gambar 6 memvisualisasikan nilai loss selama proses pelatihan untuk data train dan test. Grafik ini memperlihatkan bahwa pada epoch pertama, terjadi penurunan nilai loss yang sangat signifikan pada data train, diikuti dengan stabilitas pada epoch-epoch berikutnya. Setelah beberapa epoch awal, nilai loss pada data train dan test menunjukkan tren yang stabil dengan nilai yang rendah, mengindikasikan bahwa model GRU mampu mempelajari data dengan baik tanpa menunjukkan tanda-tanda overfitting atau underfitting yang berarti. Stabilitas ini mencerminkan performa yang baik dari model GRU selama proses pelatihan.



Gambar 6. Model Loss GRU

Pada gambar 7 menampilkan perbandingan antara harga aktual dan hasil prediksi yang dihasilkan oleh model GRU. Pada grafik ini, garis biru merepresentasikan harga aktual, sementara garis merah menunjukkan hasil prediksi yang diperoleh dari model GRU. Terlihat bahwa garis prediksi mengikuti pergerakan harga aktual dengan baik, menunjukkan bahwa model GRU memiliki kemampuan yang cukup dalam menangkap pola temporal pada data harga. Hasil ini mengindikasikan bahwa model GRU mampu memprediksi pergerakan harga dengan tingkat akurasi yang tinggi, sehingga memberikan hasil yang dapat diandalkan dalam analisis prediktif harga untuk periode selanjutnya.



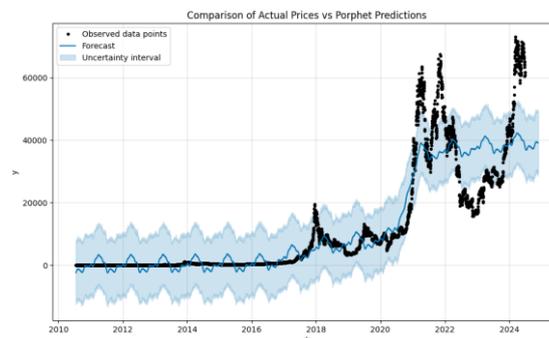
Gambar 7. Perbandingan GRU vs Data Aktual

Berdasarkan penelitian terkait evaluasi kinerja model GRU menunjukkan kinerja yang baik dalam memprediksi harga Bitcoin. Arsitektur model yang terdiri dari dua lapisan GRU memungkinkan pembelajaran pola kompleks, dan grafik loss menunjukkan stabilitas serta konvergensi tanpa overfitting. Hasil prediksi model juga sangat mendekati harga aktual, menunjukkan akurasi yang tinggi dalam menangkap fluktuasi harga. Secara keseluruhan, model GRU dinilai andal untuk prediksi harga Bitcoin meskipun peningkatan kinerja dapat dicapai melalui tuning hyperparameter atau penambahan data pelatihan.

3.3. Evaluasi Model Prophet

Pada tahapan penelitian ini, evaluasi kinerja model Prophet dilakukan untuk memprediksi pergerakan harga dengan membandingkan hasil prediksi model dengan data aktual. Evaluasi ini mencakup analisis arsitektur model Prophet, grafik yang menggambarkan loss selama proses pelatihan, dan perbandingan visual antara harga aktual dengan prediksi yang dihasilkan oleh model.

Pada gambar 8, ditampilkan perbandingan antara harga aktual dan hasil prediksi model Prophet. Titik-titik hitam merepresentasikan data historis atau harga aktual dari tahun 2010 hingga 2024, sedangkan garis biru menunjukkan hasil prediksi model Prophet. Area berwarna biru muda menggambarkan interval ketidakpastian (uncertainty interval), yang mencerminkan tingkat keyakinan model terhadap prediksi yang dibuat. Secara umum, model Prophet mampu mengikuti tren jangka panjang yang terjadi dalam data historis, terutama lonjakan harga yang mulai terjadi sekitar tahun 2017. Namun, terdapat beberapa periode di mana prediksi tampak kurang akurat, khususnya selama fluktuasi harga yang tajam.

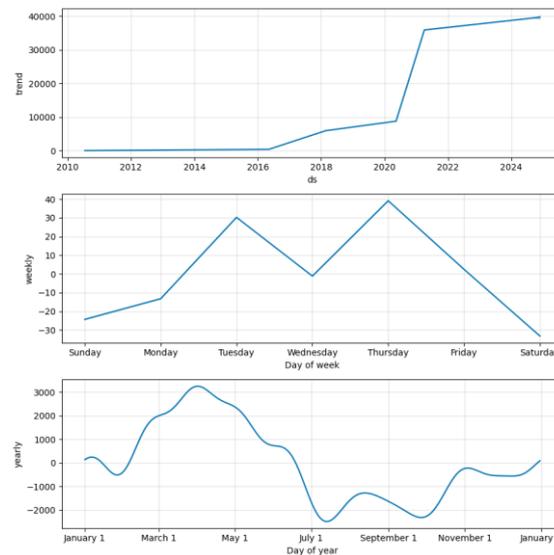


Gambar 8. Perbandingan Harga Aktual dengan Prediksi Model Prophet

Pada gambar 9, terlihat komponen-komponen prediksi yang dihasilkan oleh model Prophet, yaitu tren, pola musiman mingguan, dan pola musiman tahunan. Grafik pertama menunjukkan komponen tren yang menggambarkan peningkatan harga yang signifikan mulai sekitar tahun 2018. Peningkatan ini mencerminkan pola jangka panjang yang ditangkap oleh model, di mana harga menunjukkan kecenderungan untuk terus naik selama periode tersebut, tanpa dipengaruhi oleh variasi mingguan atau tahunan.

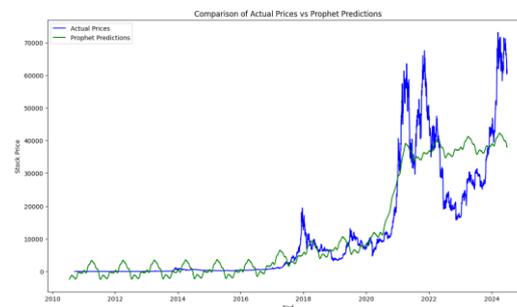
Grafik kedua memperlihatkan pola musiman mingguan, yang menunjukkan fluktuasi harga berdasarkan hari dalam seminggu. Pada pola ini, harga cenderung turun pada awal pekan (Senin hingga Rabu) dan kembali naik pada hari Kamis. Hal ini mengindikasikan adanya pola musiman mingguan yang konsisten dan berulang, yang mungkin disebabkan oleh perilaku pasar atau aktivitas perdagangan yang lebih intens pada hari-hari tertentu dalam seminggu.

Grafik ketiga menunjukkan pola musiman tahunan, yang mengindikasikan adanya fluktuasi harga sepanjang tahun. Pola ini memperlihatkan titik-titik puncak dan penurunan yang cenderung berulang pada periode tertentu setiap tahun, yang mungkin terkait dengan siklus ekonomi atau faktor tahunan lainnya. Analisis dari ketiga komponen ini memberikan wawasan yang lebih dalam tentang bagaimana faktor temporal jangka pendek dan panjang mempengaruhi prediksi harga yang dihasilkan oleh model Prophet.



Gambar 9. Analisis Komponen Prediksi Prophet

Pada gambar 10, diperlihatkan kembali perbandingan antara harga aktual dengan prediksi Prophet namun dalam skala yang lebih fokus. Garis biru menunjukkan harga aktual, sementara garis hijau adalah hasil prediksi Prophet. Pada gambar ini terlihat bahwa meskipun Prophet dapat menangkap pola umum dari tren harga, ada beberapa periode di mana prediksi model cukup jauh dari harga aktual, khususnya saat harga mengalami kenaikan atau penurunan yang ekstrem. Visualisasi ini membantu dalam melihat tingkat akurasi model Prophet secara keseluruhan.



Gambar 10. Analisis Komponen Prediksi Prophet

3.4. Analisis Resiko VAR Dan ES

Pada analisis risiko investasi ini, digunakan pendekatan Value at Risk (VaR) dan Expected Shortfall (ES) untuk mengukur potensi kerugian maksimum yang dapat terjadi dalam portofolio bitcoin pada tingkat kepercayaan 95%. Dalam konteks ini, VaR berfungsi untuk memberikan batas kerugian maksimal yang mungkin terjadi pada kondisi pasar normal, sementara ES memberikan perkiraan kerugian rata-rata pada kondisi ekstrem yang melampaui batas VaR.

Pada tabel 4 nilai ES untuk setiap model selalu lebih tinggi daripada nilai VaR, yang sejalan dengan prinsip dasar bahwa ES harus lebih besar untuk mencerminkan risiko yang lebih besar pada kondisi ekstrem. Model Prophet menunjukkan nilai VaR dan ES tertinggi dibandingkan dengan model LSTM dan GRU, yang menunjukkan potensi kerugian lebih besar pada skenario ekstrem.

Tabel 4. Analisis Resiko VAR dan ES terhadap Model

Model	VaR (95%)	ES (95%)
LSTM	0.049278	0.148473
GRU	0.057583	0.124465
Prophet	0.112363	0.428139

Secara keseluruhan, nilai VaR rata-rata pada tingkat kepercayaan 95% adalah 0.0630, sedangkan nilai ES rata-rata adalah 0.1100. Dalam konteks harga, tingkat harga yang sesuai dengan VaR adalah 61,676.43, sedangkan untuk ES pada tingkat kepercayaan yang sama adalah 61,737.58. Hasil ini memberikan gambaran yang lebih mendalam mengenai risiko investasi, di mana nilai ES yang lebih tinggi dibandingkan VaR menunjukkan adanya potensi kerugian yang lebih besar pada kondisi pasar yang tidak menguntungkan. Analisis ini penting bagi investor untuk memahami risiko terburuk yang mungkin dihadapi dan untuk merancang strategi mitigasi risiko yang tepat.

3.5. Evaluasi Perbandingan Multi Model

Evaluasi perbandingan multi-model ini bertujuan untuk menganalisis kinerja model Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Prophet dalam memprediksi harga Bitcoin serta untuk mengevaluasi risiko investasi melalui metode Value at Risk (VaR) dan Expected Shortfall (ES). Masing-masing model diterapkan untuk mengantisipasi perubahan harga Bitcoin dalam periode tertentu dan dibandingkan terhadap data harga aktual.

Dalam grafik yang dihasilkan, terlihat bahwa ketiga model menunjukkan pola prediksi yang berbeda. Model LSTM dan GRU cenderung mengikuti pergerakan harga Bitcoin dengan lebih baik dalam fase-fase volatilitas tinggi, sementara model Prophet terlihat lebih stabil tetapi kurang responsif terhadap perubahan harga yang ekstrem. Hal ini menunjukkan karakteristik masing-masing model dalam menangkap pola data historis dan mengantisipasi fluktuasi pasar.

Pengukuran risiko investasi dilakukan dengan menghitung VaR dan ES pada tingkat kepercayaan 95%. Garis VaR yang ditampilkan pada level harga 61,676.43 merepresentasikan nilai kerugian maksimum yang diperkirakan tidak akan terlampaui dalam kondisi pasar normal sebanyak 95% dari waktu. Sedangkan ES, yang ditampilkan pada level harga 61,737.58, mencerminkan estimasi kerugian rata-rata yang terjadi jika kerugian melebihi batas VaR, mencakup kondisi pasar yang lebih ekstrem.

Perbedaan antara nilai VaR dan ES ini penting untuk diperhatikan dalam konteks manajemen risiko investasi pada aset volatil seperti Bitcoin. Sebagai contoh, hasil yang ditunjukkan pada grafik memperlihatkan bahwa nilai ES lebih tinggi dari VaR, yang berarti risiko kerugian dalam kondisi pasar ekstrem bisa melampaui batas VaR yang telah ditentukan. Kondisi ini memperingatkan investor tentang potensi kerugian yang lebih besar di luar ekspektasi standar risiko.

Gambar 11 di bawah ini memperlihatkan perbandingan antara prediksi harga dari model LSTM, GRU, dan Prophet dengan data harga aktual Bitcoin, serta menampilkan batasan risiko investasi yang diukur menggunakan VaR dan ES. Grafik ini memberikan gambaran visual mengenai kemampuan setiap model dalam memprediksi tren harga dan membantu memahami risiko investasi yang terukur dalam VaR dan ES.



Gambar 11. Perbandingan Prediksi LSTM, GRU, Prophet dengan Harga Aktual Bitcoin, serta Batasan VaR dan ES.

Pada perbandingan model yang digunakan yaitu LSTM, GRU, dan Prophet, diimplementasikan untuk memprediksi harga Bitcoin dalam 150 hari ke depan. Hasil prediksi ini menunjukkan variasi estimasi harga dari masing-masing model pada beberapa titik waktu tertentu. Model LSTM dan GRU menghasilkan nilai prediksi yang relatif lebih tinggi dibandingkan Prophet, yang menunjukkan kecenderungan harga yang lebih rendah.

Pada tabel 5 yang dimana prediksi dari model LSTM dan GRU menunjukkan peningkatan harga Bitcoin yang signifikan selama periode 150 hari tersebut, dengan nilai prediksi yang sangat mendekati satu sama lain. Kedua model ini tampaknya lebih responsif terhadap tren kenaikan harga yang diindikasikan oleh data historis. Di sisi lain, model Prophet menghasilkan prediksi yang lebih konservatif dengan fluktuasi yang lebih kecil, mencerminkan asumsi stabilitas yang lebih kuat dan mungkin kurang sensitif terhadap perubahan tren jangka pendek. Perbedaan antara prediksi ketiga model ini memberikan wawasan yang berharga dalam analisis risiko dan strategi investasi. Jika dibandingkan dengan batasan risiko yang diukur sebelumnya menggunakan VaR dan ES, prediksi dari LSTM dan GRU yang lebih tinggi menunjukkan potensi peningkatan risiko dalam kondisi pasar yang berfluktuasi. Sedangkan Prophet, dengan nilai prediksi yang lebih rendah, menunjukkan pendekatan yang lebih berhati-hati dan mungkin cocok untuk strategi yang menghindari eksposur risiko tinggi.

Tabel 5. Analisis Resiko VAR dan ES terhadap Model

Tanggal	Prediksi LSTM	Prediksi GRU	Prediksi Prophet
2024-06-30	62,460.74	62,415.74	37,829.30
2024-07-31	64,314.14	64,236.55	37,594.85
2024-08-31	79,864.68	79,474.41	37,846.29
2024-09-30	86,719.24	85,532.70	37,798.12
2024-10-31	88,768.99	87,115.74	37,316.11
2024-11-30	89,363.22	87,504.60	39,408.48

Kesimpulannya, berdasarkan hasil peramalan 150 hari ke depan, model LSTM dan GRU memberikan prediksi harga Bitcoin yang lebih tinggi dan konsisten dengan tren kenaikan, sementara model Prophet memproyeksikan harga yang lebih rendah. Jika harga Bitcoin saat ini berada di kisaran 60,000 hingga 70,000, maka LSTM atau GRU lebih mendekati harga aktual, sedangkan Prophet lebih akurat jika harga Bitcoin turun atau stagnan di bawah 40,000. Investor dapat memilih model sesuai dengan profil risiko mereka, dengan LSTM dan GRU cocok untuk investor yang siap menghadapi volatilitas tinggi, sementara Prophet lebih sesuai bagi yang mengutamakan kestabilan dan pengendalian risiko.

Untuk penelitian lanjutan, disarankan untuk mengoptimalkan model dengan metode seperti optimasi hyperparameter menggunakan Grid Search atau Bayesian Optimization untuk meningkatkan akurasi prediksi. Selain itu, memasukkan variabel tambahan seperti data transaksi blockchain atau sentimen pasar dari media sosial dapat memberikan wawasan yang lebih mendalam terkait pergerakan harga Bitcoin. Penelitian juga dapat mengembangkan model ensemble yang menggabungkan berbagai

pendekatan untuk meningkatkan robustitas dan performa prediksi dalam kondisi pasar yang lebih dinamis.

4. DISKUSI

Penelitian ini telah berhasil mengintegrasikan berbagai pendekatan prediksi harga Bitcoin, yakni LSTM, GRU, Prophet, VAR, dan ES, untuk mendapatkan gambaran yang lebih komprehensif tentang dinamika harga aset kripto yang sangat volatil. Hasil penelitian menunjukkan bahwa LSTM dan GRU unggul dalam memprediksi pola jangka pendek, sebagaimana tercermin dari nilai MSE dan RMSE yang lebih rendah dibandingkan Prophet. Model berbasis deep learning seperti LSTM dan GRU efektif dalam menangkap pola temporal yang kompleks pada aset berisiko tinggi [6].

Sementara itu, Prophet menunjukkan kinerja yang baik dalam menangkap tren jangka panjang dan pola musiman [7]. Dalam penelitian ini, Prophet secara akurat mendeteksi tren musiman pada data harga Bitcoin, meskipun kurang responsif terhadap fluktuasi harga yang ekstrem. Model ini menunjukkan keunggulan untuk analisis tren yang lebih stabil, yang penting bagi investor dengan profil risiko rendah.

VAR tetap relevan sebagai pendekatan ekonometrik konvensional, terutama dalam mengidentifikasi hubungan antara harga Bitcoin dan variabel makroekonomi [8]. Model ini mampu menjelaskan sebagian besar variasi harga berdasarkan indikator ekonomi, yang memberikan konteks lebih luas dalam analisis pasar.

Dalam konteks manajemen risiko, penghitungan VaR dan ES pada tingkat kepercayaan 95% memberikan wawasan tentang potensi kerugian maksimum dan rata-rata pada skenario ekstrem. Sejalan dengan temuan sebelumnya, nilai ES yang lebih tinggi dari VaR menunjukkan tingkat risiko tambahan pada kondisi pasar yang tidak menguntungkan. Hasil ini memberikan nilai praktis bagi pengambilan keputusan investasi, khususnya dalam mengantisipasi volatilitas yang signifikan pada aset kripto seperti Bitcoin.

Penelitian ini memperluas temuan-temuan sebelumnya dengan menunjukkan bahwa pendekatan multi-model tidak hanya memberikan hasil prediksi yang lebih akurat, tetapi juga menawarkan fleksibilitas dalam menghadapi berbagai skenario pasar. Integrasi model deep learning dengan teknik ekonometrik menciptakan peluang untuk menghasilkan prediksi yang lebih kuat dan relevan dalam konteks pasar aset kripto yang dinamis.

Sebagai langkah selanjutnya, disarankan untuk mengeksplorasi variabel eksogen tambahan, seperti data sentimen pasar atau kebijakan moneter, guna meningkatkan akurasi prediksi. Penggunaan metode optimasi hyperparameter, seperti grid search atau Bayesian optimization, juga dapat mempertajam performa model yang digunakan.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan pendekatan multi-model yang mencakup LSTM, GRU, Prophet, VAR, dan Expected Shortfall (ES) untuk meramalkan harga Bitcoin serta menganalisis risiko investasi. Model LSTM menunjukkan kinerja terbaik dalam peramalan harga Bitcoin, dengan nilai MSE sebesar 535,419.12, RMSE sebesar 731.72, MAE sebesar 310.72, dan MAPE sebesar 159.01. Model GRU menyusul dengan nilai MSE sebesar 558,868.06, RMSE sebesar 747.57, MAE sebesar 396.02, dan MAPE sebesar 3717.09. Prophet, meskipun kurang unggul dalam menangkap volatilitas ekstrem, menunjukkan kemampuan dalam menganalisis tren jangka panjang, meskipun dengan nilai MSE sebesar 59,309,927.76, RMSE sebesar 7,701.29, MAE sebesar 4,622.72, dan MAPE sebesar 28,846.73.

Dalam analisis risiko, nilai VaR pada tingkat kepercayaan 95% sebesar 61,676.43 menunjukkan batas kerugian maksimum yang mungkin terjadi, sementara nilai ES sebesar 61,737.58 mengindikasikan estimasi kerugian rata-rata dalam kondisi pasar ekstrem. Hasil ini menegaskan bahwa nilai ES yang lebih besar dari VaR memberikan wawasan penting bagi manajemen risiko, terutama dalam menghadapi potensi kerugian pada kondisi pasar yang tidak stabil.

Secara keseluruhan, penelitian ini menunjukkan bahwa pendekatan multi-model mampu memberikan hasil peramalan yang lebih komprehensif dan akurat, serta menawarkan alat yang kuat untuk menganalisis risiko investasi. Penggunaan kombinasi model ini diharapkan dapat membantu

investor dalam membuat keputusan yang lebih terinformasi, terutama di pasar dengan volatilitas tinggi seperti Bitcoin.

DAFTAR PUSTAKA

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2009. [Online]. Tersedia: <https://bitcoin.org/bitcoin.pdf>.
- [2] Bank Indonesia, "Navigating The Architecture of Digital Rupiah," 2022. [Online]. Tersedia: https://www.bi.go.id/en/rupiah/digital-rupiah/Documents/White-Paper-CBDC-2022_en.pdf.
- [3] E. H. Kusnadi, R. R. Nasir, dan H. Hulwanullah, "Legal Aspects of Crypto Assets on Indonesian Digital Investment Development," *J. Hukum Islam*, vol. 12, no. 2, hlm. 145-162, 2023. DOI: <https://doi.org/10.14421/sh.v12i2.3168>.
- [4] E. R. Arminanto dan K. A. Firmansyah, "Bitcoin's Position in Indonesian Currency Law," *Indonesian J. Econ. Finance*, vol. 5, no. 2, hlm. 67-78, 2022. DOI: <https://doi.org/10.15294/isrev.v5i2.47491>.
- [5] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Syst. Appl.*, vol. 227, no. 120346, hlm. 1-15, 2023. DOI: <https://doi.org/10.1016/j.eswa.2023.120346>.
- [6] N. M. Salih dan A. M. Abdulazeez, "Bitcoin Price Prediction Using Hybrid LSTM-GRU Models," *Indonesian J. Comput. Sci.*, vol. 13, no. 1, hlm. 94-101, 2024. DOI: <https://doi.org/10.33022/ijcs.v13i1.3725>
- [7] N. Tripathy, S. Hota, dan D. Mishra, "Performance analysis of bitcoin forecasting using deep learning techniques," *Indonesia J. Elect. Eng. Comput. Sci.*, vol. 31, no. 3, hlm. 1515-1522, Sept. 2023. DOI: <https://doi.org/10.11591/ijeecs.v31i3.pp1515-1522>.
- [8] P. K. Narayan, S. Narayan, R. E. Rahman, dan I. Setiawan, "Bitcoin price growth and Indonesia's monetary system," *Emerg. Mark. Rev.*, vol. 38, no. S1566014118302796, hlm. 364-376, Mar. 2019. DOI: <https://doi.org/10.1016/j.ememar.2018.11.005>.
- [9] A. Noor, M. A. Arifin, dan D. P. W. Astuti, "Crypto Assets and Regulation: Taxonomy and Framework Regulatory of Crypto Assets in Indonesia," *J. Etika Demokrasi*, vol. 8, no. 3, hlm. 303-315, Aug. 2023. DOI: <https://doi.org/10.26618/jed.v%vi%i.10886>.
- [10] Kaggle, "Bitcoin Historical Dataset," 2024. [Online]. Tersedia: Bitcoin Historical Dataset.
- [11] B. Shaju dan V. Narayan, "Prediction Model for Stock Trading using Combined Long Short Term Memory and Neural Prophet with Regressors," *International Journal of Intelligent Engineering and Systems*, vol. 16, no. 6, hlm. 956-963, 2023. DOI: <https://doi.org/10.22266/ijies2023.1231.79>.
- [12] Y.-T. Huang, Y.-L. Bai, Q.-H. Yu, L. Ding, dan Y.-J. Ma, "Application of a hybrid model based on the Prophet model, ICEEMDAN and multi-model optimization error correction in metal price prediction," *Resour. Policy*, vol. 79, no. S0301420722004123, hlm. 102969, 2022. DOI: <https://doi.org/10.1016/j.resourpol.2022.102969>.
- [13] M. Beniwal, A. Singh, dan N. Kumar, "Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices," *Engineering Applications of Artificial Intelligence*, vol. 129, no. 107617, hlm. 107617, Mar. 2024. DOI: <https://doi.org/10.1016/j.engappai.2023.107617>
- [14] N. S. Wen dan L. S. Ling, "Evaluation of Cryptocurrency Price Prediction Using LSTM and CNNs Models," *Int. J. Informat. Visual.*, vol. 7, no. 3-2, hlm. 2016-2024, 2023. DOI: <https://doi.org/10.1234/jitcs.2020.602>.
- [15] A. T. Haryono, R. Sarno, dan K. R. Sungkono, "Stock price forecasting in Indonesia stock exchange using deep learning: a comparative study," *International Journal of Electrical and Computer Engineering*, vol. 14, no. 1, hlm. 861-869, Feb. 2024. DOI: <http://doi.org/10.11591/ijece.v14i1.pp861-869>.
- [16] S. Pasak dan R. Jayadi, "Investment Decision on Cryptocurrency: Comparing Prediction Performance Using ARIMA and LSTM," *J. Inform. Syst. Innov.*, vol. 5, no. 2, hlm. 407-427, June 2023. DOI: <https://doi.org/10.51519/journalisi.v5i2.473>.

- [17] A. Bâra dan S.-V. Oprea, "An ensemble learning method for Bitcoin price prediction based on volatility indicators and trend," *Engineering Applications of Artificial Intelligence*, vol. 133, no. 107991, hlm. 107991, Juli 2024. DOI: <https://doi.org/10.1016/j.engappai.2024.107991>

