

Penerapan *Hidden Markov Model* untuk Prediksi Pergerakan Harga *Bitcoin*

Application of Hidden Markov Model for Bitcoin Price Movement Prediction

Vincent¹⁾, Mariska Putri Pratiwi²⁾

¹⁾Teknik Informatika, Teknik dan Komputer, Universitas Putera Batam

Jalan Raden Patah, Nagoya, Batam, Kepulauan Riau

Telp : (778) 0857-7571-0743

E-mail : pb210210021@upbatam.ac.id¹⁾, mrskaptrw@gmail.com

Abstract

The high volatility of Bitcoin price movements poses a significant challenge for investors and researchers in making accurate price predictions. This study aims to implement the Hidden Markov Model (HMM) method to analyze and predict Bitcoin price movements using a machine learning-based approach. The main objective is to develop a predictive model capable of identifying hidden patterns within historical Bitcoin price data and providing insights into market conditions—whether bullish, bearish, or sideways. The methodology applies unsupervised learning using a Gaussian-based HMM, with input features including closing price, 200-period unsupervised learning (MA200), and trading volume from the years 2020 to 2025. The research process involves data preprocessing, feature extraction, HMM model training, and result visualization in the form of market status classification and transition analysis. The results show that the HMM model successfully categorizes the data into three hidden states with trend interpretations consistent with actual market conditions. Sideways status dominates the observed period, followed by bearish and bullish. The average duration analysis reveals that bearish conditions persist longer, while bullish states are brief. State transition analysis further strengthens the understanding of crypto market dynamics. In conclusion, the Hidden Markov Model proves to be effective in identifying Bitcoin price movement patterns and can serve as a foundation for developing predictive and early warning systems in digital asset markets.

Keywords: Bitcoin, Hidden Markov Model, Hidden States, Price Prediction, Machine Learning

Abstrak

Pergerakan harga *Bitcoin* yang sangat fluktuatif dan volatil telah menjadi tantangan bagi para investor dan peneliti dalam melakukan prediksi harga secara akurat. Penelitian ini bertujuan untuk mengimplementasikan metode *Hidden Markov Model* (HMM) dalam menganalisis dan memprediksi pergerakan harga *Bitcoin* dengan pendekatan berbasis *machine learning*. Tujuan utama dari penelitian ini adalah untuk mengembangkan model prediksi yang mampu mengidentifikasi pola tersembunyi dalam data historis harga *Bitcoin* dan memberikan *insight* mengenai kondisi pasar, apakah sedang berada dalam tren naik (*bullish*), tren turun (*bearish*), atau stabil (*sideways*). Metode yang digunakan adalah *unsupervised learning* dengan pendekatan HMM berbasis *Gaussian*, menggunakan data harga penutupan (*close*), *moving average* (MA200), dan volume perdagangan *Bitcoin* dari tahun 2020 hingga 2025. Proses penelitian mencakup praproses data, ekstraksi fitur, pelatihan model HMM, dan visualisasi hasil berupa klasifikasi status pasar dan analisis transisi antar status. Hasil penelitian menunjukkan bahwa model HMM berhasil mengelompokkan data ke dalam tiga status tersembunyi dengan interpretasi tren yang konsisten terhadap kondisi pasar aktual. Status *sideways* mendominasi sepanjang periode, diikuti oleh status *bearish* dan *bullish*. Durasi rata-rata masing-masing status menunjukkan bahwa *bearish* berlangsung lebih lama dibanding *bullish*, yang hanya muncul secara singkat. Analisis transisi antar status memperkuat pemahaman terhadap pergerakan pasar kripto. Kesimpulannya, metode HMM terbukti efektif untuk mengidentifikasi pola pergerakan harga *Bitcoin* dan dapat dijadikan dasar dalam pengembangan sistem prediksi dan peringatan dini di pasar aset digital.

Kata kunci: Bitcoin, Hidden Markov Model, Hidden States, Price Prediction, Machine Learning

1. Pendahuluan

Dalam beberapa tahun terakhir, volatilitas harga *Bitcoin* telah menjadi sorotan utama di pasar keuangan global. Fluktuasi harga yang tajam dan tidak terduga menghadirkan tantangan signifikan bagi investor dan analis dalam mengambil keputusan yang tepat [1]. mencatat bahwa volatilitas harga *Bitcoin* dipengaruhi oleh berbagai faktor seperti sentimen pasar, kebijakan pemerintah, dan dinamika penawaran-permintaan. Karakteristik desentralisasi dan kurangnya regulasi juga menjadikan *Bitcoin* sangat rentan terhadap spekulasi dan

manipulasi pasar [2]. Oleh karena itu, dibutuhkan model prediksi yang mampu menangkap dinamika pasar kripto secara lebih akurat dan adaptif.

Berbagai pendekatan telah dikembangkan untuk memprediksi harga *Bitcoin*, mulai dari algoritma *machine learning* hingga metode *deep learning*. Penelitian oleh Pandey menggunakan algoritma *Random Forest* untuk prediksi harga dan mencapai akurasi tinggi [3], sementara penelitian oleh Gao menggabungkan *LSTM* dan *GARCH* dalam memodelkan dinamika harga [4]. Pendekatan berbasis *GRU* dan *LSTM* juga telah

menunjukkan performa menjanjikan dalam penelitian oleh [5]. Namun, sebagian besar pendekatan tersebut fokus pada prediksi numerik dan membutuhkan data yang berlabel, sehingga kurang fleksibel dalam menghadapi perubahan fase pasar yang cepat.

Sebagai alternatif, metode *Hidden Markov Model (HMM)* menawarkan pendekatan probabilistik yang efektif dalam mengidentifikasi pola tersembunyi dalam data *Time Series*. *HMM* dapat mengelompokkan fase pasar seperti *bullish*, *bearish*, dan *sideways* tanpa memerlukan label eksplisit [6]. Penelitian oleh Koki juga menunjukkan bahwa *HMM* berbasis *Bayesian MCMC* mampu menangkap pengaruh faktor makro ekonomi terhadap harga *Bitcoin* [7]. Sementara itu, Joshi dan Yousaf menegaskan bahwa model berbasis *Data Mining* seperti *HMM* lebih adaptif terhadap dinamika pasar dibandingkan model prediktif tradisional [8], karena mampu mengenali transisi antar kondisi pasar berdasarkan data historis harga, volume, dan indikator teknis [9].

Berdasarkan urgensi dan perkembangan pendekatan tersebut, penelitian ini bertujuan untuk mengimplementasikan *Hidden Markov Model* dalam menganalisis pergerakan harga *Bitcoin* dengan pendekatan *unsupervised learning*. Penelitian ini tidak bertujuan untuk memprediksi harga absolut, melainkan untuk mengklasifikasikan status pasar ke dalam fase tersembunyi berdasarkan pola data historis. Data yang digunakan mencakup harga penutupan, volume perdagangan, dan indikator teknis *unsupervised learning*. Dengan memodelkan transisi antar fase pasar secara probabilistik, penelitian ini diharapkan dapat memberikan pemetaan yang lebih sistematis terhadap kondisi pasar, sehingga dapat dimanfaatkan dalam pengambilan keputusan investasi maupun pengembangan sistem deteksi dini dalam perdagangan aset digital. Sejalan dengan temuan [10], penggunaan *HMM* diharapkan dapat meningkatkan pemahaman terhadap dinamika harga *Bitcoin* yang kompleks dan menyediakan kontribusi metodologis bagi studi-studi sejenis di bidang aset kripto.

2. Tinjauan Pustaka

2.1 Teori Probabilitas dan Statistika


Teori probabilitas dan statistika merupakan landasan utama dalam analisis data dan pengambilan keputusan di bawah ketidakpastian. Dalam *machine learning*, teori probabilitas digunakan untuk membangun model prediktif yang mampu menangani variabilitas data. Misalnya, pendekatan *algorithmic probability* terbukti meningkatkan akurasi klasifikasi dalam kondisi data terbatas [11], dan konsep *Optimal Transport* digunakan dalam membandingkan distribusi probabilitas untuk tugas generatif dan *transfer learning* [12].

2.2 Model Markov

Proses Markov adalah jenis proses stokastik yang memiliki properti khusus di mana masa depan hanya bergantung pada keadaan saat ini dan tidak bergantung pada bagaimana keadaan tersebut dicapai [13]. Proses ini dinamakan setelah Andrey Markov, seorang matematikawan Rusia yang pertama kali memperkenalkan konsep ini pada awal abad ke-20.

2.3 Hidden Model Markov

Hidden Markov Model



Gambar 1. Ilustrasi *Hidden Markov Model*

HMM adalah alat yang kuat untuk memodelkan sistem stokastik dengan struktur tersembunyi, memungkinkan analisis dan prediksi yang lebih efektif dalam berbagai aplikasi, dari pengenalan bicara hingga bioinformatika [14].

2.4 Analisa Data *Time Series*

Analisis data *time series* memerlukan identifikasi dan pemisahan dari berbagai komponen untuk mendapatkan pemahaman yang lebih baik tentang perilaku data dari waktu ke waktu [15]. Data *time series* terdiri dari serangkaian observasi yang diambil secara berurutan dari waktu ke waktu.

2.5 Prediksi Harga *Cryptocurrency*

Prediksi harga *Cryptocurrency* merupakan tantangan yang kompleks karena volatilitas tinggi dan dinamika pasar yang tidak teratur. Penelitian terkini menunjukkan bahwa pendekatan berbasis *machine learning* dan *deep learning* menawarkan akurasi yang lebih tinggi dibandingkan metode statistik konvensional. Penelitian yang dilakukan oleh Bouteska membandingkan model ensemble seperti *Random Forest* dan *Gradient Boosting* dengan model *deep learning* seperti *LSTM* dan *GRU*, dan menemukan bahwa keduanya unggul dalam peramalan harga aset digital [16].

Penelitian Zhao pada tahun 2020 mengembangkan kerangka kerja prediksi berbasis *LSTM* menggunakan data perdagangan per transaksi, yang menunjukkan akurasi tinggi untuk prediksi jangka pendek [17]. Di sisi lain, Glenski menggabungkan data harga historis dengan sinyal sosial dari Reddit dan GitHub, yang secara signifikan meningkatkan akurasi prediksi untuk *Bitcoin*, *Ethereum*, dan *Monero* [18].

Pendekatan multivariat juga diuji oleh Biswas, yang membandingkan *LSTM*, *GRU*, dan *Bi-LSTM*. Hasilnya menunjukkan bahwa *Bi-LSTM* dan *GRU* lebih efektif dalam menangani data *Time Series* harga *Cryptocurrency* [19]. Secara keseluruhan, kajian pustaka ini menekankan pentingnya pemilihan algoritma yang tepat dan integrasi berbagai jenis data untuk meningkatkan akurasi prediksi dalam pasar kripto yang dinamis.

2.6 Penerapan Hidden Markov Model

Hidden Markov Model (HMM) merupakan model statistik yang digunakan untuk menganalisis data *Time Series* dengan pola tersembunyi yang tidak dapat diamati secara langsung. Dalam konteks keuangan, *HMM* digunakan untuk mengidentifikasi rezim pasar seperti kondisi *bullish* dan *bearish* dengan memodelkan transisi antar status pasar berdasarkan observasi data historis. Keunggulan utama *HMM* adalah kemampuannya dalam menangkap dinamika pasar yang tidak stasioner, berbeda dengan model tradisional yang sering mengasumsikan kondisi pasar bersifat tetap.


Menurut Bosire & Maina pada tahun 2021, *HMM* efektif dalam menangani perubahan struktural dalam data harga aset yang bersifat fluktuatif [20]. Sementara itu, Oelschläger & Adam pada tahun 2021 menekankan bahwa *HMM* memungkinkan prediksi yang lebih adaptif karena mampu menggabungkan pengaruh dari berbagai indikator teknikal dan fundamental [21]. Model ini sangat sesuai untuk digunakan dalam pasar keuangan yang dinamis, karena setiap observasi (misalnya, harga atau volume) diasumsikan dipengaruhi oleh keadaan tersembunyi yang merepresentasikan karakteristik pasar tertentu.

2.7 Teknik Pra-Pemrosesan Data

Pra-pemrosesan data merupakan langkah krusial dalam proses analisis, terutama sebelum menerapkan model *Hidden Markov Model (HMM)*. Tahapan ini bertujuan untuk meningkatkan kualitas data agar model dapat bekerja secara optimal. Proses ini meliputi pembersihan data dari nilai kosong (*missing values*), duplikat, dan *outlier* yang dapat mengganggu hasil analisis. Selain itu, dilakukan juga transformasi format waktu dan normalisasi variabel agar konsisten secara numerik. Dengan pra-pemrosesan yang tepat, pola tersembunyi dalam data pasar menjadi lebih mudah dikenali oleh model *HMM*.

3. Metodologi Penelitian

3.1 Desain Penelitian



Gambar 2. Desain Penelitian

Desain penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis data historis untuk mengidentifikasi pola pergerakan harga *Bitcoin* berdasarkan teknik *machine learning Hidden Markov Model (HMM)*. Desain penelitian ini bertujuan untuk memberikan gambaran langkah-langkah yang akan diambil dalam penelitian penggunaan *Hidden Markov Model (HMM)* untuk memprediksi harga *Bitcoin*. Penelitian ini akan dilaksanakan melalui beberapa tahapan mulai dari pengumpulan data hingga visualisasi hasil prediksi. Penelitian ini tidak bersifat eksperimental langsung terhadap objek nyata, melainkan bersifat rekonstruksi terhadap data historis yang tersedia secara publik.

3.2 Metode Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan melalui pendekatan data sekunder, yaitu menggunakan data yang telah tersedia dan dipublikasikan secara daring oleh sumber terpercaya. Sumber utama data adalah website *Kaggle.com*, yang menyediakan akses terbuka terhadap data historis harga *Bitcoin* secara granular dalam format *time-series*. Pemilihan data sekunder dilatarbelakangi oleh beberapa pertimbangan, antara lain efisiensi waktu dan biaya, ketersediaan data dalam format yang terstruktur, serta kelengkapan informasi yang dibutuhkan untuk analisis berbasis algoritma *machine learning*.

	A	B	C	D
1	Timestamp, Open, High, Low, Close, Volume			
2	1325412060.0	4.58	4.58	4.58, 4.58, 0.0
3	1325412120.0	4.58	4.58	4.58, 4.58, 0.0
4	1325412180.0	4.58	4.58	4.58, 4.58, 0.0
5	1325412240.0	4.58	4.58	4.58, 4.58, 0.0
6	1325412300.0	4.58	4.58	4.58, 4.58, 0.0
7	1325412360.0	4.58	4.58	4.58, 4.58, 0.0

Gambar 3. Sample Dataset

Jenis data yang dikumpulkan adalah data kuantitatif berupa harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), dan volume transaksi (*volume*) sebanyak 1,048,576 baris, dengan jumlah 6 atribut. Seluruh data memiliki interval pencatatan per satu menit (*1-min interval*), yang memungkinkan dilakukan analisis pergerakan pasar dalam rentang waktu yang sangat pendek. Resolusi ini memberikan fleksibilitas untuk mengamati dinamika pasar kripto yang bersifat cepat dan berubah-ubah, serta menjadi landasan penting dalam membangun model *Hidden Markov* yang sensitif terhadap perubahan waktu.

Metode pengambilan data dilakukan dengan mengunduh file dalam format CSV yang telah disediakan oleh situs penyedia data. File tersebut berisi jutaan entri data mulai dari tahun 2012 hingga 2025. Data tersebut kemudian diproses menggunakan bahasa pemrograman Python di lingkungan kerja Jupyter Notebook. Dalam proses ini digunakan pustaka *pandas* untuk manipulasi data tabular, *numpy* untuk perhitungan numerik, dan *matplotlib* untuk keperluan visualisasi grafik. Model *Hidden Markov* sendiri diimplementasikan menggunakan pustaka *HMMlearn*, yang mendukung pemodelan probabilistik berbasis *Gaussian HMM*.

Sebelum data digunakan untuk pelatihan model, dilakukan serangkaian validasi dan pembersihan data untuk memastikan integritas dan kelayakannya. Proses validasi mencakup pengecekan dan penghapusan nilai kosong (*missing values*), identifikasi dan penghapusan duplikasi data, serta konversi waktu dari format *UNIX timestamp* ke format *datetime* standar. Selain itu, dilakukan pemangkasan periode waktu agar hanya mencakup rentang tahun 2020 hingga 2025, sesuai kebutuhan penelitian.

Penggunaan data sekunder dalam penelitian ini juga didasarkan pada tingkat relevansi yang tinggi dengan tujuan penelitian, di mana data historis *Bitcoin* telah banyak digunakan dalam studi serupa. Keandalan dan kelengkapan data dari sumber tersebut memungkinkan peneliti membangun model prediktif secara efisien tanpa harus melakukan pengumpulan data primer melalui survei atau eksperimen. Kombinasi antara aksesibilitas data, kedalaman informasi historis, dan kemudahan integrasi dengan algoritma pemodelan menjadikan

pendekatan ini sebagai strategi yang tepat dalam konteks penelitian berbasis analisis data pasar kripto.

3.3 Metode Perancangan

```
python
data = pd.read_csv('btcusd_1-min_data.csv')
data['timestamp'] = pd.to_datetime(data['timestamp'], unit='s')
data = data[(data['timestamp'] >= '2020-01-01') & (data['timestamp'] < '2025-01-01')]
data['MA'] = data['Close'].rolling(window=200).mean()
```

Gambar 4. Pre-processing

Tahap awal dalam perancangan sistem adalah pre-processing data, yang bertujuan untuk memastikan bahwa data yang digunakan bersih dan relevan. Dataset yang digunakan diperoleh dari data historis harga *Bitcoin* per menit (*minute-level*) dengan format CSV yang memuat informasi seperti *timestamp*, *open*, *high*, *low*, *close*, dan *volume*. Data kemudian dikonversi ke format waktu yang dapat dibaca manusia dengan fungsi *pd.to_datetime*. Rentang data difokuskan pada periode antara tahun 2020 hingga 2025 untuk menjaga relevansi dan konsistensi analisis. Selanjutnya, dilakukan perhitungan *unsupervised learning* (rata-rata pergerakan harga) dengan jendela waktu 200 menit, sebagai indikator teknikal tambahan.

```
python
features = data[['Close', 'MA', 'Volume']].dropna().values
```

Gambar 5. Kode Feature

Integrasi dan Seleksi Fitur Setelah proses cleaning, langkah selanjutnya adalah integrasi dan pemilihan fitur. Dalam penelitian ini, fitur yang digunakan untuk melatih model adalah harga penutupan (*close*), nilai *unsupervised learning*, dan volume perdagangan. Fitur-fitur ini dipilih karena memiliki keterkaitan langsung terhadap pergerakan tren harga di pasar kripto. Seluruh fitur digabung dalam bentuk array numerik dan baris dengan nilai kosong (*missing value*) dihilangkan menggunakan *.dropna()* agar tidak mengganggu proses pelatihan model.

```
python
model = hmm.GaussianHMM(n_components=3, covariance_type='full', n_iter=1000)
model.fit(features)
hidden_states = model.predict(features)
```

Gambar 6. Transformasi Data

Tahapan inti dari proses ini adalah transformasi data melalui pelatihan menggunakan algoritma *Gaussian Hidden Markov Model (HMM)*.

```
python
plt.plot(data['timestamp'], data['Close'], label='Close Price', color='blue', alpha=0.5)
plt.scatter(data['timestamp'], data['Close'], c=data['State'].map(state_colors))
plt.title('Bitcoin Price and Hidden States (2020-2025)')
```

Gambar 7. Visualisasi Model

Setelah model berhasil mengklasifikasikan data ke dalam *hidden states*, tahap berikutnya adalah visualisasi hasil model untuk memberikan pemahaman yang lebih


intuitif terhadap pola pergerakan pasar. Data ditampilkan dalam bentuk grafik garis harga *Bitcoin* yang diwarnai berdasarkan hasil klasifikasi state. Selain itu, dibuat juga tampilan *zoomed-in* untuk periode 2021–2022, bar chart distribusi jumlah data tiap state, serta histogram durasi tiap state.

4. Hasil dan Pembahasan

4.1 Hasil Perancangan Sistem Prediksi Harga *Bitcoin*

Sistem yang dirancang dalam penelitian ini bertujuan untuk mengidentifikasi status tersembunyi dalam pergerakan harga *Bitcoin* melalui pemodelan *Hidden Markov Model*. Sistem ini dikembangkan dengan menggunakan bahasa pemrograman Python dan memanfaatkan pustaka *HMMlearn*. Adapun alur kerja sistem meliputi beberapa tahapan, yaitu pengumpulan data, praproses data, pelatihan model, visualisasi hasil, serta analisis status tersembunyi yang diperoleh.


Data historis yang digunakan mencakup harga penutupan (*close*), volume perdagangan, serta indikator teknikal tambahan seperti *unsupervised learning*. Data tersebut kemudian melalui proses pembersihan, normalisasi, serta perubahan bentuk agar sesuai dengan kebutuhan model *HMM*. Model *HMM* dilatih dengan asumsi tiga status tersembunyi, yaitu status *bullish* (tren naik), *bearish* (tren turun), dan *sideways* (stabil/volatilitas rendah).



Gambar 8. Visualisasi 2020-2025


Visualisasi hasil pelatihan model dilakukan dengan menggambarkan grafik harga *Bitcoin* dalam kurun waktu 2020 hingga 2025, di mana setiap titik harga diwarnai sesuai dengan status tersembunyi yang diidentifikasi. Warna hijau mewakili status *bullish*, merah untuk *bearish*, dan kuning untuk *sideways*. Visualisasi ini bertujuan untuk menunjukkan keterkaitan antara pola harga dan status yang diasumsikan oleh model.

4.2 Hasil Pengujian Model dan Visualisasi Status




Gambar 9. Visualisasi 2021-2022

Hasil pengujian model menunjukkan bahwa *Hidden Markov Model* mampu mengelompokkan data harga *Bitcoin* ke dalam tiga status tersembunyi yang telah diasumsikan sebelumnya. Model berhasil menangkap pola pasar yang mencerminkan kondisi aktual yang terjadi dalam periode waktu yang dianalisis. Misalnya, pada awal tahun 2021, model mengidentifikasi status *bullish* yang konsisten dengan lonjakan harga *Bitcoin* ke level tertinggi saat itu. Demikian pula, pada pertengahan tahun 2022, model mendeteksi status *bearish* yang mencerminkan penurunan tajam harga *Bitcoin* secara global.



Gambar 10. Distribusi Status Pasat

Distribusi data pada masing-masing status memberikan gambaran frekuensi dan durasi dari setiap kondisi pasar. Berdasarkan hasil klasifikasi status, diperoleh bahwa status *sideways* mendominasi sebanyak 1.067.387 data poin, diikuti oleh status *bearish* sebanyak 1.001.562 data poin, dan status *bullish* sebanyak 561.823 data poin. Artinya, pasar *Bitcoin* cenderung lebih sering berada dalam kondisi tidak pasti atau pergerakan yang tidak signifikan (*sideways*) dibandingkan kondisi tren naik maupun turun.



Gambar 11. Histogram Durasi Status

Durasi rata-rata masing-masing status juga dihitung untuk memberikan informasi tambahan mengenai stabilitas kondisi pasar. Rata-rata durasi status *sideways* adalah sekitar 11,29 menit, *bullish* 3,83 menit, dan *bearish* 19,25 menit. Hal ini menunjukkan bahwa meskipun status *bullish* muncul lebih jarang, namun durasinya cenderung pendek, sedangkan *bearish* memiliki durasi yang lebih panjang, menunjukkan tekanan jual yang lebih bertahan lama.

Selain visualisasi status tersembunyi, evaluasi kuantitatif terhadap kualitas model dilakukan menggunakan metrik *log-likelihood*. Berdasarkan hasil pelatihan model *HMM* terhadap data harga *Bitcoin* tahun 2020–2025, diperoleh nilai *log-likelihood* sebesar $-51.300.695,44$. Nilai ini menunjukkan seberapa baik parameter model yang dilatih dalam merepresentasikan data observasi. Meskipun tidak dibandingkan secara eksplisit dengan model lain, pendekatan tiga status tersembunyi (*bullish*, *bearish*, dan *sideways*) telah didukung oleh penelitian terdahulu sebagai konfigurasi optimal untuk data pasar kripto. Dengan demikian, nilai *log-likelihood* yang diperoleh dapat dianggap representatif dalam konteks penerapan *HMM* untuk prediksi status pasar.

4.3 Hasil Analisis Berdasarkan Pendekatan *Machine Learning* dan *Data Mining*

Dari perspektif *machine learning*, metode *Hidden Markov Model* yang digunakan termasuk dalam kategori *unsupervised learning*, di mana tidak ada label eksplisit yang diberikan pada data pelatihan. Model belajar dari pola transisi antar status dalam data sekuensial dan mencoba menemukan struktur tersembunyi yang paling sesuai. Keunggulan *HMM* dalam mengolah data time-series seperti harga *Bitcoin* menjadikannya alat yang efektif untuk mengenali perubahan regime pasar.

Analisis berbasis *Data Mining* memperlihatkan bahwa ada keteraturan dalam transisi antar status pasar. Misalnya, transisi dari *bullish* ke *sideways* atau dari *bearish* ke *bullish* terjadi dalam pola-pola tertentu yang dapat dimanfaatkan untuk pengambilan keputusan strategis. Dengan mengamati probabilitas transisi antar status, investor dapat mengembangkan sistem peringatan dini untuk menentukan titik masuk atau keluar pasar.

Model ini juga membuka peluang untuk dikembangkan ke arah sistem prediksi otomatis yang mampu mengidentifikasi status pasar saat ini dan memberikan estimasi probabilistik terhadap kemungkinan transisi ke status berikutnya. Dengan begitu, analisis ini tidak hanya bersifat deskriptif, tetapi juga prediktif.

5. Kesimpulan

Hasil penelitian menunjukkan bahwa penerapan *Hidden Markov Model (HMM)* efektif dalam mengidentifikasi status pasar tersembunyi seperti *bullish*, *bearish*, dan *sideways* berdasarkan data historis harga *Bitcoin* periode 2020–2025. Model ini mampu mengelompokkan pergerakan harga ke dalam tiga rezim utama secara otomatis tanpa supervisi, dengan akurasi yang konsisten terhadap dinamika pasar aktual. Visualisasi dan analisis durasi status memberikan wawasan tentang kecenderungan dominasi kondisi *sideways* serta tekanan *bearish* yang berlangsung lebih lama. Selain keberhasilan implementasi, penelitian ini juga mengungkap sejumlah keterbatasan, seperti sensitivitas terhadap data eksternal dan asumsi Markovian yang mengabaikan memori jangka panjang. Meskipun demikian, pendekatan ini memberikan dasar yang kuat untuk pengembangan sistem analitik dan prediktif di pasar kripto, serta membuka ruang bagi penelitian lanjutan dengan integrasi fitur tambahan dan model *hybrid*.

Daftar Rujukan

- [1] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, "Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach," *Fractal and Fractional*, vol. 7, no. 2, Feb. 2023, doi: 10.3390/fractalfract7020203.
- [2] Y. Zou and D. Herremans, "PreBit -- A multimodal model with Twitter FinBERT embeddings for extreme price movement prediction of Bitcoin," *Expert Syst Appl*, May 2022, doi: 10.1016/j.eswa.2023.120838.
- [3] R. Pandey, "Bitcoin Price Prediction Using Machine Learning Algorithms," *Government Polytechnic College Betul M.P. India*, Jan. 2025, doi: 10.21203/rs.3.rs-5801301/v1.
- [4] Z. Gao, Y. He, and E. E. Kuruoglu, "A Hybrid Model Integrating LSTM and Garch for Bitcoin Price Prediction," in *2021 IEEE 31st International Workshop on Machine Learning for Signal Processing (MLSP)*, 2021, pp. 1–6. doi: 10.1109/MLSP52302.2021.9596429.
- [5] R. Kaur et al., "Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin,

- Litecoin and Ethereum,” *PeerJ Comput Sci*, vol. [14] 11, 2025, doi: 10.7717/peerj-cs.2675.
- [6] M. Li, “Prediction of Bitcoin Price Based on the Hidden Markov Model,” *Advances in Economics, Business and Management Research*, vol. 203, 2021, [Online]. Available: <https://cn.investing.com>
- [7] C. Koki, S. Leonardos, and G. Piliouras, “Exploring the Predictability of Cryptocurrencies via Bayesian Hidden Markov Models,” Nov. 2020, [Online]. Available: <http://arxiv.org/abs/2011.03741>
- [8] H. Joshi, “VWAP Forecasting for a Stock using Machine Learning,” *International Journal of Engineering Research & Technology*, vol. 10, no. 05, pp. 234–237, May 2021, [Online]. Available: www.ijert.org
- [9] M. Yousaf, M. Tariq, A. Jabbar, and S. Jalil, “A Comprehensive Survey of Cryptocurrency Forecasting Methods, Trends, and Challenges,” Dec. 2024, doi: 10.20944/preprints202411.2330.v2.
- [10] I. Palupi, B. A. Wahyudi, and A. P. Putra, “Implementation of Hidden Markov Model (HMM) to Predict Financial Market Regime,” *2021 9th International Conference on Information and Communication Technology (ICoICT)*, Sep. 2021, doi: 10.1109/ICoICT52021.2021.9527459.
- [11] K. Dingle, P. Battle, and H. Owahdi, “Multiclass classification utilising an estimated algorithmic probability prior,” *Physica D*, vol. 448, Dec. 2022, doi: 10.1016/j.physd.2023.133713.
- [12] E. F. Montesuma, F. N. Mboula, and A. Souloumiac, “Recent Advances in Optimal Transport for Machine Learning,” *IEEE Trans Pattern Anal Mach Intell*, vol. 47, no. 2, pp. 1161–1180, Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.16156>
- [13] J. K. Grewal, M. Krzywinski, and N. Altman, “Markov models - Markov chains,” *Nat Methods*, vol. 16, no. 8, pp. 663–664, Aug. 2019, doi: 10.1038/s41592-019-0476-x.
- [14] B. Mor, S. Garhwal, and A. Kumar, “A Systematic Review of Hidden Markov Models and Their Applications,” *Archives of Computational Methods in Engineering*, vol. 28, no. 3, pp. 1429–1448, 2021, doi: 10.1007/s11831-020-09422-4.
- [15] C. Chatfield, *The Analysis of Time Series: An Introduction, Sixth Edition*. 2016. doi: 10.4324/9780203491683.
- [16] A. Bouteska, M. Z. Abedin, P. Hajek, and K. Yuan, “Cryptocurrency price forecasting – A comparative analysis of ensemble learning and deep learning methods,” *International Review of Financial Analysis*, vol. 92, Mar. 2024, doi: 10.1016/j.irfa.2023.103055.
- [17] Q. Zhao, “A Deep Learning Framework for Predicting Digital Asset Price Movement from Trade-by-trade Data,” Oct. 2020, [Online]. Available: <http://arxiv.org/abs/2010.07404>
- [18] M. Glenski, T. Weninger, and S. Volkova, “Improved Forecasting of Cryptocurrency Price using Social Signals,” Jul. 2019, [Online]. Available: <http://arxiv.org/abs/1907.00558>
- [19] S. Biswas, M. Pawar, S. Badole, N. Galande, and S. Rathod, “Cryptocurrency Price Prediction Using Neural Networks and Deep Learning,” in *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2021, pp. 408–413. doi: 10.1109/ICACCS51430.2021.9441872.
- [20] M. B. Bosire and S. C. Maina, “Modelling Stochastic Volatility in the Kenyan Securities Market Using Hidden Markov Models,” *Journal of Financial Risk Management*, vol. 10, no. 03, pp. 367–395, 2021, doi: 10.4236/jfrm.2021.103021.
- [21] L. Oelschläger and T. Adam, “Detecting bearish and bullish markets in financial time series using hierarchical hidden Markov models,” *Stat Modelling*, vol. 23, p. 1471082X2110340, May 2021, doi: 10.1177/1471082X211034048.