Turnitin No Repository

1.+Rizki+dan+Bu+Fifi+Reviewer+2_Updated.docx

Assignment 4

Skripsi

UIN Sultan Maulana Hasanudin

Document Details

Submission ID
trn:oid:::1:3623885005

Submission Date
Aug 7, 2026, 4:01 PM GMT+7

Download Date
Aug 7, 2026, 4:02 PM GMT+7

File Name
1._Rizki_dan_Bu_Fifi_Reviewer_2_Updated.docx

File Size
206.7 KB

7 Pages

3,436 Words

23,486 Characters

11% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

10% Internet sources
7% Publications
2% Submitted works (Student Papers)

Top Sources

10% Internet sources
7% Publications
2% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1 Internet
ojs.unwaha.ac.id 3%

2 Publication
Sun, Jiaqi. "Factors Influencing Railroad Trespassing Behavior: A Survey-Based Sta... <1%

3 Internet
publications.holistence.com <1%

4 Internet
ejournal.itn.ac.id <1%

5 Internet
ejurnal.seminar-id.com <1%

6 Internet
jurnal.polinema.ac.id <1%

7 Internet
rama.unimal.ac.id <1%

8 Internet
digilib.unila.ac.id <1%

9 Internet
eprints.amikom.ac.id <1%

10 Internet
repository.iainkudus.ac.id <1%

11 Student papers
Universitas Diponegoro <1%

12 Internet
id.scribd.com <1%

13 Internet
tin.fst.uin-alauddin.ac.id <1%

14 Student papers
iGroup <1%

15 Internet
vibdoc.com <1%

16 Internet
www.ausstats.abs.gov.au <1%

17 Publication
Jelly Helia Putri, Sunarsan Sitohang. "Klasifikasi Kinerja Pegawai Menggunakan Al... <1%

18 Publication
Sandi Badiwibowo Atim, Muhammad Afdhaluddin. "Komparasi Perceptron dan R... <1%

19 Internet
publikasi.dinus.ac.id <1%

20 Internet
repo.itera.ac.id <1%

21 Internet
subset.id <1%

22 Internet
test.acarindex.com <1%

23 Internet
www.coursehero.com <1%

24 Publication
Dwi Nurmelly Handayani, Sayid Qutub. "Penerapan Random Forest Untuk Predik... <1%

EPiC **Exact Papers in Compilation**
Vol. 5 No. 2 Mei 2023, Halaman …- …
E-ISSN: 2656-0550

Deteksi Risiko Keuangan pada Aset Digital Menggunakan Machine Learning

Achmad Rizki Setiawan[1*], Nur Khafidhoh[2], Agus Sifaunnajah[3]
[1,2,3]Sistem Informasi, Universitas KH. A. Wahab Hasbullah
*Email: achmadrizkisetiawan890@gmail.com[1], nurkhafidhoh@unwaha.ac.id[2], agus.syifa85@gmail.com[3]

Commented [A1]: afiliasi hanya tulis satu saja

Commented [A2]: sertakan email seluruh author

ABSTRACT

*The rapid growth of blockchain-based digital asset transactions has created new opportunities in the digital financial ecosystem while simultaneously increasing the complexity of financial risk management due to high price volatility, abnormal transaction patterns, and the growing potential for illicit activities such as money laundering and fraud. This study aims to identify high-risk transaction patterns and predict financial risk levels within the blockchain ecosystem using a machine learning approach. Blockchain transaction data were collected and processed through data cleaning, normalization, and feature extraction prior to analysis. The **K-Means** algorithm was employed to cluster transactions based on similar behavioural characteristics, while the **Random Forest** algorithm was used to classify transaction risk levels according to the clustering results and available transaction attributes. Model performance was evaluated using accuracy, precision, recall, and F1-score to provide a comprehensive assessment of classification effectiveness. The results indicate that the clustering process successfully identified three primary risk categories—**Low Risk**, **Medium Risk**, and **High Risk**—representing different stages of Bitcoin market dynamics based on price movements and transaction volume patterns. Furthermore, the Random Forest model achieved outstanding predictive performance, with accuracy, precision, recall, and F1-score all exceeding **99%**, while demonstrating slightly better performance than the Decision Tree model due to its greater stability and robustness through an ensemble learning approach. These findings suggest that integrating machine learning techniques into blockchain-based financial systems can significantly enhance early detection of potentially risky transactions and support more informed decision-making for investors, financial institutions, and regulators in fostering a more secure, transparent, and sustainable digital asset ecosystem. Moreover, the proposed model has strong potential to be implemented as a **real-time early warning system** to support financial risk management and decision-making in digital asset trading environments.*

Keywords: *Blockchain, Bitcoin, Machine Learning, K-Means, Random Forest.*

ABSTRAK

Pertumbuhan transaksi aset digital berbasis blockchain telah menciptakan peluang baru dalam sistem keuangan digital, namun di sisi lain juga meningkatkan kompleksitas manajemen risiko akibat tingginya volatilitas harga, aktivitas transaksi yang tidak wajar, serta potensi penyalahgunaan seperti pencucian uang dan penipuan. Penelitian ini bertujuan untuk mengidentifikasi pola transaksi berisiko dan memprediksi tingkat risiko keuangan pada ekosistem blockchain menggunakan pendekatan machine learning. Data transaksi blockchain dikumpulkan, diproses melalui tahap pembersihan data, normalisasi, dan ekstraksi fitur sebelum dilakukan analisis. Algoritma K-Means digunakan untuk mengelompokkan pola transaksi berdasarkan karakteristik yang serupa, sedangkan algoritma Random Forest diterapkan untuk mengklasifikasikan tingkat risiko transaksi berdasarkan hasil pengelompokan dan atribut transaksi yang tersedia. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score untuk mengukur kemampuan klasifikasi secara komprehensif. Hasil penelitian menunjukkan bahwa proses clustering berhasil membentuk tiga kategori risiko utama, yaitu Low Risk, Medium Risk, dan High Risk, yang merepresentasikan dinamika pasar Bitcoin berdasarkan pola harga dan volume transaksi. Selanjutnya, model Random Forest mampu memberikan performa prediksi yang sangat baik dengan nilai akurasi, presisi, recall, dan F1-score masing-masing berada di atas 99%, serta menunjukkan performa yang sedikit lebih unggul dibandingkan Decision Tree karena lebih stabil dalam menangani fluktuasi data melalui pendekatan ensemble learning. Temuan ini mengindikasikan bahwa integrasi metode machine learning pada sistem blockchain dapat meningkatkan efektivitas deteksi dini terhadap aktivitas transaksi yang berpotensi menimbulkan risiko keuangan, sekaligus mendukung proses pengambilan keputusan bagi investor, lembaga keuangan, dan regulator dalam membangun ekosistem aset digital yang lebih aman, transparan, dan berkelanjutan. Model yang dikembangkan juga berpotensi diimplementasikan sebagai early warning system berbasis data real-time untuk mendukung manajemen risiko pada perdagangan aset digital.

Commented [A3]: terlalu sedikit tolong ditambahkan

Kata-kata Kunci: *Blockchain, Bitcoin, Machine Learning, K-Means, Random Forest.*

EPIC: Exact Papers in Compilation
Vol.5 No.2 Mei 2023

PENDAHULUAN

Perkembangan bidang ilmu pengetahuan dan teknologi semakin pesat saat ini terutama di masa era digitalisasi dan era informasi. (Khafidhoh et al., 2024). Perkembangan teknologi blockchain telah membawa perubahan signifikan dalam ekosistem keuangan digital global, khususnya dalam hal transaksi aset kripto seperti Bitcoin, Ethereum, dan berbagai altcoin lainnya. Kompleksitas proses implementasi *blockchain* meningkat disebabkan oleh infrastruktur digital dan fragmentasi sistem logistik yang terbatas di negara berkembang. (Kurniawan et al., 2026). Transaksi berbasis blockchain menawarkan transparansi, keamanan, dan desentralisasi yang tinggi. Cryptocurrency sebagai bentuk digitalisasi alat pembayaran terenkripsi sitem yang sudah tersebar di dunia (Legal et al., 2021). Urgensi penelitian ini terletak pada kebutuhan untuk mengidentifikasi dan memprediksi risiko keuangan pada transaksi blockchain secara lebih akurat dan efisien. Seiring semakin masifnya penggunaan kripto oleh individu dan institusi, pengawasan terhadap pola-pola transaksi menjadi sangat penting guna mendukung keamanan transaksi digital dan melindungi aset pengguna. Blockchain dan cryptocurrency menjadi perkembangan teknologi yang sukses mengubah system keuangan digital secara signifikan.. Blockchain memudahkan koneksi antar transaksi karena tidak memerlukan pihak bank atau lembaga keuangan sebagai perantara. Namun, adaptasi dan pengaplikasian teknologi yang tergolong lambat menjadi salah satu tantangan yang perlu diatasi. Industri maritim Singapura Zhou et al. (2020) mencatat bahwa masalah terkait regulasi, kepercayaan, interoperabilitas, dan standarisasi menjadi tantangan utama dalam proses implementasi *blockchain* (Indraprakoso et al., 2023).

Cryptocurrency, sebagai salah satu implementasi utama dari teknologi blockchain, telah menjadi alat transaksi yang semakin populer dalam beberapa tahun terakhir. Aset digital seperti Bitcoin, Ethereum, dan berbagai altcoin lainnya memungkinkan pengguna untuk melakukan transaksi global dengan biaya rendah dan kecepatan tinggi. Beberapa transaksi dalam blockchain dapat digunakan untuk aktivitas ilegal seperti pencucian uang, pendanaan terorisme, serta penipuan berbasis kripto. Beberapa transaksi dalam blockchain disalahgunakan berupa tindakan ilegal berkaitan dengan tindak pidana seperti pencuciaan uang, pembiayaan aksi terorisme, dan penipuan berbasis kripto.

Salah satu contohnya adalah kasus pencucian uang melalui pertukaran cryptocurrency yang melibatkan platform Bitfinex pada tahun 2016, di mana sekitar 120.000 Bitcoin dicuri dan kemudian dicuci melalui berbagai transaksi kecil di berbagai dompet digital (Chainalysis, 2022). Dalam penelitian ini, analisis pola transaksi blockchain dalam cryptocurrency menjadi aspek penting dalam mendeteksi potensi risiko keuangan. Machine Learning (ML) telah banyak digunakan dalam berbagai bidang analitik data, termasuk dalam mendeteksi pola transaksi yang mencurigakan. Penelitian ini akan menggunakan berbagai sumber data untuk analisis, seperti dataset transaksi blockchain yang tersedia di Kaggle, Google Dataset Search, dan GitHub. Selain itu, data tambahan akan diambil dari API exchange crypto seperti Blockchain.com dan Binance untuk mendapatkan informasi harga, volume transaksi, dan jenis cryptocurrency secara real-time. Dengan kombinasi teknik pengambilan data melalui API, web scraping, serta analisis Machine Learning, penelitian ini dilakukan dengan tujuan untuk melakukan pengembangan model yang mampu mendeteksi pola transaksi berisiko dan memberikan prediksi risiko keuangan secara lebih akurat. Bitcoin adalah alat pembayaran digital yang dipersamakan dengan cryptocurrency. Bitcoin berkonsep pada teknik dasar kriptografi dan jaringan komputer mulai dari fungsi hash, blockchain, jaringan terdesentralisasi (peer-to-peer), dan mekanisme konsensus (Nanda Sari & Gelar, 2024). Prediksi merupakan proses sistematis untuk memperhitungkan kejadian mendatang melalui data historis maupun data terkini untuk meminimalisir kesalahan di kemudian hari (Julianto, 2022). Upaya untuk mengimplementasikan tujuan pengklusteran ini maka metode yang diterapkan adalah K-Means. Metode tersebut menjadi rekomendasi berdasarkan atas penelitian yang telah sukses dilakukan oleh peneliti terdahulu (Nursikuwagus et al., 2024).

METODE PENELITIAN

Pendekatan kuantitatif dipilih menjadi metode eksperimen pada penelitian ini. Penelitian ini memiliki fokus utama berupa pengujian hipotesis secara objektif melalui analisis data sekunder transaksi blockchain. Menurut (Dr. Arif Rachman, Dr. E. Yochanan, 2024), pendekatan ini bertujuan untuk mengukur dan menganalisis pola transaksi menggunakan teknik *machine learning* untuk menghasilkan kesimpulan yang dapat digeneralisasi. Selain itu penelitian ini juga memanfaatkan teknik analisis data. Analisis data merupakan tahapan dalam proses pengolahan data yang bersumber dari hasil wawancara, catatan di lapangan, dan bahan lain yang disusun secara sistematis agar mudah

EPIC: Exact Papers in Compilation
Vol.5 No.2 Mei 2023

dipahami oleh orang lain (Khafidhoh & Badriyah, 2023). Untuk mencapai hasil maksimal, dataset yang digunakan dalam penelitian data mining harus sesuai dengan algoritma dan metode yang dipilih (*Journal of Artificial Intelligence and Digital Business (RIGGS) Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random*, 2025). Framework dalam bahasa pemrograman python menjadi fokus klasifikasi algoritma sebagai teknik dalam model machine learning (Data et al., 2023).

Populasi dan Sampel Data

Populasi seluruh data transaksi keuangan pada jaringan blockchain public, termasuk transaksi peer-to-peer (P2P), *smart contract* (DeFi) dan transaksi bursa asset digital. Pengambilan data sampel menggunakan teknik purposive sampling dengan data yang memiliki kriteria berupa atribut lengkap (waktu, jumlah, alamat pengirim/penerima, biaya transaksi). Data diambil dalam rentang waktu 1 Januari 2023 hingga 20 April 2025 dengan jumlah minimal 10.000 transaksi. Data diperoleh dari repositori public seperti Kaggle, serta pengambilan data real-time melalui API dari CoinGecko.

Variabel Penelitian

Penelitian ini mengkaji tiga jenis variabel utama, yaitu variable bebas (*independent variable),* variable terikat (dependent variable) dan variable control. Variabel bebas mencakup *Transaction Amount, Timestamp, Sender/Receiver Address Frequency, Transaction Fee, Transaction Type,* dan *Anonymity Score*. Sedangkan variable terikat adalah tingkat risiko transaksi (*Risk Level)* yang dikategorikan menjadi berisiko atau tidak berisiko. Lalu variable control yaitu *Periode waktu dataset, jumlah sampel, dan parameter model (hyperparameter).*

HASIL DAN PEMBAHASAN

Dataset yang digunakan mencakup data transaksi Bitcoin (BTC) interval 15 menit periode Januari 2023 hingga Juni 2025, hasil integrasi data historis dan data realtime dari REST API CoinGecko. Dataset akhir terdiri dari 97.749 observasi dengan 12 variabel utama yang merepresentasikan harga dan aktivitas transaksi.

Tabel 1. Deskripsi Variabel Dataset Bitcoin

NO	VARIABEL	TIPE DATA	DESKRIPSI
1	Open time	Datetime	Waktu pembukaan interval transaksi
2	Open	Numeric	Harga pembukaan (USD)
3	High	Numeric	Harga tertinggi (USD)
4	Low	Numeric	Harga terendah (USD)
5	Close	Numeric	Harga penutupan (USD)
6	Volume	Numeric	Volume transaksi BTC
7	Close time	Datetime	Waktu penutupan interval
8	Quote asset volume	Numeric	Volume aset kuotasi
9	Number of trades	Numeric	Jumlah transaksi
10	Taker buy base volume	Numeric	Volume beli agresif
11	Taker buy quote volume	Numeric	Volume beli kuotasi
12	Ignore	Numeric	Kolom tambahan

Pemeriksaan kualitas data menunjukkan tidak terdapat missing values, sehingga dataset dinyatakan valid untuk analisis lanjutan.

Hasil Penelitian

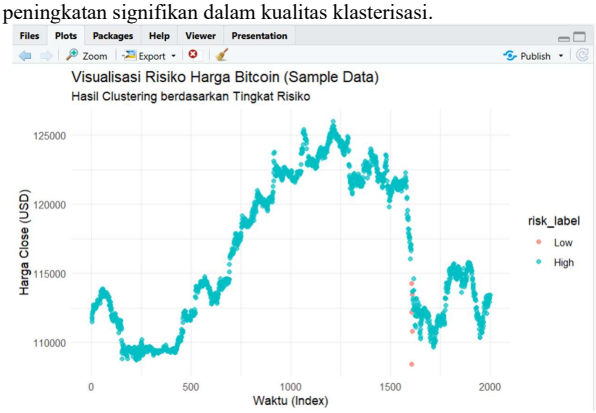
. Analisis statistik deskriptif menunjukkan fluktuasi harga dan volume yang tinggi sepanjang periode penelitian. Nilai ekstrem pada volume dan harga mengindikasikan keberadaan transaksi berskala besar (whale activity) yang relevan untuk analisis risiko. Pembentukan Label Risiko dengan K-Means ini adalah inti dari unsupervised learning. Pembentukan label risiko dalam penelitian ini sepenuhnya didasarkan pada pendekatan unsupervised learning menggunakan algoritma K-Means Clustering. Tahap ini menjadi fondasi utama penelitian karena dataset transaksi Bitcoin tidak menyediakan label risiko keuangan secara eksplisit. Oleh karena itu, struktur risiko pasar harus diekstraksi langsung dari pola data harga dan volume tanpa supervisi awal.

1. Pembentukan Label Risiko dengan K-Means

Jumlah klaster terbaik ditentukan menggunakan Elbow Method, dengan menganalisis nilai *Within-*

EPIC: Exact Papers in Compilation
Vol.5 No.2 Mei 2023

Cluster Sum of Squares (WSS) untuk jumlah klaster k = 1 hingga k = 10. WSS merepresentasikan tingkat homogenitas data di dalam setiap klaster; semakin kecil nilai WSS, semakin baik kualitas pengelompokan. Evaluasi memberikan hasil berupa nilai WSS yang menurun taja, dari k awal = 1 hingga k akhir = 3, yang mengindikasikan peningkatan signifikan dalam kualitas klasterisasi.



Gambar 1 Visualisasi Sebaran Klaster Risiko Harga Bitcoin (2023-2025)

Namun, setelah k = 3, penurunan nilai WSS mulai melandai secara signifikan, sehingga penambahan jumlah klaster tidak lagi memberikan peningkatan struktur klaster yang substansial. Fenomena ini menandai keberadaan titik siku (elbow point) pada k = 3, yang secara metodologis dianggap sebagai jumlah klaster optimal. Dengan demikian, penggunaan k = 3 mampu menjadi penyeimbang terbaik atas adanya kompleksitas model maupun kualitas segmentasi data, serta menghindari risiko *over-segmentation*.

2. Performa Model Decision Tree vs. Random Forest

Setelah label risiko (*Low, Medium, High*) dibentuk melalui pendekatan *unsupervised learning* menggunakan K-Means, tahap selanjutnya adalah mengevaluasi kemampuan model *supervised learning* dalam memprediksi tingkat risiko transaksi Bitcoin.

Model decision tree menghasilkan akurasi sebesar 99,85%, yang menunjukkan kemampuan klasifikasi yang sangat tinggi. Temuan ini mengindikasikan bahwa harga terendah dalam suatu interval waktu memiliki peran krusial dalam menangkap kondisi risiko pasar, karena mencerminkan tekanan jual terendah yang terjadi dalam periode tersebut. Sedangkan model random forest mampu menghasilkan tingkat akurasi performa sebesar 99,86% yang lebih tinggi dibandingkan dengan model decision tree. Peningkatan ini diperoleh melalui mekanisme ensemble learning yang menggabungkan banyak pohon keputusan dan menggunakan teknik bagging untuk mengurangi variansi model. Random Forest tetap mengidentifikasi variabel harga—terutama *Low price*—sebagai fitur penting, namun dengan pembobotan yang lebih stabil terhadap fitur-fitur lain seperti *Open*, *Close*, *High*, dan *Volume*. Perbedaan akurasi antara kedua model relatif kecil (0,01%), yang menunjukkan bahwa kedua pendekatan mampu mempelajari pola risiko secara sangat efektif. Namun, random forest unggul secara marginal dalam hal stabilitas dan generalisasi, sementara decision tree unggul dalam interpretabilitas dan kejelasan aturan keputusan.

Pembahasan

Temuan utama dalam penelitian ini menunjukkan bahwa pola transaksi Bitcoin secara alami tersegmentasi ke dalam tiga klaster risiko utama ketika dianalisis menggunakan algoritma K-Means tanpa supervisi. Segmentasi ini tidak hanya bersifat statistik, tetapi juga memiliki makna ekonomi dan pasar (market meaning) yang kuat. Ketiga klaster tersebut merepresentasikan fase-fase dinamika pasar Bitcoin yang selaras dengan teori siklus pasar keuangan dan karakteristik volatilitas aset kripto.

1. Interpretasi Dinamika Risiko Pasar

Klaster *Low Risk* merepresentasikan fase pasar dengan harga relatif rendah dan stabil, disertai fluktuasi yang terbatas dan volume transaksi yang tidak ekstrem. Secara teoritis, kondisi ini selaras dengan fase akumulasi (accumulation phase**)** dalam siklus pasar, di mana tekanan jual telah menurun dan pasar mulai membentuk dasar harga (*price bottoming*). Dalam konteks pasar Bitcoin, fase ini umumnya terjadi setelah periode penurunan harga yang signifikan (*bear market*). Temuan penelitian menunjukkan bahwa klaster ini mendominasi periode awal dataset, khususnya pada tahun 2023, yang mencerminkan fase

EPIC: Exact Papers in Compilation
Vol.5 No.2 Mei 2023

pemulihan pasca penurunan harga pada tahun sebelumnya. Risiko finansial pada fase ini relatif rendah karena volatilitas harga masih terkendali dan belum terjadi lonjakan spekulatif.

Klaster *Medium Risk* menunjukkan peningkatan volatilitas harga dan aktivitas transaksi dibandingkan klaster risiko rendah. Fase ini mencerminkan kondisi transisi pasar, di mana harga mulai bergerak lebih agresif namun belum memasuki fase euforia penuh. Secara teoritis, klaster ini sejalan dengan fase transisi atau re-accumulation, yang sering kali ditandai oleh ketidakpastian arah pasar. Harga cenderung mengalami kenaikan dan koreksi berulang, mencerminkan pertarungan antara sentimen optimisme dan kehati-hatian pelaku pasar.

Klaster *High Risk* ditandai oleh lonjakan harga dan volume transaksi yang ekstrem, yang mengindikasikan meningkatnya aktivitas spekulatif dan tekanan pasar yang tinggi. Dalam teori siklus pasar, kondisi ini identik dengan fase puncak atau euforia (peak volatility phase**)**. Dari perspektif manajemen risiko, fase *High Risk* dapat diartikan sebagai zona bahaya (danger zone), di mana strategi agresif dapat menghasilkan keuntungan besar namun juga berpotensi menimbulkan kerugian signifikan. Model K-Means secara efektif menangkap fase ini melalui pola harga dan volume tanpa memerlukan indikator eksternal.

Tabel 4.7 Pembagian Kluster Risiko Harga Bitcoin per Tahun (2023-2025)

Tahun	Tingkat Risiko	Tanggal Contoh	Harga Close (Usd)	Volume Rata-Rata	Jumlah Data
2023	Low	2023-02-21	23,130.06	5,035.60	3,734
2023	Medium	2023-07-21	28,119.55	568.75	31,301
2024	Low	2024-03-12	59,679.00	4,042.67	155
2024	Medium	2024-06-04	62,983.98	344.38	29,643
2024	High	2024-12-04	96,119.63	392.69	5,338
2025	Low	2025-03-02	91,584.99	4,451.40	39
2025	Medium	2025-04-07	75,817.99	2,053.63	7
2025	High	2025-05-24	104,803.83	214.00	27,504

Secara konseptual, temuan tiga klaster risiko ini memperkuat pandangan bahwa pasar Bitcoin bergerak dalam siklus risiko yang dapat diidentifikasi secara data-driven. Hal ini menegaskan bahwa algoritma unsupervised learning mampu mengekstraksi struktur laten risiko pasar hanya dari variabel harga dan volume. Dengan ini, pengklusteran memberikan hasil bahwa *clustering* juga memiliki nilai aplikatif sebagai dasar pengambilan keputusan berbasis risiko di pasar kripto sehingga tidak hanya relevan secara akademik.

Dengan demikian, hasil clustering tidak hanya relevan secara akademik, tetapi juga memiliki nilai aplikatif sebagai dasar pengambilan keputusan berbasis risiko di pasar kripto.

2. Analisis Performa Model

Hasil evaluasi menunjukkan bahwa kedua model klasifikasi—Decision Tree dan Random Forest—mencapai tingkat akurasi yang sangat tinggi, masing-masing sebesar 99,85% dan 99,86%. Nilai akurasi yang mendekati 100% ini bukan merupakan anomali, melainkan mencerminkan keterkaitan yang sangat kuat antara variabel input dan label risik**o** yang dibentuk pada tahap *unsupervised learning*.

Label risiko (*Low, Medium, High*) yang digunakan pada tahap klasifikasi secara langsung diturunkan dari pola harga dan volume transaksi melalui K-Means clustering. Variabel OHLCV (Open, High, Low, Close, Volume) memiliki korelasi yang sangat tinggi terhadap struktur klaster yang terbentuk, khususnya antar variabel harga yang menunjukkan hubungan linear yang kuat.

Kenapa random forest lebih unggul dari decision tree? Meskipun selisih akurasi antarmodel tergolong kecil, terdapat performa lebih unggul yang ditunjukkan oleh Random Forest apabila dibandingkan dengan Decision Tree. Random Forest mengadopsi pendekatan dengan membuat pohon keputusan dalam jumlah banyak secara pararel dan mengintegrasikan hasil prediksinya melalui sistem suara terbanyak (*majority voting*). Pendekatan ini membuat random forest lebih tahan terhadap noise, stabil pada dataset berskala besar, konsisten dalam menghadapi fluktuasi ekstrem harga dan volume.

Hasil penelitian ini juga menyoroti adanya trade-off antara interpretabilita**s** dan robustness model. Decision Tree unggul dalam menjelaskan aturan keputusan secara eksplisit—terutama dengan dominasi fitur *Low price* sebagai prediktor utama—sehingga cocok untuk analisis konseptual dan kebutuhan transparansi. Tingginya performa kedua model menegaskan bahwa pendekatan hybrid *unsupervised–supervised learning* yang digunakan dalam penelitian ini efektif dalam memodelkan risiko transaksi Bitcoin.

3. Implikasi Praktis bagi Trader

EPIC: Exact Papers in Compilation
Vol.5 No.2 Mei 2023

Salah satu kontribusi utama penelitian ini terletak pada kegunaan praktis model prediksi risiko yang dikembangkan. Model yang dihasilkan mampu mengklasifikasikan kondisi pasar ke dalam kategori *Low, Medium, dan High Risk* hanya berdasarkan data OHLCV yang diperoleh secara realtime melalui API. Otomatisasi ini sangat relevan dalam konteks pasar kripto yang bergerak cepat dan beroperasi selama 24 jam, di mana keterlambatan pengambilan keputusan dapat berdampak langsung pada potensi keuntungan maupun kerugian.

Model prediksi risiko yang dikembangkan dapat dijadikan sebagai sistem peringatan dini (early warning system), terutama untuk strategi perdagangan jangka pendek seperti scalping dan intraday trading. Sebaliknya, kondisi *Low Risk* dapat dimanfaatkan sebagai indikasi stabilitas pasar yang relatif lebih aman untuk melakukan entry secara bertahap, khususnya bagi trader yang mengedepankan pengendalian risiko dibandingkan agresivitas keuntungan.

Keunggulan lain dari sistem ini adalah kemampuannya untuk diintegrasikan ke dalam lingkungan perdagangan realtime, seperti dashboard analitik atau aplikasi trading berbasis web. Dengan memanfaatkan API pasar kripto, sistem dapat memberikan pembaruan risiko secara kontinu dan objektif, sehingga berfungsi sebagai alat pendukung keputusan (*decision support system*) bagi trader. Secara keseluruhan, implikasi praktis penelitian ini menunjukkan bahwa model machine learning tidak hanya relevan dalam konteks akademik, tetapi juga memiliki potensi implementasi nyata dalam aktivitas perdagangan kripto. Sistem prediksi risiko yang dihasilkan dapat digunakan oleh trader individu maupun dikembangkan lebih lanjut oleh penyedia platform trading sebagai fitur tambahan untuk manajemen risiko.

SIMPULAN

Penelitian ini berhasil membuktikan bahwa pendekatan *hybrid machine learning*—yang menggabungkan *unsupervised learning* (K-Means) dengan *supervised learning* (Random Forest dan Decision Tree)—efektif dalam memodelkan dan memprediksi risiko fluktuasi harga Bitcoin. Secara substansial, penelitian menunjukkan bahwa ketidakpastian pasar kripto yang sering dianggap acak (random), sebenarnya memiliki struktur pola yang dapat dikelompokkan secara matematis. Kompatibilitas antara tujuan deteksi dini dan hasil eksperimen terlihat pada performa model klasifikasi. Hal ini dikonfirmasi oleh akurasi model Decision Tree (99,85%) dan Random Forest (99,86%) yang nyaris sempurna . Implikasi praktis dari penelitian ini menawarkan prospek pengembangan sistem peringatan dini (*early warning system*) bagi para pelaku pasar. Model yang dihasilkan dapat diintegrasikan dengan API data *realtime* untuk memberikan sinyal "zona bahaya" saat pasar memasuki fase volatilitas ekstrem, sehingga mendukung pengambilan keputusan *trading* jangka pendek (intraday/scalping) yang lebih terukur. Meskipun demikian, penelitian ini memiliki keterbatasan karena hanya mengandalkan data teknikal (OHLCV) dari satu aset tunggal (Bitcoin). Peluang penelitian selanjutnya dapat difokuskan pada pengayaan fitur dengan memasukkan analisis sentimen berita atau metrik *on-chain* untuk menangkap faktor eksternal penggerak harga.

1 *EPIC: Exact Papers in Compilation*
Vol.5 No.2 Mei 2023

DAFTAR PUSTAKA

Commented [A4]: perbaiki masih sangat salah gunakan APA Sytle

Badriyah, L., & Khafidhoh, N. (2023). Sistem Informasi Administrasi Pembayaran Pada Pondok Pesantren As-Sa'idiyyah 1 Bahrul Ulum Berbasis Website. Nusantara of Engineering (NOE), 6(2), 118-123.

Fauzi, A., Maulidah, N., Supriyadi, R., Nalatissifa, H., & Diantika, S. (2025). Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random Forest. RIGGS: Journal of Artificial Intelligence and Digital Business, 4(1), 43-49.

Indraprakoso, D. (2023). Eksplorasi potensi penggunaan blockchain dalam optimalisasi manajemen pelabuhan di indonesia: Tinjauan literatur. Sanskara Manajemen Dan Bisnis, 1(03), 140-160.

Julianto, J. (2022). Analisis Investasi Dalam Memprediksi Pergerakan Harga Bitcoin Dengan Menggunakan Recurrent Neural Network Pada Platform Indodax. Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi, 8(2), 136-147.

Khafidhoh, N., & Munawarah, M. (2020). Clustering Data Obat-obatan Menggunakan Algoritma K-means. *Exact Papers in Compilation (EPiC)*, *2*(03), 293-298.

Khoirudin, D. H., Anam, C., & Khafidhoh, N. (2022). Sistem Pendukung Keputusan Penentuan Kelayakan Pengajuan Kredit Motor Berbasis Simple Additive Weighting (SAW): Study Kasus UD. Putra Mandiri Motor. *Exact Papers in Compilation (EPiC)*, *4*(1), 529-536.

Kurniawan, F. C., Sukrawan, Y., & Puspanikan, S. K. (2026). Analisis Bibliometrik dan Systematic Literature Review Hambatan Implementasi Blockchain pada Logistik Negara Berkembang: Perspektif Indonesia. Jurnal Teknologi dan Manajemen Industri Terapan, 5(1), 174-182.

Kurniawan, I. D., Sasono, S., Septiningsih, I., Santoso, B., & Harjono, M. R. (2013). Transformasi penggunaan cryptocurrency melalui Bitcoin dalam transaksi komersial dihubungkan dengan diskursus perlindungan hukum (legal protection) konsumen di Indonesia. Law Review, 12(3), 12.

Rachman, D. A., & Yochanan, D. E. DIAIS (2024). Dan R & D, 72-83.

Sari, A. N., & Gelar, T. (2024). Blockchain: Teknologi dan implementasinya. Jurnal Mnemonic, 7(1), 63-70.Nursikuwagus, A., Gunawan, H., & Alamsyah, I. (2024). *Indonesia Dengan Penerapan Algoritma K-Means*. *11*(2). Https://Doi.Org/10.30656/Jsii.V11i2.9276

Team, C. (2022). The 2022 crypto crime report. Available: go. chainalysis. com/2021-crypto-crime-report.

Wardhana, R. G., Wang, G., & Sibuea, F. (2023). Penerapan machine learning dalam prediksi tingkat kasus penyakit di Indonesia. Journal of Information System Management (JOISM), 5(1), 40-45.