

DETEKSI ANOMALI HARGA BITCOIN MENGGUNAKAN VARIATIONAL AUTOENCODER DAN EXTREME VALUE THEORY

Nur Arif^{1*}, Supatman²

^{1,2} Informatika, Universitas Mercu Buana Yogyakarta; Jl. Jembatan Merah No. 84C Gejayan, Yogyakarta 55283; 0274-584922

Received: 2 Maret 2025
Accepted: 29 Maret 2025
Published: 14 April 2025

Keywords:

Bitcoin;
Variational Autoencoder;
Extreme Value theory;
Deteksi Anomali;
Generalized Pareto
Distribution;

Correspondent Email:

18111055@student.mercubua
na-yogya.ac.id

Abstrak. Deteksi anomali pada harga Bitcoin menjadi tantangan penting dalam menganalisis volatilitas pasar cryptocurrency. Fluktuasi yang tajam dan tak terduga memerlukan metode yang sensitif dalam mendeteksi peristiwa ekstrim. Penelitian ini mengusulkan Kombinasi Variational Autoencoder(VAE) dan Extreme Value Theory(EVT) untuk mendeteksi anomali. Data yang digunakan diambil dari situs web [investing.com](https://www.investing.com), yang mencakup 1461 data pelatihan, 151 data validasi dan 500 data uji. VAE digunakan untuk menghitung rekonstruksi error, kemudian data dianalisis menggunakan EVT untuk memodelkan distribusi tail error menggunakan Generalized Pareto Distribution (GPD). Anomali didefinisikan berdasarkan threshold yang dihitung dari persentil distribusi error, dengan deteksi lebih sensitif terhadap data ekstrem. Metode ini diuji dengan menghitung metrik precision, recall, F1-score, dan accuracy. Hasil menunjukkan bahwa kombinasi VAE dan EVT efektif dalam mendeteksi anomali ekstrem, dengan hasil evaluasi yang baik dan akurat. Penelitian ini berkontribusi pada pengembangan model deteksi anomali yang lebih tangguh, terutama untuk pasar cryptocurrency yang sangat volatil. Hasil ini penting untuk mengidentifikasi potensi risiko atau peluang dalam pasar yang sangat volatil.

Abstract. Anomaly detection in Bitcoin price is an important challenge in analyzing cryptocurrency market volatility. Sharp and unpredictable fluctuations require a sensitive method to detect extreme events. This study proposes a combination of Variational Autoencoder (VAE) and Extreme Value Theory (EVT) to detect anomalies. The data used are taken from the [investing.com](https://www.investing.com) website, which includes 1461 training data, 151 validation data and 500 test data. VAE is used to calculate the error reconstruction, then the data is analyzed using EVT to model the tail error distribution using the Generalized Pareto Distribution (GPD). Anomalies are defined based on the threshold calculated from the percentile of the error distribution, with detection being more sensitive to extreme data. This method is tested by calculating the metrics of precision, recall, F1-score, and accuracy. The results show that the combination of VAE and EVT is effective in detecting extreme anomalies, with good and accurate evaluation results. This study contributes to the development of a more robust anomaly detection model, especially for the highly volatile cryptocurrency market. These results are important for identifying potential risks or opportunities in a highly volatile market..

1. PENDAHULUAN

Bitcoin diperkenalkan Satoshi Nakamoto pada 2008 melalui *whitpaper* “*Bitcoin: A Peer-to-Peer Electronic Cash System*”, yang merupakan mata uang digital terdesentralisasi dengan mengandalkan teknologi *Blockchain* untuk mencatat transaksi. Bitcoin didasarkan pada jaringan *peer-to-peer* yang dirancang untuk transaksi melalui internet secara langsung tanpa memerlukan pihak ketiga[1]. Bitcoin memiliki keterkaitan erat dengan *Blockchain*, jenis basis data baru yang menggunakan buku besar terdistribusi untuk menyimpan dan memvalidasi transaksi secara aman diseluruh jaringan komputer. Bitcoin sebagai mata uang digital pertama dan paling populer, seringkali mengalami lonjakan dan penurunan harga yang tajam. Hal ini menjadi tantangan bagi investor untuk mengidentifikasi pergerakan harga yang tidak normal atau anomali, sehingga menjadi indikasi adanya manipulasi pasar atau peluang investasi[2].

Deteksi anomali adalah proses mencari data dengan perilaku yang berbeda dari biasanya. Anomali dihasilkan oleh aktivitas abnormal seperti serangan dunia maya dan penipuan kartu kredit[3]. Bitcoin menjadi topik yang menarik banyak perhatian dalam beberapa tahun ini. Sebagai aset digital yang volatilitasnya tinggi, Bitcoin sering mengalami fluktuasi besar dalam waktu singkat[4], yang dapat menciptakan potensi terjadinya anomali. Pergerakan harga yang cepat dan tak terduga ini memunculkan resiko tinggi bagi investor.

Berbagai penelitian sebelumnya, telah menggunakan berbagai teknik untuk mendeteksi anomali, termasuk analisa statistik dan teknik machine learning. Pada penelitian yang dilakukan oleh Zafrah, dkk, dalam penggunaan metode *Variational Autoencoder* untuk mendeteksi anomali jaringan berdasarkan fitur aliran data, menunjukkan bahwa penggunaan *Variational Autoencoder* lebih unggul dibandingkan *Autoencoder* dan *One-Class Vector Machine*, berdasarkan analisis *ROC curve* dan area dibawah kurva *ROC (AUC-ROC)*[5]. Selanjutnya pada penelitian deteksi anomali untuk memantau kondisi peralatan melalui data berbasis waktu. Dalam penelitian ini peneliti menggabungkan *Long Short-Term Memory (LSTM)*, *Variational Autoencoder* dan *GAN*, menunjukkan kemampuan pemetaan encoder dan diskriminasi discriminator. Hasil

eksperimen menunjukkan bahwa metode dapat mendeteksi anomali dengan cepat dan akurat[6].

Meskipun ada beberapa penelitian yang membahas deteksi anomali *cryptocurrency*, namun penelitian – penelitian sebelumnya lebih berfokus pada penggunaan metode *deep learning* atau metode statistik tradisional. Di sisi lain belum banyak penggunaan model deteksi anomali yang secara efektif menangani data yang memiliki distribusi ekstrim. Dengan demikian penelitian ini bertujuan untuk menggabungkan *Variational Autoencoder* untuk representasi data dan *Extreme Value Theory* untuk pemodelan distribusi ekstrim. Diharapkan penelitian ini dapat berkontribusi terhadap pengembangan metode deteksi anomali dan memberikan pemahaman yang lebih dalam mengenai fluktuasi harga bitcoin dan resiko investasi.

2. TINJAUAN PUSTAKA

2.1. Bitcoin

Bitcoin menggunakan sistem *peer-to-peer (P2P)*, sehingga pengguna dapat melakukan transaksi langsung tanpa perantara seperti bank atau lembaga keuangan lainnya. Dalam sistem ini, setiap transaksi di verifikasi oleh jaringan node yang tersebar diseluruh dunia menggunakan kriptografi dan konsensus berbasis *proof-of-work (PoW)*[7].

2.2. Deteksi Anomali

Deteksi anomali digunakan untuk mengidentifikasi aktivitas mencurigakan yang mungkin menunjukkan upaya peretasan atau pelanggaran data[8].

2.3. Variational Autoencoder

Variational Autoencoder adalah sebuah model generatif yang digunakan dalam pembelajaran mesin untuk mempelajari distribusi data baru yang menyerupai data yang telah dilatih. VAE adalah jenis *autoencoder* yang memperkenalkan teknik *variational inference* untuk mempelajari representasi laten yang lebih baik dalam data[9].

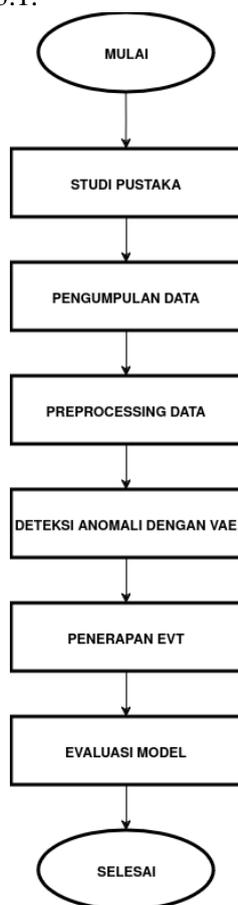
2.4. Extreme Value Theory

Extreme Value Theory adalah pendekatan statistik yang digunakan untuk menganalisis perilaku ekstrim atau kejadian langka dalam

data. EVT berfokus pada *tail distribution*. Distribusi kejadian ekstrim dimodelkan menggunakan dua pendekatan utama yaitu : *Generalized Extreme Value (GEV)* dan *Generalized Pareto Distribution (GPD)*[10].

3. METODE PENELITIAN

Metodologi yang digunakan pada penelitian ini melalui beberapa tahapan utama untuk mendeteksi anomali pada data harga Bitcoin. Tahapan utama pada penelitian ini dapat dilihat pada Gambar 3.1.



Gambar 3.1 Alur Penelitian

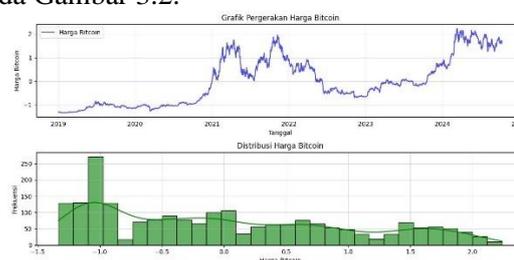
3.1. Studi Pustaka

Pada tahap ini dilakukan pencarian dan pengumpulan informasi dengan tujuan untuk memahami konsep dasar dan metode yang digunakan dalam penelitian. Dalam hal ini, peneliti mengumpulkan berbagai sumber dari jurnal, buku dan artikel terkait. Dari hasil identifikasi yang dilakukan, peneliti menyimpulkan bahwa penggunaan kombinasi *Variational Autoencoder* untuk mengenali pola data normal dan *Extreme value Theory* untuk

deteksi kejadian ekstrim merupakan pendekatan yang relevan dan efektif dalam deteksi anomali pada data harga Bitcoin.

3.2. Pengumpulan Data

Dataset yang digunakan pada penelitian ini adalah data historis Bitcoin yang diunduh secara manual dari situs web investing.com. Data tersebut mencakup informasi harga Bitcoin dari periode 1 Januari 2019 hingga 12 November 2024, dengan total 2113 data. Data distribusi dan pergerakan harga Bitcoin yang digunakan dalam penelitian ini dapat dilihat pada Gambar 3.2.



Gambar 3.2 Distribusi Dan Pergerakan Harga Bitcoin

3.3. Preprocessing Data

a. Data Selection

Data selection dilakukan untuk memastikan dataset hanya mengandung informasi yang relevan[11]. Data yang tidak relevan dihapus untuk mengurangi dimensi data agar fokus analisis hanya pada pola penting dan menghindari data yang tidak diperlukan.

b. Data Cleaning

Tahapan *data cleaning* bertujuan untuk membersihkan data dari format yang tidak konsisten dan memastikan data berada dalam format yang sesuai untuk analisis[12]. *Missing Value* pada data yang digunakan ditangani dengan dua cara. Pertama dengan mengisi nilai yang hilang pada kolom “tanggal” menggunakan teknik *forward fill* sehingga nilai yang hilang akan digantikan dengan nilai sebelumnya. Sedangkan pada kolom numerik *Missing Values* diisi dengan median dari kolom tersebut.

c. Data Normalization

Dataset dinormalisasi agar memiliki rentan yang lebih stabil sehingga fitur – fitur dalam dataset memiliki skala yang serupa. Proses normalisasi data pada penelitian ini dilakukan dengan beberapa teknik dengan tujuan agar distribusi data lebih terkontrol. Penggunaan *Log Transformation* pada kolom “vol” dilakukan untuk membantu mengurangi *skewness*. *StandardScaler* di terapkan pada kolom numerik dengan tujuan mengubah data memiliki rata – rata 0 dan standard deviasi 1 sehingga model tidak akan terbebani oleh skala fitur. Pada kolom perubahan harga, *RobustScaler* dipilih karena lebih tahan terhadap *outlier* dan ideal untuk data yang mengandung nilai ekstrim.

d. Spilt Dataset

Dataset yang telah diproses melalui beberapa tahapan, selanjutnya dilakukan pembagian data menjadi data *training*, *validation*, dan *testing*. Pembagian data ini bertujuan mengevaluasi performa model dan memastikan model *generalisasi* dengan baik. Pembagian data dilakukan dengan berbasis waktu. 70% untuk *training*, 15% untuk *validation* dan 15% untuk *testing*. Informasi lengkap pembagian dataset dapat dilihat pada Tabel 3.1.

Dataset	Jumlah Baris
Train Data	1461
Validation data	151
Test Data	500
Total	2112

a. Data Loader

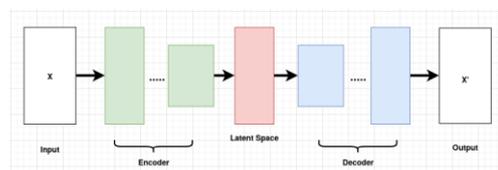
Pada penelitian ini *Data Loader* digunakan untuk mempermudah dan mempercepat proses training. Dataset dibagi menjadi batch – batch yang sangat penting dalam efisiensi memori dan pelatihan model lebih cepat. Informasi lengkap pembagian data

dalam tahapan *Data Loader* dapat dilihat pada Tabel 3.2.

Dataset	Baris	Batch
Train Data	1461	46
Validation Data	151	5
Test Data	500	16
Total	2112	67

3.4. Arsitektur Variational Autoencoder

Variational Autoencoder menggunakan dua komponen utama untuk mempelajari distribusi data yaitu *Encoder* dan *Decode*. *Encoder* mengambil data input kemudian memetakannya ke dalam distribusi probabilistik dalam ruang laten dan menghasilkan parameter distribusi *mean* (μ) dan *variance* (σ^2). Sedangkan *Decoder* mengambil sampel dari distribusi laten dan berusaha merekonstruksi kembali ke data asli. Sehingga model tidak hanya mempelajari representasi laten yang deterministik tapi juga distribusi probabilitas dari representasi data tersebut. Detail arsitektur *Variational Autoencoder* dapat dilihat pada Gambar 3.3.



Gambar 3.3 Arsitektur VAE

3.5. Penerapan Extreme Value Theory

Extreme Value Theory diterapkan pada distribusi residu rekonstruksi untuk mendeteksi nilai ekstrem yang signifikan. Ambang batas dihitung dari tail distribusi residual dengan analisis probabilistik. *Extreme Value Theory* diterapkan untuk memodelkan distribusi tail dari rekonstruksi error yang dihasilkan oleh *Variational Autoencoder*. Dalam mendeteksi anomali menggunakan EVT pertama yang dilakukan adalah menentukan *threshold*. Rumus dalam menentukan *threshold* ditunjukkan pada persamaan 1.

$$Threshold = \mu + threshold_{factor} \times \sigma \tag{1}$$

Setelah *threshold* ditentukan, *Generalized Pareto Distribution* digunakan untuk memodelkan distribusi ekor dari kesalahan yang dihitung menggunakan persamaan 2.

$$F(x) = 1 - \left(1 + \frac{\varepsilon(x - \mu)}{\sigma}\right) \quad (2)$$

Keterangan :

F(x) = Fungsi kumulatif GPD

x = Nilai yang lebih besar dari *threshold*

μ = Batas bawah

σ = Parameter skala dari GPD

ε = Parameter bentuk dari GPD

3.6. Evaluasi Model

Pada tahap ini dilakukan pengujian untuk mengetahui seberapa baik model dalam merepresentasikan data. *Confussion matrix* digunakan untuk mengevaluasi kinerja model dengan membandingkan hasilnya terhadap label sebenarnya[13]. Evaluasi performa dilakukan menggunakan beberapa metrik evaluasi seperti *precision*, *recall*, *F1-score* dan *accuracy*. Setelah model diuji secara menyeluruh, selanjutnya dapat disimpulkan dan memberikan gambaran yang lebih jelas tentang kemampuan VAE dalam mendeteksi anomali dan seberapa efektif EVT dalam mendukung deteksi anomali.

4. HASIL DAN PEMBAHASAN

4.1. Preprocessing Data

Preprocessing data dilakukan untuk memastikan model dapat dilatih dengan data yang berkualitas. Semua proses yang dilakukan pada tahapan *preprocessing* bertujuan untuk membuat model dapat memproses dataset dengan baik dan efektif. Pada penelitian ini dataset berhasil dimuat dengan baris dan kolom yang sesuai, setelah sebelumnya dilakukan pemilihan kolom yang relevan. Hasil *preprocessing* menunjukkan dataset sudah siap digunakan untuk model dalam proses yang lebih lanjut. Tipe data sudah berhasil dikonversi dengan benar, nilai yang hilang berhasil ditangani dan normalisasi data telah sukses dilakukan. Pembagian data menjadi set pelatihan, validasi dan pengujian berhasil diterapkan dengan jumlah *batch* yang tepat untuk setiap subsetnya. Hasil tahapan *preprocessing data* dapat dilihat pada gambar 4.1.

The screenshot shows a data preprocessing interface. At the top, it displays the number of missing values for various columns before and after the process. Below this, a table shows the normalized data with columns: Terakhir, Pembukaan, Tertinggi, Terendah, Vol., and Perubahan%. The table contains 10 rows of data. Below the table, there are statistics for the training, validation, and test data, including the number of rows and the number of batches used for each.

	Terakhir	Pembukaan	Tertinggi	Terendah	Vol.	Perubahan%
0	1.722362	1.698624	1.675482	1.777824	-0.433487	0.233378
1	1.696324	1.586408	1.671571	1.651401	-0.219441	1.202703
2	1.584443	1.602371	1.567266	1.595988	-0.233720	-0.195946
3	1.600462	1.680703	1.629052	1.605849	-0.329256	-0.851351
4	1.678777	1.684287	1.662121	1.746138	-0.365953	-0.067568
5	1.683318	1.746679	1.724925	1.761516	-0.220056	-0.327793
6	1.712723	1.675833	1.648981	1.725757	-0.702596	0.391882
7	1.673878	1.677038	1.620519	1.736890	-0.727077	-0.030405
8	1.674882	1.608650	1.625778	1.671830	-0.302528	0.719595
9	1.606735	1.603042	1.579503	1.642141	-0.242015	0.037162

Gambar 4.1 Hasil Preprocessing Data

4.2. Implementasi Model

4.2.1. Variational Autoencoder (VAE)

Pada penelitian ini model VAE menggunakan *activation function ReLu* untuk lapisan *encoder* dan *decoder*. Untuk memastikan data rekonstruksi berada dalam rentang yang sesuai, peneliti menggunakan *tanh* atau *sigmoid* pada lapisan terakhir. Peneliti menggunakan model VAE untuk mendeteksi anomali *Bitcoin* dengan cara mengubah data harga menjadi representasi probabilistik untuk mencapai pemahaman lebih mendalam terhadap *fluktuasi* pasar. Dengan menggunakan *MSE* dan *KL divergence* sebagai bagian dari fungsi loss, model akan menjadi lebih akurat dalam mendeteksi anomali berdasarkan kesalahan rekonstruksi. Kemudian untuk meningkatkan kinerja model, penelitian ini menggunakan *hyperparameter tuning* dengan *optuna* sehingga dapat memilih konfigurasi optimal dalam tugas deteksi anomali. Parameter pelatihan yang digunakan dalam proses pelatihan model VAE dapat dilihat pada Tabel 4.1.

Tabel 4.1 Parameter Pelatihan Model VAE

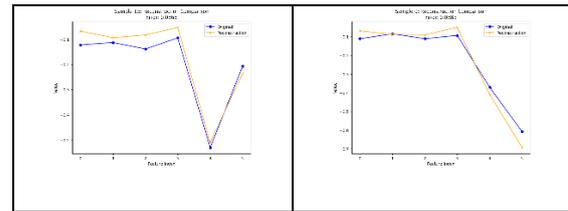
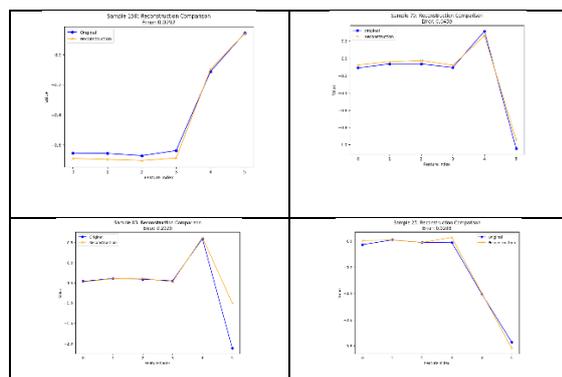
Parameter	Nilai
Latent Dimension	128 - 256
Learning Rate	1e-5 – 1e-3
KL Weight	0.00001 – 0.0005
Optimizer	Adam
Early Stopping Patience	20 – 50
Batch Size	32 – 128
Epoch	200 - 400
Scheduler	ReduceLRonPlateau
Dropout Rate	0.5

Optuna adalah sebuah framework untuk optimasi berbasis algoritma pencarian. Sehingga secara otomatis mencari kombinasi terbaik untuk *Hyperparameter*[14]. Kemudian setelah pencarian selesai, parameter terbaik akan disimpan untuk digunakan dalam melatih model. Hasil *Hyperparameter Tunning* dapat dilihat pada Tabel 4.2.

Tabel 4.2 Hasil Hyperparameter Tunning

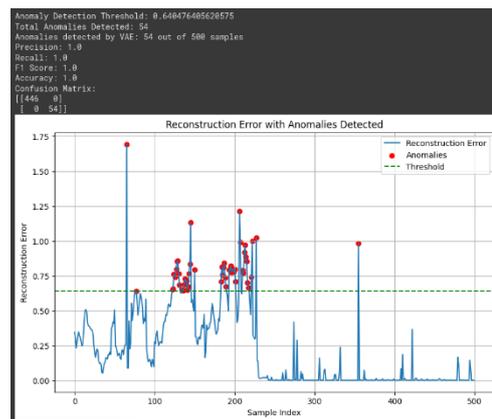
Parameter	Nilai
Latent Dimension	131
KL Weight	3.566289078895205e-05
Early Stopping	28
Batch Size	64
Epoch	386
Use Tanh	True
Learning Rate	0.00016037917841844166

Dari hasil pelatihan model yang telah dilakukan, menunjukkan VAE efektif dalam merekonstruksi data normal dengan menghasilkan rekonstruksi error yang sangat rendah. Namun pada data yang memiliki *fluktuasi* lebih tajam, VAE mulai kesulitan dan menghasilkan error yang lebih tinggi. Disisi lain VAE menunjukkan kemampuannya dalam memodelkan distribusi data dengan baik dan merekonstruksi data tidak terlalu jauh dari pola yang diajarkan. Hasil pelatihan model VAE dapat dilihat pada Gambar 4.2.



Gambar 4.2 Sample hasil rekontruksi

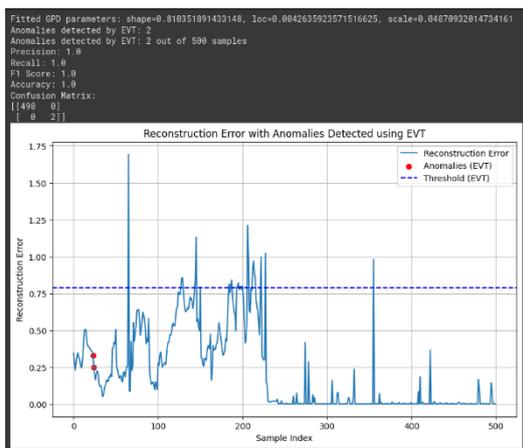
Dalam implementasi deteksi anomali menggunakan *Variational Autoencoder*, proses dimulai dengan mengubah model ke mode evaluasi dan menghitung kesalahan rekonstruksi (MSE). Kesalahan dihitung pada setiap sample dalam *batch* kemudian setiap sample akan dihitung rata – ratanya. Seluruh kesalahan rekonstruksi pada dataset akan dihimpun untuk menentukan ambang batas dinamis. Sample yang memiliki kesalahan rekonstruksi melebihi *threshold* akan dianggap sebagai anomali. Hasil deteksi anomali menggunakan VAE dapat dilihat pada Gambar 4.2.



Gambar 4.2 Deteksi Anomali menggunakan VAE

4.2.2. Extreme Value Theory (EVT)

Implementasi deteksi anomali dengan EVT dilakukan dengan cara mengurutkan hasil rekonstruksi error (MSE) yang telah dihitung menggunakan model VAE pada setiap sample. Penentuan *threshold* di lakukan berdasarkan percentile dari distribusi kesalahan yang membatasi nilai – nilai ekstrim. Kemudian *Generalized pareto distribution(GPD)* digunakan untuk memodelkan *tai distribution* dari kesalahan yang lebih besar dari *threshold*. Hasil deteksi anomali menggunakan EVT dapat dilihat pada Gambar 4.3.



Gambar 4.3. Deteksi Anomali Menggunakan EVT

Evaluasi model dilakukan dengan mengukur kinerja model berdasarkan beberapa metrik seperti *loss* dan *accuracy*. Selain itu model juga dievaluasi berdasarkan *precision*, *recall* dan *F1-score* untuk mengetahui sejauh mana kemampuan model dalam mendeteksi anomali. Berikut adalah hasil evaluasi model berdasarkan *confusion matrix* dan metrik evaluasi yang digunakan.

Matrik	Nilai
Train Loss	0.0504
Validation Loss	0.0532
Precision	1.0
Recall	1.0
F1-Score	1.0
Accuracy	1.0
Confusion matrix	[[498,0],[0,2]]

Kombinasi *Variational Autoencoder(VAE)* dan *Extreme Value Theory(EVT)* memberikan pendekatan yang komprehensif dan saling melengkapi. VAE mendeteksi anomali berdasarkan error rekonstruksi dengan cara yang sangat sensitif terutama anomali yang memiliki perbedaan besar dalam error rekonstruksi. Disisi lain, EVT fokus pada *tai distribution* dari error rekonstruksi. Dengan memodelkan distribusi ekstrem menggunakan *GPD(Generalized Pareto Distribution)*. Sehingga anomali yang jarang terjadi tetapi signifikan menjadi terdeteksi.

5. KESIMPULAN

- a. Penelitian ini berhasil menggabungkan kedua metode.

Dari hasil pengujian menunjukkan anomali yang terdeteksi oleh VAE selanjutnya di verifikasi oleh EVT, untuk memastikan hanya anomali paling signifikan yang terdeteksi. Ini dapat mengurangi kemungkinan *False Positives* dan meningkatkan akurasi deteksi anomali.

- b. VAE dapat digunakan untuk mendeteksi banyak jenis anomali berdasarkan error rekonstruksi, sementara EVT bertindak sebagai mekanisme verifikasi berdasarkan model distribusi tail.
- c. VAE akan mendeteksi banyak anomali jika *threshold* nya rendah. Sehingga perlu penyesuaian lebih lanjut *threshold* dan parameter yang digunakan.
- d. EVT tidak cukup sensitif terhadap anomali yang lebih halus, karena model ini berfokus pada tail distribusi yang cenderung hanya mengidentifikasi anomali besar saja.

Penyesuaian *threshold* dan parameter memiliki peran sangat penting untuk menghindari *False Positives*. Dengan pengembangan lebih lanjut pada *threshold adaptif* dan penerapan pada data lebih bervariasi kombinasi kedua model ini akan memiliki potensi besar untuk analisis pasar *cryptocurrency*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2008. [Online]. Available: www.bitcoin.org
- [2] C. Rose, "The Evolution Of Digital Currencies: Bitcoin, A Cryptocurrency Causing A Monetary Revolution," Aug. 2015.
- [3] D. R. K. Saputra, Y. V. Via, and A. N. Sihananto, "DETEKSI ANOMALI MENGGUNAKAN ENSEMBLE LEARNING DAN RANDOM OVERSAMPLING PADA PENIPUAN TRANSAKSI KEUANGAN," *Jurnal Informatika dan Teknik Elektro Terapan*, vol.

- 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4910.
- [4] D. Widyanti, S. Sudarno, and T. Widiharih, "ANALISIS VOLATILITAS BITCOIN MENGGUNAKAN MODEL ARCH DAN GARCH," *Jurnal Gaussian*, vol. 12, no. 2, pp. 254–265, Jul. 2023, doi: 10.14710/j.gauss.12.2.254-265.
- [5] S. Zavrak and M. Iskefiyeli, "Anomaly-Based Intrusion Detection from Network Flow Features Using Variational Autoencoder," *IEEE Access*, vol. 8, pp. 108346–108358, 2020, doi: 10.1109/ACCESS.2020.3001350.
- [6] Z. Niu, K. Yu, and X. Wu, "LSTM-based vae-gan for time-series anomaly detection," *Sensors (Switzerland)*, vol. 20, no. 13, pp. 1–12, Jul. 2020, doi: 10.3390/s20133738.
- [7] R. S. Wardhani and W. Anggita, "Pengaruh Bitcoin dan Nilai Tukar Rupiah Terhadap Harga Saham (Studi Pada Sub Sektor Perbankan Yang Terdaftar di Bursa Efek Indonesia Periode 2020-2022)," *JURNAL ILMIAH GLOBAL EDUCATION*, vol. 2, Mar. 2024, doi: 10.55681/jige.v5i1.2681.
- [8] Carudin Carudin, Marisa Marisa, Munarwan Munarwan, Felix Reba, and Mayko E Koibur, *Buku Ajar Data Mining*, vol. 139. PT. Sonpedia Publishing Indonesia, 2024.
- [9] D. P. Kingma and M. Welling, "An Introduction to Variational Autoencoders," *Foundations and Trends® in Machine Learning*, vol. 12, no. 4, pp. 307–392, 2019, doi: 10.1561/22000000056.
- [10] F. F. Najamuddin, E. T. Herdiani, and A. K. Jaya, "VALUE AT RISK ESTIMATION USING EXTREME VALUE THEORY APPROACH IN INDONESIA STOCK EXCHANGE," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 18, no. 2, pp. 0695–0706, May 2024, doi: 10.30598/barekengvol18iss2pp0695-0706.
- [11] A. Srirahayu and L. Setya Pribadie, "JURNAL ILMIAH INFORMATIKA GLOBAL Review Paper Data Mining Klasifikasi Data Mining", doi: 10.36982/jiig.v13i2.2307.
- [12] A. M. Putri, W. Khafa Nofa, D. Anggraini, and P. Hapsari, "PENERAPAN METODE BERT UNTUK ANALISIS SENTIMEN ULASAN PENGGUNA APLIKASI SEGARI DI GOOGLE PLAY STORE," *JUIT*, vol. 4, no. 1, [Online]. Available: <https://databoks.katadata.co.id>
- [13] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf Process Manag*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.
- [14] A. Tikaningsih, P. Lestari, A. Nurhopipah, I. Tahyudin, E. Winarto, and N. Hassa, "Telematika Optuna Based Hyperparameter Tuning for Improving the Performance Prediction Mortality and Hospital Length of Stay for Stroke Patients," vol. 17, no. 1, pp. 1–16, 2024, doi: 10.35671/telematika.v17i1.2816.