

Integrasi Metrik *On-Chain* dan *Patterned Dataset Model* Menggunakan K-Means untuk Potensi Maksimal Profit di Bitcoin

Gamar Ramadhani Malik¹, Rizky Parlika^{2*}, Kartini³

^{1,2,3} Informatika, UPN “Veteran” Jawa Timur
122081010229@student.upnjatim.ac.id
2rizkyparlika.if@upnjatim.ac.id
3kartini.if@upnjatim.ac.id

*Corresponding author email: rizkyparlika.if@upnjatim.ac.id

Abstrak—Pasar aset kripto khususnya Bitcoin memiliki volatilitas ekstrem dan pergerakan *non-Gaussian* yang menyulitkan untuk memprediksi arah harga jika hanya bergantung pada data historis konvensional (OHLC). Penelitian ini mengusulkan sebuah kebaruan dengan mengintegrasikan data pasar tradisional dan metrik dari *on-chain* secara spesifik *active spending addresses* untuk mengekstraksi sinyal perdagangan yang optimal. Data historis dari Agustus 2011 hingga Februari 2026 diproses menggunakan *Patterned Dataset Model* untuk mengklasifikasikan kondisi pasar menjadi *Complete*, *Rocket*, dan *Dip*. Algoritma K-Means *Clustering* kemudian diterapkan untuk memetakan fase akumulasi fundamental. Berdasarkan evaluasi metrik *Silhouette Coefficient* dan *Davies-Bouldin Index*, dataset pada kondisi *Dip* terbukti menghasilkan struktur *cluster* pemisahan anomali terbaik. Titik anomali pada *cluster* harga terendah yang divalidasi oleh lonjakan *active spending addresses* kemudian diekstraksi sebagai sinyal beli. Pengujian *trading rules* dengan skenario penahanan aset minimal 24 jam hingga maksimal akhir bulan menunjukkan performa yang sangat baik. Secara keseluruhan model ini berhasil memvalidasi 1.744 sinyal beli dengan tingkat kemenangan mencapai 99.14%, rata-rata *Return of Investment* (ROI) sebesar 19,49% per transaksi, dan akumulasi profit maksimal hingga 300.612 USD. Hasil ini membuktikan bahwa integrasi metrik *on-chain* pada dataset berpola kondisi *Dip* mampu mereduksi risiko sinyal palsu secara signifikan dan memaksimalkan profitabilitas investor

Kata Kunci— Bitcoin, *Patterned Dataset Model*, K-Means, *On-Chain*, Machine Learning

I. PENDAHULUAN

Pasar aset kripto terkhususnya Bitcoin telah sukses menjadi instrumen investasi yang sangat menarik dan mencuri perhatian global. Sehingga persepsi dari masyarakat bisa tergeser dalam cara mereka memandang sistem keuangan yang modern. Ditengah berbagai tantangan yang kompleks, investasi Bitcoin hadir sebagai peluang sebagai instrumen investasi baru bagi para investor. Sebagai aset digital utama, Bitcoin memfasilitasi transaksi dari secara langsung antarindividu (*peer-to-peer*) yang digerakkan oleh teknologi Bitcoin, sehingga mengeliminasi kebutuhan akan pihak ketiga atau lembaga keuangan[1]

Bitcoin beroperasi dengan menggunakan sistem desentralisasi sehingga tidak akan terikat pada kendali lembaga keuangan manapun. Karakteristik ini yang menjadi pendorong popularitas Bitcoin sebagai instrumen investasi di kalangan investor. Terlebih lagi para investor memanfaatkan Bitcoin

tidak hanya untuk melindungi nilai aset mereka, tetapi juga ekspektasi untuk memperoleh imbal hasil yang signifikan[2]. Potensi keuntungan yang besar akan selalu berbanding lurus dengan tingginya risiko yang ditanggung. Kondisi ini dipicu oleh sifat pergerakan harga dari Bitcoin yang memiliki volatilitas tinggi serta pola distribusi miring atau bisa disebut juga dengan distribusi *non-Gaussian*[3]

Karakteristik pergerakan *non-Gaussian* dan volatilitas ekstrem ini terlihat sangat jelas ketika meninjau dinamika pasar pada periode 2018 hingga 2022 yang merupakan salah satu fase paling bergejolak dalam sejarah Bitcoin. Pada rentang waktu tersebut pasar mengalami siklus fluktuasi yang sangat tajam diawali dengan fase *crypto winter* di tahun 2018 yang menekan harga secara signifikan dan disusul oleh kepanikan pasar global akibat pandemi COVID-19 pada awal 2020. Namun pasca dari fluktuasi tersebut kapitalisasi pasar Bitcoin justru melonjak secara pesat hingga menembus sekitar US\$1,274 triliun pada bulan September tahun 2021, sebelum akhirnya kembali terkoreksi tajam memasuki siklus bear market di awal tahun 2022 dengan nilai kapitalisasi pasar menyentuh US\$578,586 miliar[4].

Dinamika harga yang sangat fluktuatif dan sulit ditebak ini menegaskan bahwa analisis Bitcoin tidak cukup jika hanya bergantung pada data harga historis seperti data OHLC (*Open, High, Low, dan Close*). Keterbatasan data pasar dalam menangkap nilai dan sentimen perilaku investor menuntut adanya pendekatan baru dalam pemodelan prediksi arah harga[5]. Untuk mengantisipasi risiko dari pergerakan *non-Gaussian* tersebut diperlukan pemodelan dataset historis dari Bitcoin untuk membaca kondisi pasar secara lebih akurat.

Berbagai model prediksi yang ada saat ini masih sering mengandalkan data riwayat historis Bitcoin secara mentah tanpa melalui pemodelan terlebih dahulu. Oleh karena itu diperlukan sebuah pendekatan yang berbeda dimana data riwayat historis diekstraksi dan dibentuk polanya terlebih dahulu[6]. Membangun dari landasan tersebut penelitian ini mengembangkan konsep pemodelan yang secara khusus memproses dan mempola data riwayat historis Bitcoin. Mengacu pada penelitian yang diteliti oleh R. Parlika(2024) yang berfokus pada ekstraksi data riwayat historis pasar konvensional seperti harga OHLC[7]. Penelitian ini mengusulkan sebuah kebaruan dengan memperkaya dataset melalui integrasi metrik *on-chain*.

Mengintegrasikan dengan *on-chain* bertujuan untuk membaca

aktivitas fundamental dan intrinsik dari jaringan Bitcoin itu sendiri secara lebih mendalam. Berbeda dengan data historis yang seringkali sangat dipengaruhi oleh sentimen sesaat dan spekulasi pergerakan harga data *on-chain* menawarkan keunggulan berupa kumpulan informasi yang terekam secara permanen, transparan, dan tidak dapat dimanipulasi di dalam buku besar publik (*public ledger*) Blockchain[8] Data *on-chain* menyajikan metrik yang sangat komprehensif mencakup seluruh aktivitas jaringan mulai dari jumlah transaksi, banyaknya jumlah dompet, biaya transaksi, dan masih banyak lagi[9].

Berbagai metrik yang tersedia, penelitian ini memfokuskan pemodelan dataset dan menggabungkan metrik *active spending addresses*. Signifikasi peran metrik ini dikuatkan oleh studi literatur K Alabi (2017) yang membuktikan bahwa jaringan dari Blockchain Bitcoin mematuhi prinsip hukum *Metcalfe* sebuah jaringan digital termasuk pergerakan harga Bitcoin memiliki korelasi langsung dengan *active addreeses* di dalamnya. Oleh karena itu dalam kerangka analisis *on-chain* pada penelitian ini, indikator fundamental tersebut direpresentasikan secara kuantitatif melalui jumlah *active spending addresses* yang terekam setiap harinya[10].


Pemodelan dataset nantinya akan menghasilkan gambaran kondisi dari pergerakan harga Bitcoin. Secara teknis tahap awal ini memproses berbagai fitur dari data historis mentah seperti harga *close*, harga *high*, dan harga *low* dari data tersebut akan diformulasikan dengan menggunakan matematis. Melalui tahapan ekstraksi ini menciptakan dataset baru yang mengklasifikasikan pergerakan pasar ke dalam dua karakteristik utama: kondisi tren lonjakan harga(Kondisi *Rocket*) dan kejatuhan harga(Kondisi *Dip*)[6][11].

Setelah dataset berhasil diklasifikasikan ke dalam kondisi *Rocket* dan *Dip* langkah krusial selanjutnya adalah mengidentifikasi ke titik *entry* yang paling strategis bagi investor. Untuk mencapai hal tersebut penelitian ini menerapkan metode pengelompokan menggunakan algoritma K-Means[12]. Proses pengelompokan ini mengintegrasikan metrik *on-chain active spending addresses* ke dalam dataset. Tujuannya adalah untuk memetakan titik *entry* dalam satu bulan yang secara bersamaan dengan tingginya tingkat aktivitas pengeluaran di dalam jaringan. Titik temu antara harga yang terekam dan fundamental jaringan yang aktif ini mengindikasikan adanya fase akumulasi yang kuat.

Titik-titik krusial yang berhasil diidentifikasi dari klaster tersebut kemudian akan ditandai dan disimpan sebagai sinyal pembelian terkonfirmasi. Sebagai tindak lanjut dari pemetaan ini, skenario proyeksi keuntungan dirancang dengan strategi menahan aset selama rentang waktu minimal 24 jam hingga batas waktu maksimal pada akhir bulan berjalan[6]. Strategi ini ditujukan untuk memberikan signal penjualan tepat di titik puncak pada bulan tersebut sehingga profitabilitas dapat dimaksimalkan berdasarkan pola data historis dan aktivitas *on-chain*.

II. METODOLOGI

Pada Bab ini akan menguraikan tahapan metodologi yang dirancang dan diterapkan dalam penelitian untuk mengidentifikasi sinyal pergerakan harga Bitcoin melalui integrasi metrik *on-chain* dan pemodelan dataset. Pendekatan sistematis diperlukan guna memastikan kelancaran pemrosesan data historis menjadi informasi fundamental yang siap diekstraksi. Secara garis besar alur kerja penelitian ini divisualisasikan melalui diagram alir pada Gbr 1 di bawah ini.



Gbr 1. Alur Tahapan Pemrosesan Data

Berdasarkan Gbr 1 kerangka penelitian ini dimulai dengan tahapan pengambilan dataset yang mencakup pengumpulan data harga historis konvensional beserta metrik *on-chain* (*active spending addresses*). Data mentah tersebut kemudian diproses pada tahap pemodelan dataset untuk membentuk pola kondisi pasar (*Rocket* dan *Dip*). Selanjutnya proses akan diteruskan pada tahap pengelompokan data menggunakan algoritma K-Means untuk memetakan titik anomali dan akumulasi. Sebagai muara dari keseluruhan analisis penelitian ini Menyusun *trading rules* untuk menentukan strategi *entry* dan *exit* yang optimal. Penjelasan lebih lanjut dan rinci mengenai setiap tahapan dalam diagram alir tersebut akan dibahas pada subbab berikut.

II.1. Pengambilan Dataset

Tahap pengumpulan data dalam penelitian ini dilakukan dengan mengombinasikan data pasar OHLC dan metrik *on-chain* (*active spending addresses*). Ekstraksi data *on-chain* dilakukan secara langsung dari *public ledger* Bitcoin menggunakan layanan Google BigQuery untuk menjamin transparansi dan validitas. Pengambilan dataset ditarik menggunakan rentang waktu harian yang mencakup periode 18 Agustus 2011 hingga 06 Februari 2026. Secara keseluruhan total data yang berhasil diekstraksi dan digabungkan berjumlah 5.274 baris data yang selanjutnya akan diproses lebih lanjut pada tahapan pemodelan dataset.

II.2. Pemodelan Dataset

Data mentah yang telah dikumpulkan selanjutnya distrukturkan menggunakan pemodelan dataset. Tahap ini memproses data harga histori meliputi harga tertinggi (*High/H*), terendah (*Low/L*) dan penutupan atau terkini (*Close/C*) untuk memetakan rentang fluktuasi harian menggunakan persamaan (1) hingga (5) yang bertujuan untuk mendapatkan nilai dari *Total Range(R)*, *Top Range (TR)*, *Lower Range (LR)*, *Percentage Top Range (PTR)*, *Percentage Lower Range (PLR)*.

$$R = H - L \quad (1)$$

$$TR = H - C \quad (2)$$

$$LR = C - L \quad (3)$$

$$PTR = \frac{TR}{R} \times 100\% \quad (4)$$

$$PLR = \frac{LR}{R} \times 100\% \quad (5)$$

Melalui perhitungan tersebut dapat dilakukan klasifikasi arah pergerakan pasar. Berdasarkan ekstraksi parameter ini dataset secara keseluruhan akan terbagi menjadi tiga kondisi utama, yaitu: kondisi *Complete* (representasi keseluruhan data berpola), Kondisi *Dip* atau tren turun ditandai dengan nilai $PTR = 100$ dan $PLR = 0$ serta kondisi *Rocket* atau tren naik ditandai dengan nilai $PLR = 100$ dan $PTR = 0$.

II.3. Pengelompokan Data

Tahap pengelompokan menggunakan algoritma K-Means terlebih dahulu diterapkan pada ketiga kondisi dataset yang telah dibentuk yaitu kondisi *Complete*, *Rocket*, dan *Dip*. Evaluasi awal ini dilakukan untuk mengidentifikasi kondisi mana yang memiliki karakteristik pemisahan data paling optimal dan terpisah dengan jelas. Untuk mengukur kualitas hasil pengelompokan tersebut penelitian ini menggunakan dua metrik evaluasi internal yaitu *Silhouette Coefficient* dan *Davies-Bouldin Index*.

Pada tahap ini, setiap titik data harian Bitcoin direpresentasikan menggunakan dua fitur utama, yaitu harga penutupan yang telah dinormalisasi (*Close_norm*) dan aktivitas *spending on-chain* yang telah dinormalisasi (*active_spending_norm*), keduanya diskalakan ke rentang 0–100 menggunakan *MinMaxScaler*. Proses pengelompokan dilakukan dengan membagi setiap subset kondisi ke dalam tiga kluster ($n_clusters = 3$) menggunakan parameter $random_state=42$ dan $n_init=10$ untuk menjamin konsistensi hasil. Pada kondisi *Dip*, kluster dengan nilai rata-rata *Close_norm* terendah diidentifikasi sebagai kluster target, yakni periode di mana harga Bitcoin berada pada titik paling tertekan secara historis dan berpotensi menjadi titik masuk bagi strategi pembelian.

a. Silhouette Coefficient

Silhouette Coefficient merupakan metrik evaluasi kualitas *clustering* yang mengkombinasikan dua metode utama yaitu kohesi (*cohesion*) dan separasi (*separation*). Metrik ini menilai seberapa erat hubungan antar data di dalam satu *cluster* yang sama sekaligus seberapa jauh jarak pemisahannya dengan *cluster* lain[13]. Metrik *Silhouette Coefficient* melibatkan beberapa tahapan matematis berikut:

Tahap pertama adalah menghitung rata-rata dari titik data Bitcoin misalkan i terhadap seluruh titik data lain yang berada di dalam *cluster* yang sama.

$$a(i) = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d(i, j) \quad (6)$$

Dengan j merupakan titik data lain di dalam *cluster* A, dan $d(i, j)$ adalah jarak (*Euclidean* atau *Manhattan*) antara titik i dan j .

Kedua menghitung rata-rata jarak dari titik i terhadap semua titik data pada *cluster* lain (C) di mana $A \neq C$

$$d(i, C) = \frac{1}{|C|} \sum_{j \in C} d(i, j) \quad (7)$$

Ketiga, mencari jarak rata-rata terkecil dari titik i ke *cluster* lain yang bukan *cluster*-nya sendiri:

$$b(i) = \min_{C \neq A} d(i, j) \quad (8)$$

Berdasarkan komponen tersebut, nilai *Silhouette Coefficient* untuk titik data i dirumuskan sebagai:

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (9)$$

Nilai $s(i)$ yang mendekati 1 mengindikasikan bahwa data telah berada telah pada *cluster* yang sangat tepat dan terpisah jauh dari *cluster* lain.

b. Davies-Bouldin Index

Davies-Bouldin Index (DBI) adalah metrik evaluasi internal yang digunakan untuk mengukur kualitas *cluster* berdasarkan rasio antara jarak antar *cluster* dan kepadatan *intra cluster*. Metrik ini menilai seberapa baik setiap *cluster* terpisah satu sama lain. Semakin kecil nilai DBI yang dihasilkan semakin baik kualitas *clustering* tersebut karena hal ini menunjukkan bahwa *cluster* yang terbentuk terpisah dengan batas yang jelas dan tidak saling tumpang tindih[14]. Sebaliknya sehingga pengelompokan dianggap kurang efektif.

Menurut penelitian yang dilakukan oleh Prasetya (2025), Langkah pertama dalam perhitungan DBI adalah mencari rasio perbandingan antara rata-rata jarak sebaran titik di dalam *cluster* (*Sum of Square Within*) atau SSW dengan antar pusat *cluster* (*Sum of Square Between*) atau SSB menggunakan *Euclidean Distance*[15]. Rasio ini didapatkan melalui persamaan berikut:

$$R_{i,j} = \frac{SSW_i + SSW_j}{SSB_{i,j}} \quad (10)$$


Selanjutnya, nilai rasio maksimal dari setiap pasangan *cluster* digunakan untuk menghitung nilai akhir DBI melalui persamaan:

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} (R_{i,j}) \quad (11)$$

Dengan k adalah jumlah total *cluster* yang terbentuk.

c. Visualisasi Data dan Hasil Komparasi

Sebelum mengevaluasi performa dari *clustering*, dataset yang telah dilakukan pemodelan data divisualisasikan terlebih dahulu. Pemetaan ini bertujuan untuk melihat persebaran titik data secara historis pada ketiga kondisi yang akan diuji (*Complete*, *Dip*, dan *Rocket*)



Gbr 2. Visualisasi Pemodelan Dataset pada Kondisi *Complete*, *Dip*, dan *Rocket*

Berdasarkan Gbr 2 panel pertama (atas) menampilkan Pemodelan Dataset pada kondisi *Complete* merepresentasikan seluruh Riwayat pergerakan harga secara utuh. Panel kedua (Tengah) mengilustrasikan kondisi *Dip* di mana titik-titik data terisolasi secara spesifik pada momen-momen saat harga mengalami tekanan atau berada di dasar fluktuasi harian. Sebaliknya panel ketiga (bawah) menampilkan pada kondisi *Rocket* yang secara khusus memetakan titik anomaly pada saat terjadinya lonjaka harga.

Ketiga variasi kondisi dataset yang telah terbagi 3 tersebut kemudian diintegrasikan dengan metrik *on-chain active_spending_addresses* dan diproses menggunakan algoritma K-Means. Untuk menentukan dataset mana yang memiliki pemisahan anomaly paling optimal, kualitas *clustering* dari ketiga kondisi tersebut dievaluasi dan dibandingkan. Perbandingan kualitas *clustering* tersebut dapat dilihat pada Gbr 3.

	Subset	Size	Silhouette	Davies-Bouldin
0	Complete	126574	0.544428	0.729872
1	Dip/Crash	5372	0.721819	0.622577
2	Rocket/Moon	8187	0.709085	0.640873

Gbr 3. Perbandingan Nilai Metrik dari 3 Kondisi Dataset

Berdasarkan Gbr 3 yang merupakan hasil komparasi menunjukkan bahwa dataset pada kondisi penurunan atau *Dip* menghasilkan performa *clustering* yang terbaik di antara ketiganya. Kondisi *dip* diproyeksikan mencatat nilai *Silhouette Coefficient* tertinggi mendekati 1 sekaligus nilai dari *Davies-Bouldin Index* terendah dibandingkan dengan kondisi *Complete* dan *Rocket*.

Kombinasi skor evaluasi ini membuktikan bahwa pada saat pasar mengalami fase kejatuhan harga membentuk pola yang direpresentasikan oleh *active_spending_addresses* membentuk kelompok data yang sangat padat di bagian dalam dan terpisah dengan batas yang sangat tegas dari kelompok lainnya. Oleh karena itu dataset dengan kondisi *Dip* dipilih sebagai objek utama untuk mengekstraksi *sinyal entry*. *Cluster* yang terbentuk secara solid pada kondisi ini diyakini mampu memetakan secara presisi anomaly pasar yakni titik di mana harga jatuh ke level terendah dalam satu siklus bulan namun secara bersamaan diiringi oleh lonjakan dari *activity_spending_addresses* yang masif sebagai indikasi fase akumulasi.

II.4. Trading Rules

Sinyal *entry* yang telah berhasil diekstraksi dan divalidasi melalui proses *clustering* K-Means pada kondisi *Dip* selanjutnya dieksekusi berdasarkan serangkaian skenario simulasi yang terstruktur. Skenario ini diformulasikan ke dalam tahapan *Trading Rules* yang berfungsi untuk mensimulasikan transaksi pembelian dan penjualan sekaligus mengukur potensi profitabilitas dari model yang diusulkan secara objektif.

Aturan perdagangan dalam penelitian ini dirancang dengan parameter penahanan aset yang spesifik dan terukur. Ketika sebuah titik data teridentifikasi masuk ke dalam *cluster* anomaly yakni representasi harga di level dasar yang diiringi oleh lonjakan *active_spending_addresses* sistem akan mencatat dan menyimpannya sebagai sinyal pembelian.

Setelah titik signal pembelian tersebut ditandai skenario memproyeksikan bahwa aset Bitcoin yang diperoleh wajib ditahan dengan batas waktu minimal selama 24 jam. Penerapan aturan penahanan minimal ini bertujuan untuk menyaring volatilitas semu harian serta memberikan jeda waktu yang rasional bagi fase akumulasi fundamental untuk mulai mendorong pembalikan arah tren harga.

Lebih lanjutnya batas waktu maksimal untuk penahanan aset ditetapkan hingga hari akhir pada bulan berjalan atau akhir bulan target. Tujuan utama dari strategi sinyal keluar ini adalah untuk mencari dan memberikan titik sinyal penjualan tepat di titik puncak harga yang terjadi dalam rentang waktu penahanan tersebut. Melalui kombinasi Batasan penahanan minimal 24 jam dan maksimal hingga akhir bulan efektivitas model *clustering* pada kondisi *Dip* ini dapat dievaluasi secara kuantitatif khususnya dalam mengoptimalkan *Return on Investment* (ROI) dan meminimalisasi risiko kerugian pada setiap siklus bulannya.


III. HASIL DAN PEMBAHASAN

Pada pembahasan ini akan menguraikan secara komprehensif hasil dari pengujian evaluasi dari kerangka metodologi yang telah dirancang sebelumnya. Fokus utama dari pembahasan ini adalah membuktikan efektivitas integrasi antara metrik *on-chain active_spending_addresses* dengan pemodelan dataset pada kondisi *Dip*. Analisis luaran dari algoritma K-Means dan skenario *trading rules* dibagi menjadi 2 aspek utama; pertama evaluasi visual terhadap akurasi sinyal dalam menangkap

momentum pembalikan arah tren harga dan kedua pengukuran performa kuantitatif dari strategi yang diusulkan melalui rekapitulasi tingkat kemenangan dan profitabilitas. Seluruh hasil komputasi ini dibedah untuk mengukur keandalan model dalam mengidentifikasi anomali pasar dan memaksimalkan *Return on Investment* (ROI).

III.1. Evaluasi Sinyal dan Visualisasi

Tahap pertama dalam mengukur efektivitas model adalah melakukan pemetaan dan evaluasi visual terhadap titik-titik eksekusi yang dihasilkan oleh algoritma *clustering*. Untuk memetakan secara presisi kapan sinyal untuk masuk dan keluar, hasil simulasi ini diproyeksikan ke dalam visualisasi deret waktu. Visualisasi ini merangkum fluktuasi harga Bitcoin harian secara spesifik untuk setiap bulan.



Gbr 4. Pemetaan sinyal *Dip* dan Validasi Momentum di September 2011

Berdasarkan Gbr 4. Performa dari algoritma dalam menangkap anomali pasar dapat diamati secara langsung melalui penempatan penanda (*marker*) pada grafik garis pergerakan harga penutupan Bitcoin (garis biru). Titik sinyal dipresentasikan oleh penanda segitiga biru (Deteksi Kondisi *Dip*), sementara titik sinyal penjualan atau validasi momentum ditandai oleh segitiga merah.

Penanda segitiga biru muncul secara akurat di area lembah grafik secara tidak langsung memvalidasi bahwa algoritma K-Means berhasil mengisolasi *cluster* harga terendah yang beririsan dengan filter lonjakan ekstrem *active_spending_addresses*. Kemunculan titik ini mengkonfirmasi bahwa anomaly pengeluaran *on-chain* benar-benar berfungsi sebagai fondasi akumulasi yang kuat. Selanjutnya, garis putus-putus (*dashed line*) yang ditarik dari titik sinyal beli menuju penanda lingkaran merah menunjukkan durasi dari penahanan aset secara minimal 24 jam dan maksimal hingga batas akhir bulan. Segitiga merah tersebut secara konsisten bertengger di area puncak fluktuasi bulanan membuktikan bahwa aturan sinyal keluar di harga maksimal bulanan sukses menangkap momentum pembalikan arah tren harga pasca kejatuhan harga.

III.2. Performa Strategi

Sinyal pembelian yang telah diekstraksi dari algoritma K-Means pada kondisi *Dip* kemudian diuji profitabilitasnya melalui skenario *Trading Rules* dengan batasan penahanan maksimal hingga akhir bulan berjalan. Untuk membedakan

bagaimana performa model secara terperinci, penelitian ini mengambil sampel data pada bulan September 2011 sebagai representasi. Rekapitulasi dari seluruh sinyal yang muncul pada rentang bulan tersebut disajikan pada Tabel 1.

Tabel I. Rekapitulasi Sinyal pada Kondisi *Dip* di September 2011

Date	Start Price	M Profit Time	M Max Price	M Max Profit	M ROI(%)
2011-09-01	8.22	2011-09-04	8.89	0.67	8.15
2011-09-06	8.00	2011-09-06	8.89	0.89	11.12
2011-09-08	7.4	2011-09-08	8.5	1.1	14.86
2011-09-13	5.97	2011-09-13	7.4	1.43	23.95
2011-09-14	5.53	2011-09-26	6.06	0.53	9.58
2011-09-15	5.13	2011-09-26	6.06	0.93	18.12
2011-09-16	4.85	2011-09-26	6.06	1.21	24.94
2011-09-18	4.92	2011-09-26	6.06	1.14	23.17
2011-09-19	4.9	2011-09-26	6.06	1.16	23.67
2011-09-21	5.66	2011-09-26	6.06	0.4	7.06
2011-09-24	5.68	2011-09-26	6.06	0.38	6.69
2011-09-26	4.8	2011-09-26	6.06	1.26	26.25
2011-09-28	4.82	2011-09-28	4.92	0.1	2.07
2011-09-29	4.82	2011-09-29	4.82	0.00	0.00

Berdasarkan Tabel I sistem telah berhasil mendeteksi sebanyak 14 sinyal pembelian di sepanjang bulan September 2011. Rentang harga pembelian (*Start Price*) terjadi dalam tren penurunan *downtrend* dimulai dari harga 8.22 USD pada 1 September hingga mencapai titik terdalam di harga 4.80 USD pada 26 September. Dapat diamati pada kolom *M Profit Time*, mayoritas titik sinyal jual dari sinyal beli yang berbeda (tanggal 14 hingga 26 September) terpusat pada satu tanggal yang yaitu 26 September 2011 di harga puncak 6.06 USD. Hal ini membuktikan bahwa strategi penahanan aset maksimal hingga akhir bulan berhasil melakukan penjemputan pada momentum *reversal* (pembalikan arah) secara optimal tanpa perlu tergesa-gesa menjual di awal fluktuasi. Dari total 14 sinyal yang dihasilkan strategi ini mencetak 13 transaksi yang memiliki profit dan hanya mengalami 1 transaksi yang tidak profit atau balik modal dikarenakan tidak mengalami kenaikan selama 24 jam atau terkena batas maksimal akhir bulan. Secara statistik skenario ini menghasilkan tingkat kemenangan yang sangat tinggi sebesar 92,86% dalam satu bulan perdagangan. Hasil rekapitulasi keseluruhan rentang waktu dari Agustus 2011 hingga Februari 2026 bisa dilihat pada tabel II.

Tabel II. Rekapitulasi Performa Skenario secara Keseluruhan dari 2011-2026

Total sinyal	Sinyal Profit	Sinyal Balik Modal	Tingkat Kemenangan	Total Potensi Max Profit(USD)	Rata-Rata Potensi Max ROI
1.744 Sinyal	1.729 Sinyal	15 Sinyal	99/14%	\$300.612	19.49%

Berdasarkan Tabel II algoritma *clustering* secara total telah memicu dan memvalidasi 1.744 sinyal beli di sepanjang periode pengujian historis. Dari ribuan sinyal tersebut model ini menciptakan tingkat akurasi yang luar biasa dengan 1.729 sinyal yang profit dan hanya mencatat 15 transaksi yang balik modal. Proporsi ini mendorong persentase tingkat kemenangan

keseluruhan level dengan mencapai 99,14%. Minimnya sinyal yang balik modal membuktikan bahwa lapisan dari filter fundamental yang ditetapkan pada sistem yaitu keharusan adanya anomali dari *active_spending_addresses* saat harga berada di *cluster* terendah yang berfungsi sangat optimal dalam mereduksi sinyal palsu atau jebakan penurunan harga lebih lanjut.

Tingginya akurasi deteksi ini berbanding lurus dengan metrik profitabilitas yang dihasilkan secara kumulatif seluruh sinyal pada skenario ini berpotensi membukukan total profit maksimal hingga 300.612 USD. Efisiensi dari model ini tercermin pada rata-rata potensi max ROI di setiap satu sinyal yang dipicu mampu menawarkan rata-rata proyeksi pengembalian sebesar 19,49% per transaksi.

Skenario penahanan aset dengan batas maksimal akhir bulan terbukti memberikan ruang waktu yang presisi bagi fase akumulasi fundamental *on-chain* untuk mendorong pembalikan arah harga sehingga kapitalisasi keuntungan dapat direalisasikan secara maksimal di titik puncak fluktuasi bulanan Bitcoin.

Meskipun model menghasilkan tingkat kemenangan 99.14%, perlu dicatat evaluasi risiko terkait *maximum drawdown* selama periode *black swan*. Sebagai contoh, pada kepanikan pasar global akibat COVID-19 di bulan Maret 2020, penurunan harga terjadi secara masif. Model pada kondisi *Dip* yang dipadukan dengan filter *active spending addresses* berhasil menghindari sinyal beli palsu (*false entry*) di awal keruntuhan, dan baru memicu sinyal beli ketika fase akumulasi fundamental tervalidasi. Jika terjadi kegagalan (*drawdown*), batas penahanan aset maksimal hingga akhir bulan berfungsi membatasi paparan kerugian jangka panjang.

IV. KESIMPULAN

Penelitian ini menyimpulkan penggabungan data pasar historis dengan metrik *on-chain* secara spesifik *active spending addresses* mampu mengekstraksi sinyal perdagangan Bitcoin yang optimal. Dengan memproses data historis melalui *Patterned Dataset Model* dan algoritma K-Means Clustering terbukti bahwa pemodelan pada kondisi *Dip* menghasilkan struktur *cluster* pemisahan anomali yang paling baik. Hal ini dibuktikan melalui evaluasi metrik *Silhouette Coefficient* dan *Davies-Bouldin Index* di mana dataset kondisi *Dip* menunjukkan performa *clustering* terbaik dibandingkan dengan kondisi pasar *Complete* maupun *Rocket*. Titik anomali pada *cluster* harga terendah yang beriringan dengan lonjakan aktivitas fundamental jaringan kemudian diekstraksi dan divalidasi sebagai sinyal beli.

Penerapan strategi ini memberikan hasil yang sangat baik dalam memaksimalkan profitabilitas dan meminimalkan risiko jebakan atau sinyal palsu. Melalui pengujian *trading rules* dengan skenario penahanan aset minimal 24 jam hingga batas maksimal akhir bulan berjalan model yang diusulkan berhasil memvalidasi 1.744 sinyal beli. Dari keseluruhan sinyal tersebut strategi ini mencetak tingkat kemenangan yang tinggi mencapai 99,14% dengan rata-rata ROI 19.49% untuk setiap

transaksinya. Secara kumulatif skenario ini berpotensi membukukan akumulasi profit maksimal hingga 300.612 USD membuktikan bahwa integrasi metrik *on-chain* pada dataset berpola sangat efektif untuk investor.

REFERENSI

- [1] S. Nakamoto, "Bitcoin: A peer-to-peer electronic cash system," Available at SSRN 3440802, 2008.
- [2] D. E. Shafira, O. Ferli, E. Haryanti, and E. Wijaya, "Analisis Korelasi dan Pergerakan bersama Saham, Emas dan Bitcoin Studi Kasus Pasar Indonesia," *Journal of Management and Business Review*, vol. 20, no. 3, pp. 207–220, 2023.
- [3] P. H. Padhila, I. Cholissodin, and P. P. Adikara, "Prediksi Harga Bitcoin berdasarkan Data Historis Harian dan Google Trend Index menggunakan Algoritme Extreme Learning Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 7, pp. 3515–3524, 2022.
- [4] A. H. Elsayed, G. Gozgor, and L. Yarovaya, "Volatility and return connectedness of cryptocurrency, gold, and uncertainty: Evidence from the cryptocurrency uncertainty indices," *Financ. Res. Lett.*, vol. 47, p. 102732, 2022.
- [5] Z. Wen, E. Bouri, Y. Xu, and Y. Zhao, "Intraday return predictability in the cryptocurrency markets: Momentum, reversal, or both," *The North American Journal of Economics and Finance*, vol. 62, p. 101733, 2022.
- [6] R. Parlika and B. Rahmat, "Use of Patterned Datasets (Minimum and Maximum) to predict Bitcoin and Ethereum price movements," *Technium*, vol. 16, 2023.
- [7] R. Parlika, R. R. Isnanto, and B. Rahmat, "Prediction of ROI achievements and potential maximum profit on spot Bitcoin Rupiah trading using K-means clustering and patterned dataset model," *JOIV: International Journal on Informatics Visualization*, vol. 8, no. 3–2, pp. 1987–2001, 2024.
- [8] G. Putri, S. Vernanda, A. Fatmawati, and M. Faiz, "Synergistic Alpha: A Deep Learning Framework for Forecasting Cryptocurrency Returns by Fusing On-Chain, Sentiment, and Market Data," *Enigma in Economics*, vol. 3, no. 2, pp. 96–107, 2025.
- [9] G. Kim, D.-H. Shin, J. G. Choi, and S. Lim, "A deep learning-based cryptocurrency price prediction model that uses on-chain data," *IEEE Access*, vol. 10, pp. 56232–56248, 2022.
- [10] K. Alabi, "Digital blockchain networks appear to be following Metcalfe's Law," *Electron. Commer. Res. Appl.*, vol. 24, pp. 23–29, 2017.
- [11] R. Parlika, M. Mustafid, and B. Rahmat, "Minimum, Maximum, and Average Implementation of Patterned Datasets in Mapping Cryptocurrency Fluctuation Patterns," *JOIV: International Journal on Informatics Visualization*, vol. 8, no. 1, pp. 378–386, 2024.
- [12] L. Morissette and S. Chartier, "The k-means clustering technique: General considerations and implementation in Mathematica," *Tutor. Quant. Methods Psychol.*, vol. 9, no. 1, pp. 15–24, 2013.
- [13] W. W. Pribadi, A. Yunus, and A. S. Wiguna, "Perbandingan metode K-means euclidean distance dan manhattan distance pada penentuan zonasi covid-19 di kabupaten malang," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 2, pp. 493–500, 2022.
- [14] M. R. Mauludin, O. Nurdian, and F. M. Basysyar, "Penerapan Algoritma K-Means Clustering Untuk Analisis Kinerja Pengiriman Paket Shopee Express Di Hub Transit Kedawung," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, 2025.
- [15] L. B. A. Prasetya, "Clustering Dalam Menentukan Tindak Lanjut Hasil Annual Check Mental Health Dengan Algoritma K-Means," *Computer Based Information System Journal*, vol. 13, no. 1, pp. 55–61, 2025.