Tinjauan Pustaka Sistematis: Deteksi Rezim Pasar Menggunakan *Extreme Gradient Boosting* untuk Sinyal Perdagangan Kripto

Mohammad Faris Al Fatih[1], Rizky Parlika[2], Hendra Maulana[3]

[1]Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur, Surabaya, Indonesia

[2]Departemen Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur, Surabaya, Indonesia

[3]Program Studi Bisnis Digital, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur, Surabaya, Indonesia

E-mail: 22081010277@strudent.upnjatim.ac.id[1], rizkyparlika.if@upnjatim.ac.id[2], hendra.maulana.if@upnjatim.ac.id[3]

Abstrak. Tinjauan pustaka sistematis ini mengkaji integrasi deteksi rezim pasar, *Extreme Gradient Boosting* (XGBoost), dan sinyal perdagangan mata uang kripto berdasarkan 20 studi pada 2021–2026. Seleksi literatur mengikuti PRISMA melalui basis data OpenAlex. Hasil pemetaan menunjukkan bahwa 4 studi (20,0%) berfokus pada deteksi rezim, 9 studi (45,0%) menggunakan XGBoost tanpa kesadaran rezim, 2 studi (10,0%) mengintegrasikan keduanya, dan 5 studi (25,0%) berada pada domain terkait. Sintesis menunjukkan masih terbatasnya integrasi informasi rezim dengan XGBoost dalam perdagangan kripto, khususnya untuk menghasilkan sinyal perdagangan yang adaptif terhadap kondisi pasar. Berdasarkan celah tersebut, penelitian ini mengusulkan kerangka *Regime-Aware XGBoost* dengan integrasi informasi rezim sebagai fitur dan mekanisme *switching* adaptif yang memerlukan validasi empiris lebih lanjut.

Kata kunci: Deteksi Rezim Pasar; *Extreme Gradient Boosting*; Sinyal Perdagangan; Mata Uang Kripto; Tinjauan Pustaka Sistematis

Abstract. *This systematic literature review examines the integration of market regime detection, Extreme Gradient Boosting (XGBoost), and cryptocurrency trading signals based on 20 studies published between 2021 and 2026. Literature selection followed PRISMA using the OpenAlex database. The mapping shows that 4 studies (20.0%) focused on regime detection, 9 studies (45.0%) used XGBoost without regime awareness, 2 studies (10.0%) integrated both, and 5 studies (25.0%) addressed related domains. The synthesis indicates limited integration of regime information with XGBoost in cryptocurrency trading, particularly for generating trading signals that adapt to changing market conditions. Based on this gap, this study proposes a Regime-Aware XGBoost framework that incorporates regime information as features and an adaptive switching mechanism, requiring further empirical validation.*

Keywords: *Market Regime Detection; Extreme Gradient Boosting; Trading Signals; Cryptocurrency; Systematic Literature Review*

1. Pendahuluan

Pasar mata uang kripto berkembang pesat dalam satu dekade terakhir, dengan lebih dari 23.000 aset terdaftar pada 2023 dan valuasi pasar mencapai 870,81 miliar dolar AS. Pertumbuhan tersebut disertai volatilitas tinggi yang menjadikan pasar kripto dinamis dan sulit diprediksi, sekaligus membuka peluang penerapan pembelajaran mesin untuk menangkap pola nonlinier [1]. Pergerakan harga dipengaruhi berbagai faktor, termasuk indikator teknis, data *on-chain*, serta sentimen investor dari media sosial dan berita [2]. Kondisi tersebut menuntut model prediktif yang akurat dan *robust* terhadap perubahan pasar.

Salah satu karakteristik penting pasar keuangan adalah keberadaan rezim pasar, yaitu kondisi dengan karakteristik statistik berbeda dalam volatilitas, tren, dan korelasi. Pada pasar kripto, perubahan rezim dapat terjadi secara tiba-tiba sehingga model yang sesuai pada satu kondisi belum tentu efektif pada kondisi lainnya [3]. Pergeseran tersebut dapat dipengaruhi faktor makroekonomi, regulasi, serta sentimen investor [4], Berbagai metode telah digunakan untuk mendeteksi rezim, seperti *Hidden Markov Model* (HMM), *Markov-Switching GARCH* (MS-GARCH), CAViaR berbasis Markov, dan Bayesian MCMC-HMM. Meskipun mampu menangkap perpindahan rezim secara endogen, metode tersebut memiliki keterbatasan dalam skalabilitas, komputasi, dan integrasi fitur berdimensi tinggi [3], [4].

Di sisi lain, *Extreme Gradient Boosting* (XGBoost) mampu menangkap hubungan nonlinier pada data tabular dan telah diterapkan dalam prediksi harga Bitcoin, optimasi portofolio, serta peramalan kripto [5], [6], [7]. XGBoost telah berhasil diterapkan untuk prediksi harga Bitcoin [6], optimasi portofolio saham, dan pemilihan fitur untuk peramalan kripto [7]. Namun, pemanfaatannya bersama deteksi rezim untuk menghasilkan sinyal perdagangan kripto masih terbatas dalam literatur. Tinjauan terdahulu lebih banyak membahas dominasi RNN/LSTM, arsitektur hibrida, atau karakteristik multi-rezim untuk strategi *hedging*, tanpa secara khusus mengkaji integrasi deteksi rezim dengan XGBoost untuk sinyal perdagangan kripto [8].

Berdasarkan celah tersebut, tinjauan pustaka sistematis ini bertujuan menjawab tiga pertanyaan penelitian: (RQ1) metode deteksi rezim apa yang diterapkan pada pasar kripto dan bagaimana efektivitasnya dalam mengidentifikasi peralihan rezim? (RQ2) bagaimana XGBoost dimanfaatkan dalam prediksi dan perdagangan kripto serta apa kekuatan dan keterbatasannya? (RQ3) sejauh mana deteksi rezim telah diintegrasikan dengan XGBoost untuk menghasilkan sinyal perdagangan kripto, dan apa arah penelitian berdasarkan celah tersebut?

Kontribusi tinjauan ini meliputi: (1) proses seleksi literatur transparan berbasis PRISMA; (2) sintesis kuantitatif berdasarkan metode, tahun, aset, dan metrik evaluasi; (3) pemetaan studi yang menggunakan deteksi rezim, XGBoost, dan integrasi keduanya; (4) analisis komparatif berdasarkan pendekatan, *dataset*, metrik, kelebihan, dan keterbatasan; serta (5) usulan kerangka *Regime-Aware XGBoost* dengan dua mekanisme integrasi yang dapat diuji secara empiris pada penelitian selanjutnya.

2. Metodologi Tinjauan

2.1. Sumber dan Strategi Pencarian

Pencarian literatur dilakukan melalui OpenAlex, katalog akademik terbuka dengan cakupan luas, metadata lengkap, dan akses API gratis yang mendukung reproduktibilitas. Pencarian dilakukan pada September 2026 dengan rentang publikasi Januari 2021–Juni 2026.

Search string menggunakan operator Boolean dengan tiga klaster, yaitu aset/area finansial, tugas prediktif, dan metode *machine learning*:

'(Bitcoin OR cryptocurrency OR crypto OR Ethereum OR XRP OR stock OR equity OR financial OR trading OR portfolio OR intraday) AND (forecasting OR prediction OR price OR volatility OR return OR risk OR sentiment OR regime) AND (XGBoost OR LightGBM OR LSTM OR "machine learning" OR "deep learning" OR HMM OR regime OR "technical indicators" OR "feature selection" OR sentiment)'

Pencarian ini dilakukan pada field title, abstract, dan keywords yang terindeks OpenAlex. Hasil pencarian awal menghasilkan 7.022 catatan.

2.2. Kriteria Inklusi dan Eksklusi

Kriteria inklusi dan eksklusi ditetapkan sebelum pencarian untuk memastikan relevansi dan konsistensi seleksi studi. Kriteria mencakup jenis publikasi, bahasa, periode publikasi, subjek Scopus, topik, dan validitas metodologis, sebagaimana dirangkum pada Tabel 1.

Table 1. Kriteria inklusi dan eksklusi tinjauan pustaka sistematis.

Kriteria	Inklusi	Eksklusi
Publikasi	Jurnal *peer-reviewed* (article/review)	*Preprint*, buku, tesis, disertasi, laporan, proceeding
Bahasa	Inggris	Selain Inggris
Tahun	Jan 2021–Jun 2026	Di luar periode
Subjek Scopus	Computer Science/Decision Sciences	Di luar CS/DS
Topik	Rezim kripto, XGBoost/GB keuangan, atau sinyal trading ML	Di luar topik
Metode	Empiris, simulasi, atau SLR tervalidasi	Teoretis tanpa validasi, opini/editorial

2.3. Proses Seleksi Mengikuti PRISMA

Seleksi literatur mengikuti empat tahap PRISMA: identifikasi, *screening*, eligibilitas, dan inklusi. Alur seleksi ditampilkan pada Gambar 1, sedangkan ringkasan jumlah dan alasan eksklusi disajikan pada Tabel 2.

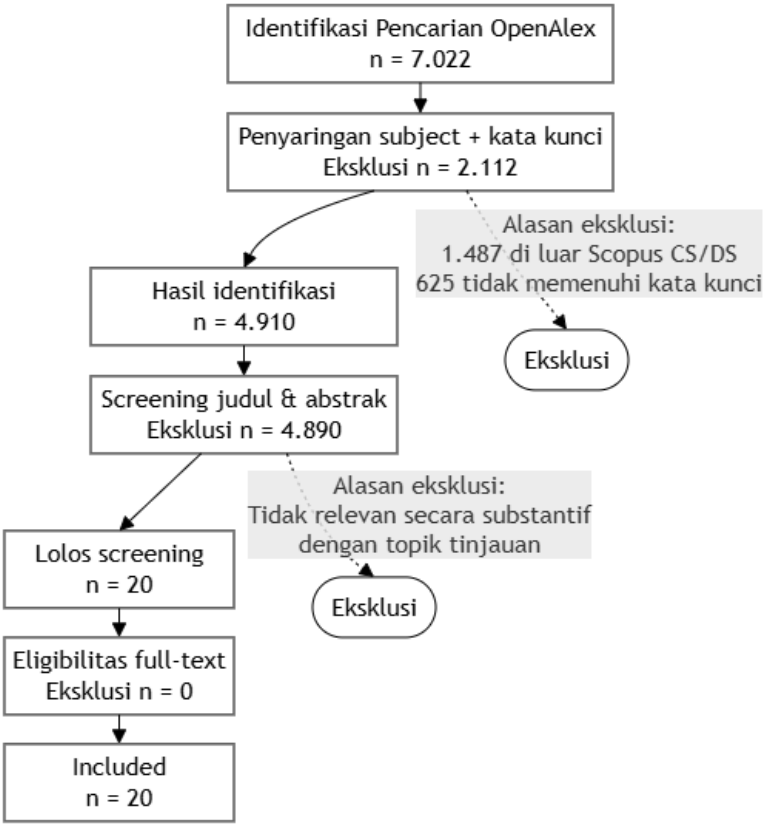

Gambar 1. Diagram alur PRISMA proses seleksi literatur

Pada tahap identifikasi, pencarian OpenAlex menghasilkan 7.022 catatan. Penyaringan otomatis berdasarkan subjek Scopus Computer Science/Decision Sciences dan kata kunci pada judul/abstrak mengeksklusi 2.112 catatan, sehingga tersisa 4.910 catatan.

Tahap *screening* dilakukan secara independen oleh dua penulis berdasarkan relevansi terhadap deteksi rezim pasar, XGBoost, dan sinyal perdagangan kripto. Perbedaan penilaian diselesaikan melalui diskusi dengan penulis ketiga. Sebanyak 4.890 catatan dieksklusi dan 20 artikel dilanjutkan ke tahap eligibilitas.

Pada tahap eligibilitas, seluruh 20 artikel dinilai berdasarkan kriteria pada Tabel 1 dan memenuhi seluruh persyaratan. Dengan demikian, 20 artikel dimasukkan ke dalam sintesis.

Table 2. Ringkasan jumlah artikel dan alasan eksklusi pada setiap tahap PRISMA

Tahap	Jumlah masuk	Dieksklusi	Alasan eksklusi	Jumlah keluar
Identifikasi	7.022	2.112	Bukan Scopus CS/DS subject: 1.487; tidak match keyword di title/abstract: 625	4.910
Screening	4.910	4.890	Tidak relevan secara substantif terhadap integrasi rezim-XGBoost atau sinyal perdagangan kripto	20
Eligibilitas	20	0	Semua memenuhi kriteria inklusi	20
Inklusi	20	—	—	20

2.4. Strategi Ekstraksi Data dan Sintesis

Data diekstraksi oleh penulis pertama dan divalidasi oleh penulis kedua berdasarkan sembilan dimensi, meliputi referensi, jurnal dan kuartil, fokus penelitian, metode deteksi rezim, metode prediksi/ML, aset, data, metrik evaluasi, serta temuan dan keterbatasan. Sintesis dilakukan secara kualitatif melalui analisis tematik dan secara kuantitatif melalui tabulasi distribusi tahun, metode, aset, dan metrik. Pemetaan juga dilakukan untuk membedakan studi yang menggunakan deteksi rezim, XGBoost, atau integrasi keduanya.

3. Hasil Tinjauan

3.1. Karakteristik Studi yang Dipilih dan Sintesis Kuantitatif

Sebanyak 20 artikel dianalisis, dengan tren publikasi meningkat dan puncak pada 2025 sebanyak 8 studi (40,0%), sementara distribusi metode menunjukkan keberagaman pendekatan yang dapat saling tumpang tindih karena penggunaan kombinasi metode (Gambar 2–3). Bitcoin menjadi aset yang paling banyak diteliti, yaitu 14 studi (70,0%), diikuti Ethereum sebanyak 6 studi (30,0%) (Gambar 4). Metrik evaluasi yang digunakan mencakup tiga kategori utama, yaitu metrik prediktif seperti RMSE, MAPE, R^2, dan accuracy; metrik keuangan seperti Sharpe, *drawdown*, dan *return*; serta metrik *backtesting* seperti *win rate* dan Calmar (Gambar 5).

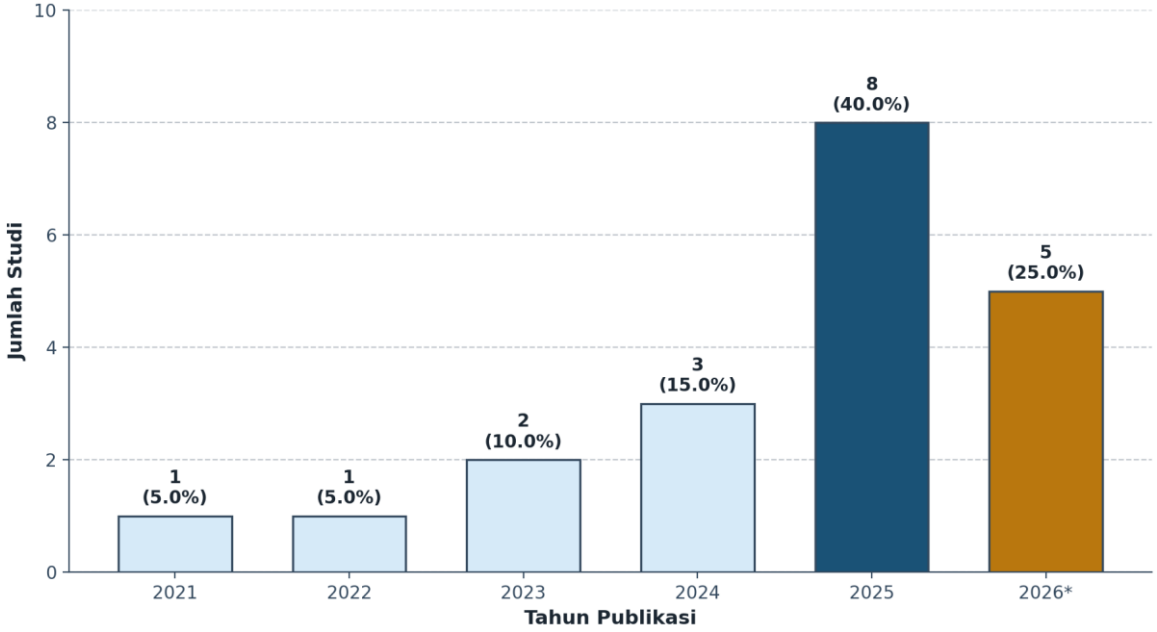

Gambar 2. Distribusi tahun publikasi 20 studi yang ditinjau

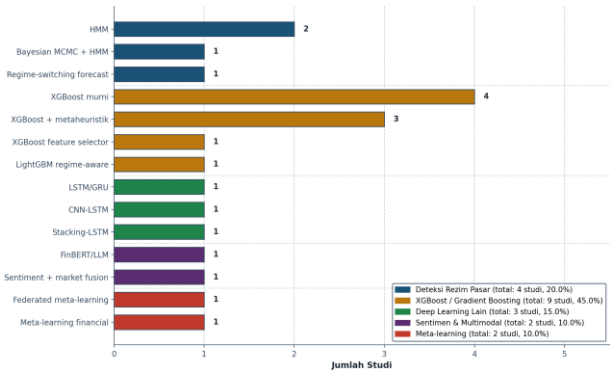

Gambar 3. Distribusi metode utama dalam 20 studi yang ditinjau

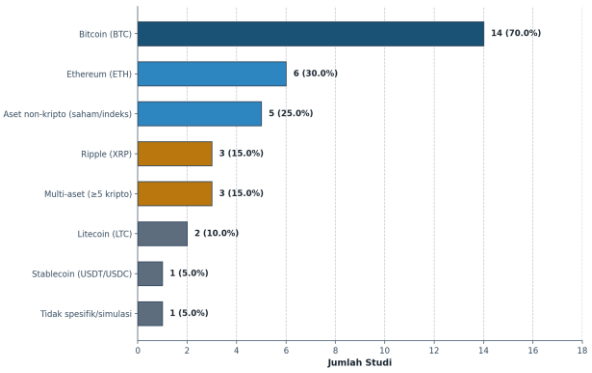

Gambar 4. Distribusi aset kripto yang diteliti dalam 20 studi

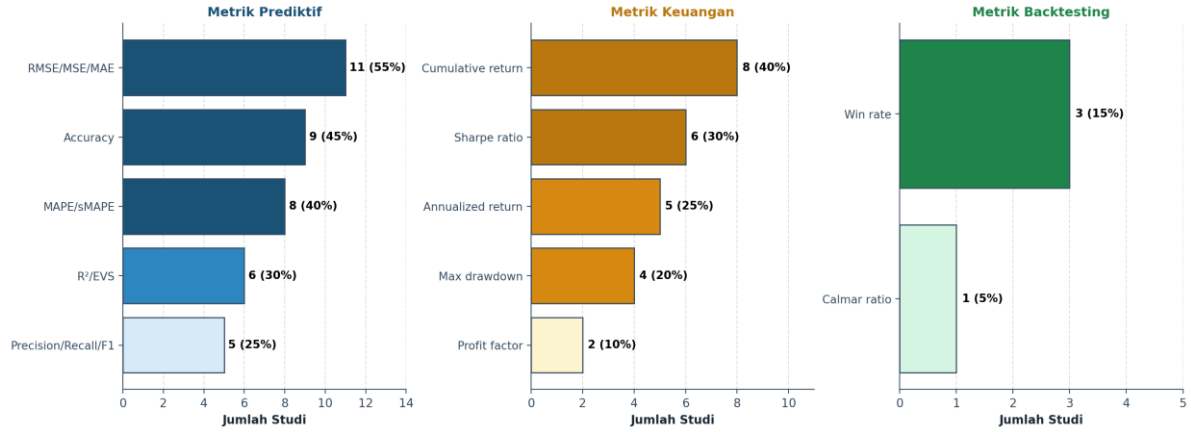

Gambar 5. Distribusi metrik evaluasi yang digunakan dalam 20 studi

3.2. Pemetaan Eksplisit Integrasi Rezim–XGBoost

Salah satu temuan kunci dari tinjauan ini adalah pemetaan eksplisit mengenai sejauh mana integrasi antara deteksi rezim pasar dan XGBoost telah dilakukan dalam literatur. Berdasarkan analisis terhadap 20 studi, pemetaan integrasi disajikan pada Tabel 3.

Table 3. Pemetaan eksplisit integrasi antara deteksi rezim pasar dan XGBoost/gradient boosting

Kategori integrasi	Definisi	n	Presentase	Referensi
A. Regime detection only	Deteksi rezim tanpa integrasi XGBoost/gradient boosting	4	20,0%	[3], [4]
B. XGBoost only	XGBoost/gradient boosting tanpa kesadaran rezim	9	45,0%	[5], [6], [7], [9]
C. Integrasi rezim + XGBoost	Integrasi deteksi rezim dengan XGBoost/gradient boosting	2	10,0%	[10], [11]
D. Adjacent	Sinyal, risiko, sentimen, atau meta-learning tanpa integrasi langsung	5	25,0%	[1], [2], [8], [12], [13]

Hanya 2 dari 20 studi (10,0%) yang secara eksplisit mengintegrasikan deteksi rezim dengan XGBoost atau gradient boosting, yaitu satu berbasis Regime-Aware LightGBM [10] dan satu pendekatan probabilistik generatif [11]. menunjukkan bahwa integrasi keduanya masih terbatas dalam literatur. Analisis tematik mengidentifikasi tiga klaster utama, yaitu (1) deteksi rezim pasar kripto, (2) penerapan XGBoost untuk prediksi harga dan volatilitas, dan (3) sistem perdagangan berbasis sinyal dan backtesting. Studi kunci dirangkum pada Tabel 4.

Table 4. Ringkasan studi kunci dalam tinjauan pustaka

Ref	Fokus Utama	Metode	Dataset	Temuan Kunci
[1]	AI crypto predictability	Machine learning ensemble	BTC, ETH, ADA	AI meningkatkan prediktabilitas harga kripto
[2]	Fusion sentimen + market	Stacking-LSTM (SentiStack)	Bitcoin	Model sentimen mengungguli baseline *Buy* and *Hold*
[3]	Regime switching forecasting	Regime-switching forecasting	Kripto multi-aset	Model berbasis rezim lebih adaptif terhadap perubahan pasar
[4]	Regime shift Bitcoin	Bayesian MCMC + HMM	Bitcoin 2016-2024	Pergeseran dari faktor teknis ke makroekonomi seiring waktu
[5]	XGBoost vs DL	XGBoost, LSTM, Random Forest	Saham NIFTY 50	XGBoost unggul (Sharpe 1,72) dibanding LSTM dan RF
[6]	PSO + XGBoost	Enhanced PSO + XGBoost	Bitcoin	PSO optimasi hiperparameter XGBoost untuk prediksi kripto
[7]	XGBoost feature selection	XGBoost + RF + TWSVR	Bitcoin	27 faktor terpilih meningkatkan akurasi prediksi
[8]	Survey algoritma prediksi kripto	Systematic survey	Multi-aset	Tidak ada model yang konsisten unggul di semua kondisi pasar
[10]	Regime-Aware LightGBM	LightGBM + rolling HMM	NASDAQ-100	Model sadar-rezim menghasilkan alpha tervalidasi statistik
[12]	Safe haven Bitcoin	Explainable AI + rezim tekanan	Bitcoin	Perilaku Bitcoin berubah signifikan terhadap rezim tekanan global
[14]	ML volatile crypto market	ML algorithms comparison	Bitcoin, altcoin	ML efektif untuk prediksi di pasar volatil
[15]	Feature selection crypto	Feature selection techniques	Kripto multi-aset	Feature selection signifikan meningkatkan akurasi
[9]	TLBO-XGBoost BTC	TLBO + XGBoost + novel labeling	Bitcoin	Labeling novel meningkatkan akurasi XGBoost
[16]	Label-driven trading	Label-driven optimization	Saham multi-indeks	Profitabilitas tidak hanya bergantung akurasi model
[17]	Meta-learning financial	Meta-learning strategies	Dataset finansial multi-domain	Adaptasi cepat ke dataset baru dengan pelatihan ulang minimal
[18]	Bitcoin sentiment LLM	LLM sentiment analysis	Bitcoin	Sentiment index fitur paling berdampak pada prediksi harga
[11]	Regime-aware probabilistic	Probabilistic generative models	Bitcoin	Kerangka adaptif mengungguli baseline pada rezim volatilitas tinggi
[13]	Federated meta-learning	Hardware-aware federated	Saham intraday	Adaptasi cepat terhadap data scarcity di edge
[19]	Technical indicators ML crypto	ML + 130+ indikator teknis	BTC, ETH, XRP	Integrasi indikator teknis meningkatkan performa trading
[20]	Bitcoin macro-micro factors	Time series analysis	Bitcoin	Faktor makro dan mikro memiliki dampak berbeda per periode

3.3. Deteksi Rezim Pasar

Deteksi rezim pasar bertujuan mengidentifikasi perubahan kondisi pasar yang memengaruhi perilaku harga aset. Pada pasar kripto, HMM menjadi salah satu pendekatan yang banyak digunakan untuk menangkap perpindahan rezim. Studi Bayesian MCMC-HMM pada Bitcoin menemukan pergeseran

faktor penggerak harga dari faktor teknis dan sisi penawaran menuju faktor makroekonomi sepanjang 2016–2024 [4]. Pendekatan regime-switching juga menunjukkan pentingnya adaptasi model terhadap perubahan kondisi pasar dan concept drift [3]. sementara studi berbasis Explainable AI menemukan perbedaan perilaku Bitcoin pada berbagai rezim tekanan global [12]. Temuan tersebut menunjukkan bahwa rezim pasar bersifat dinamis dan dapat diidentifikasi dari data deret waktu, tetapi integrasinya ke dalam model prediktif masih menjadi tantangan.

3.4. Extreme Gradient Boosting untuk Prediksi Pasar

Extreme Gradient Boosting (XGBoost) banyak diterapkan dalam prediksi keuangan dan kripto karena mampu menangkap hubungan nonlinier pada data tabular [5]. Studi menunjukkan XGBoost kompetitif dalam prediksi harga, termasuk menghasilkan Sharpe ratio rata-rata 1,72 dan maximum drawdown terendah dibandingkan LSTM dan Random Forest [5], serta dapat ditingkatkan melalui optimasi hiperparameter [6]. XGBoost juga digunakan untuk pemilihan fitur, dengan studi yang menunjukkan manfaat seleksi faktor dan indikator teknis terhadap akurasi prediksi [7], [15]. Selain itu, optimasi labeling dan hiperparameter melalui TLBO-XGBoost dilaporkan meningkatkan akurasi dibandingkan XGBoost standar [9], sementara penelitian label-driven menunjukkan bahwa profitabilitas sinyal turut dipengaruhi oleh definisi label [16]. Integrasi informasi rezim dengan gradient boosting juga telah diuji melalui Regime-Aware LightGBM yang menghasilkan alpha tervalidasi secara statistik [10]. Meskipun menggunakan LightGBM, temuan tersebut menunjukkan kelayakan konseptual integrasi rezim dengan gradient boosting dan relevan sebagai dasar pengembangan pendekatan berbasis XGBoost.

3.5. Sinyal Perdagangan Kripto

Sinyal perdagangan merupakan keluaran model prediktif yang diterjemahkan menjadi keputusan beli, jual, atau hold dan dievaluasi melalui backtesting. Studi menunjukkan bahwa kinerja sinyal dipengaruhi pemilihan fitur dan strategi labeling [14], [16]. Pendekatan adaptif melalui meta-learning memungkinkan penyesuaian terhadap kondisi pasar baru dengan pelatihan ulang minimal [17]. sedangkan federated meta-learning diterapkan pada prediksi intraday return [13]. Integrasi sentimen berita dan media sosial juga dapat meningkatkan kinerja perdagangan [2]. sementara sentiment index dilaporkan sebagai fitur berpengaruh dalam prediksi Bitcoin [18]. Studi lain menunjukkan bahwa ratusan indikator teknis yang dipilih melalui feature selection dapat meningkatkan akurasi prediksi pada Bitcoin, Ethereum, dan Ripple [19]. Sementara itu, kontribusi faktor makro dan mikro terhadap prediksi Bitcoin berubah sepanjang waktu, yang mendukung pentingnya pendekatan sadar-rezim [20].

4. Pembahasan

4.1. Analisis Perbandingan Antar Pendekatan

Berdasarkan sintesis 20 studi, terdapat beberapa pola penting. Pertama, terdapat kesenjangan metodologis antara deteksi rezim pasar dan XGBoost. Deteksi rezim didominasi model HMM dan Bayesian MCMC yang berfokus pada pemodelan volatilitas dan perpindahan rezim [3], [4], sedangkan XGBoost umumnya digunakan sebagai supervised learning untuk prediksi harga atau return tanpa mempertimbangkan rezim secara eksplisit [5], [6]. Integrasi keduanya masih terbatas, dengan hanya 2 dari 20 studi (10,0%) yang secara eksplisit menggabungkan deteksi rezim dan gradient boosting [10], [11]. sebagaimana ditunjukkan pada pemetaan kuantitatif Tabel 3.

Kedua, kinerja XGBoost bergantung pada konteks penerapannya. Pada data saham dengan fitur teknis terstruktur, XGBoost menunjukkan kinerja kompetitif dibandingkan LSTM dan Random Forest [5]. Pada pasar kripto yang lebih volatil, efektivitasnya dipengaruhi optimasi hiperparameter dan skema labeling [6], [9]. Hal ini menunjukkan bahwa kinerja XGBoost tidak bersifat absolut, tetapi dipengaruhi kualitas fitur dan konfigurasi model.

Ketiga, akurasi prediksi tidak selalu mencerminkan profitabilitas. Studi berbasis backtesting menunjukkan perlunya mempertimbangkan akurasi, return, dan risiko secara bersamaan [14], [16].

Oleh karena itu, evaluasi sinyal perdagangan perlu mencakup metrik keuangan seperti Sharpe ratio dan maximum drawdown, selain metrik prediktif seperti MAPE dan RMSE.
Untuk memperkuat perbandingan, Tabel 5 merangkum tiga pendekatan utama berdasarkan paradigma, kekuatan, kelemahan, dataset, metrik evaluasi, keterbatasan, generalisasi, dan reproducibility. Sintesis ini menjadi dasar identifikasi celah integrasi antara deteksi rezim dan XGBoost.

Table 5. Analisis komparatif antar pendekatan utama yang teridentifikasi dalam literatur

Dimensi	A: Deteksi Rezim	B: XGBoost Murni	C: Regime-Aware XGBoost
Paradigma	Probabilistik generatif (HMM, MS-GARCH, Bayesian)	Supervised ensemble (gradient boosting)	Hibrida probabilistik + supervised
Kekuatan	Deteksi perpindahan rezim, interpretasi statistik, volatilitas non-stasioner	Relasi nonlinier, seleksi fitur, skalabilitas, inferensi cepat	Menggabungkan keduanya, adaptif terhadap rezim
Kelemahan	Kurang efektif pada fitur berdimensi tinggi, inferensi relatif lambat	Rentan concept drift dan perubahan distribusi	Implementasi lebih kompleks, risiko overfitting
Dataset umum	Log-return BTC/ETH, indikator makro	Indikator teknis, on-chain, sentimen	Kombinasi teknis, makro, dan sentimen
Metrik evaluasi	Log-likelihood, AIC/BIC, akurasi rezim	RMSE, MAPE, R^2, akurasi, MAE, Sharpe	Metrik prediktif, Sharpe, drawdown, performa per rezim
Keterbatasan	Skalabilitas, asumsi Gaussian, frekuensi tinggi	Sensitif hiperparameter, non-stasioner, interpretasi rezim terbatas	Belum ada standar jumlah rezim, pengujian rezim ekstrem dan benchmark masih terbatas
Generalisasi lintas aset	Cukup baik	Baik pada data tabular	Belum luas diuji
Reproducibility	Sedang	Tinggi	Rendah; belum ada protokol standar

Berdasarkan Tabel 5, pendekatan A dan B memiliki kekuatan yang saling melengkapi: deteksi rezim unggul dalam menangkap struktur stokastik pasar, sedangkan XGBoost unggul dalam memodelkan hubungan fitur-target yang nonlinier. Integrasi keduanya berpotensi mengatasi keterbatasan masing-masing, khususnya kerentanan XGBoost terhadap concept drift dan keterbatasan deteksi rezim pada fitur berdimensi tinggi. Dengan hanya 10,0% studi yang mengeksplorasi integrasi tersebut, masih terdapat ruang empiris untuk menguji pendekatan regime-aware XGBoost pada data kripto.

4.2. Tantangan dan Keterbatasan

Beberapa tantangan umum yang teridentifikasi dari literatur perlu diperhatikan dalam pengembangan sistem perdagangan kripto berbasis deteksi rezim dan XGBoost. Tantangan pertama adalah sifat data keuangan yang non-stasioner, di mana distribusi statistik data berubah seiring waktu akibat pergeseran rezim pasar, perubahan regulasi, dan evolusi struktur pasar [3]. Fenomena concept drift ini menyebabkan model yang dilatih pada periode tertentu mengalami degradasi kinerja saat kondisi pasar berubah [13]. Tantangan kedua adalah risiko overfitting, terutama ketika menggunakan fitur berdimensi tinggi seperti ratusan indikator teknis [15], [19]. Meskipun teknik pemilihan fitur dapat mengatasi masalah ini sebagian, menyeimbangkan kompleksitas model dengan kemampuan generalisasi tetap menjadi tantangan.
Tantangan ketiga adalah volatilitas ekstrem yang khas pada pasar kripto, yang membuat prediksi menjadi lebih sulit dan sinyal perdagangan lebih rentan terhadap false signal [14]. Tantangan keempat adalah keterbatasan data historis. Bitcoin dan sebagian besar kripto memiliki sejarah perdagangan

yang relatif pendek dibandingkan dengan pasar saham atau forex, yang membatasi jumlah data yang tersedia untuk melatih dan memvalidasi model. Tantangan kelima adalah kurangnya interpretasi yang memadai. Meskipun XGBoost relatif lebih dapat diinterpretasikan dibandingkan model deep learning, memahami mengapa model menghasilkan sinyal tertentu pada rezim pasar tertentu tetap menjadi area yang perlu penelitian lebih lanjut, terutama dengan penerapan metode Explainable AI [12].

4.3. Arah Penelitian Mendatang

Berdasarkan celah-celah yang teridentifikasi dalam literatur, beberapa arah penelitian mendatang dapat direkomendasikan. Pertama, pengembangan kerangka kerja yang secara eksplisit mengintegrasikan deteksi rezim pasar dengan XGBoost untuk menghasilkan sinyal perdagangan kripto. Meskipun pendekatan regime-aware telah dieksplorasi dengan LightGBM [10] dan model probabilistik generatif [11], penerapan serupa dengan XGBoost untuk pasar kripto masih belum memadai (lihat Tabel 3). Kedua, pengembangan mekanisme regime-adaptive di mana hiperparameter XGBoost atau bobot fitur disesuaikan secara dinamis berdasarkan rezim pasar yang terdeteksi. Pendekatan ini berpotensi meningkatkan robustness model terhadap pergeseran rezim.
Ketiga, integrasi data multimodal yang mencakup indikator teknis, data on-chain, sentimen media sosial, dan variabel makroekonomi ke dalam pipeline XGBoost yang sadar rezim. Studi-studi yang mengeksplorasi integrasi data sentimen dengan model prediktif [2], [18] dan pengaruh variabel makroekonomi terhadap rezim Bitcoin [4] memberikan landasan yang kuat untuk pengembangan lebih lanjut. Keempat, pengembangan strategi evaluasi yang lebih komprehensif yang tidak hanya mempertimbangkan akurasi prediksi, tetapi juga profitabilitas setelah biaya transaksi, pengelolaan risiko ekor (tail risk), dan performa di berbagai rezim pasar secara terpisah. Kelima, penerapan teknik meta-learning dan federated learning untuk memungkinkan model XGBoost beradaptasi lebih cepat terhadap pergeseran rezim dengan kebutuhan pelatihan ulang yang minimal [13], [17].

4.4. Kerangka Penelitian yang Diusulkan: Regime-Aware XGBoost

Berdasarkan sintesis Tabel 5 dan celah integrasi pada Tabel 3, kami mengusulkan kerangka Regime-Aware XGBoost sebagai arah penelitian pada pasar kripto. Kerangka ini merupakan proposal berbasis SLR, bukan klaim peningkatan performa. Validasi empiris diperlukan untuk menguji mekanisme integrasi melalui dua jalur metodologis utama.

4.4.1. Mekanisme 1: Regime Label sebagai Fitur Kategorikal dalam XGBoost (Feature-Conditioned Approach)

Pada mekanisme ini, model deteksi rezim (mis. HMM dengan n state) dijalankan secara independen pada data deret waktu log-return kripto untuk menghasilkan label rezim diskrit $r_t \in \{1,2,...,n\}$ pada setiap time step t. Label rezim ini kemudian di-encoding (one-hot atau ordinal) dan ditambahkan sebagai fitur kategorikal tambahan dalam matriks fitur XGBoost, bersama indikator teknis, sentimen, dan fitur makroekonomi lainnya. XGBoost kemudian dilatih dengan fitur yang diperkaya untuk memprediksi target (arah harga, return, atau probabilitas kelas sinyal). Secara konseptual, mekanisme ini memungkinkan model XGBoost mempelajari pola prediktif yang berbeda untuk setiap rezim secara otomatis melalui mekanisme split pohon keputusan pada fitur rezim. Sebagai contoh, XGBoost dapat mempelajari bahwa pada rezim "calm state" fitur RSI lebih prediktif, sedangkan pada rezim "bubble collapse" fitur sentimen lebih prediktif. Mekanisme ini relatif sederhana untuk diimplementasikan dan tidak menambah kompleksitas inferensi yang signifikan, namun memerlukan penentuan jumlah rezim yang tepat (model selection pada HMM).

4.4.2. Regime-Triggered Switching — Adaptasi Hiperparameter atau Strategi (Switching Approach)

Pada mekanisme ini, model deteksi rezim bertindak sebagai meta-controller yang menentukan konfigurasi XGBoost atau strategi perdagangan yang aktif pada setiap time step. Terdapat dua sub-varian: (a) hyperparameter switching, di mana beberapa set hiperparameter XGBoost yang berbeda dilatih secara offline untuk rezim yang berbeda (mis. set-A untuk calm, set-B untuk bubble formation, set-C untuk bubble collapse), dan rezim aktif menentukan set mana yang digunakan untuk inferensi;

(b) strategy switching, di mana rezim aktif menentukan strategi perdagangan yang berbeda (mis. momentum-following pada bubble formation, mean-reversion pada calm state, risk-off/fiat pada bubble collapse). Mekanisme ini lebih kompleks namun secara konseptual memberikan fleksibilitas yang lebih besar karena tidak hanya model yang beradaptasi tetapi juga strategi eksekusi. Mekanisme ini juga mendukung interpretasi yang lebih transparan karena setiap keputusan dapat dilacak ke rezim aktif.

Komponen Kerangka yang Diusulkan:

- Modul Deteksi Rezim: HMM atau MS-GARCH dilatih pada log-return historis untuk menghasilkan probabilitas rezim posterior P(rt|y1:t)pada setiap time step.
- Modul Feature Engineering: Indikator teknis (RSI, MACD, ATR, OBV), data on-chain (active addresses, hash rate), sentimen (LLM-based sentiment index), dan variabel makroekonomi (VIX, DXY, suku bunga Fed) direkayasa menjadi fitur tabular.
- Modul XGBoost Regime-Aware: XGBoost dengan integrasi salah satu dari dua mekanisme di atas (fitur rezim atau switching).
- Modul Sinyal & Eksekusi: Output probabilitas XGBoost dikonversi menjadi sinyal {long, short, *hold*} dengan mempertimbangkan biaya transaksi dan position sizing berbasis volatilitas rezim.
- Modul Evaluasi Multi-Rezim: Backtesting dilakukan tidak hanya secara agregat tetapi juga dipecah per rezim untuk menilai stabilitas performa lintas rezim.

Pertanyaan Riset Empiris yang Diajukan untuk Penelitian Lanjutan:

- RQ-E1: Apakah penambahan fitur rezim (Mekanisme 1) menghasilkan peningkatan Sharpe ratio yang signifikan secara statistik dibandingkan XGBoost tanpa fitur rezim?
- RQ-E2: Apakah hyperparameter switching (Mekanisme 2a) mengungguli single-configuration XGBoost pada periode dengan pergeseran rezim?
- RQ-E3: Berapa jumlah rezim optimal (2, 3, atau 4) untuk pasar kripto dari perspektif out-of-sample trading performance?
- RQ-E4: Seberapa robust peningkatan performa (jika ada) terhadap pilihan aset (BTC vs ETH vs altcoin) dan horizon waktu?

Pertanyaan-pertanyaan ini diharapkan menjadi agenda empiris yang dapat diuji pada penelitian lanjutan. Klaim bahwa "kesadaran rezim meningkatkan performa perdagangan" baru dapat dibuat setelah eksperimen terkontrol dengan baseline yang adil, validasi walk-forward, dan pengujian signifikansi statistik dilakukan. Sampai eksperimen tersebut dilakukan, kerangka ini tetap berada pada level proposal dan research direction.

5. Kesimpulan

Tinjauan pustaka sistematis terhadap 20 studi yang dipublikasikan antara 2021 hingga 2026, diseleksi mengikuti PRISMA dari 7.022 catatan awal pada OpenAlex, difilter berdasarkan subjek Scopus Computer Science dan Decision Sciences menjadi 4.910 artikel, kemudian discreening menjadi 20 studi inti, mengungkapkan lanskap penelitian terfragmentasi pada persimpangan deteksi rezim pasar, XGBoost, dan sinyal perdagangan kripto. Pemetaan kuantitatif menunjukkan hanya 10,0% studi (2 dari 20) yang mengintegrasikan rezim dengan XGBoost, sementara 20,0% fokus pada deteksi rezim tanpa XGBoost dan 45,0% menggunakan XGBoost tanpa kesadaran rezim. Celah ini didukung data, bukan interpretasi naratif.

Analisis komparatif menunjukkan kekuatan dan kelemahan kedua pendekatan saling melengkapi: deteksi rezim kuat dalam menangani non-stationarity tetapi lemah pada fitur berdimensi tinggi, sedangkan XGBoost kuat dalam pemetaan fitur-target nonlinier tetapi rentan concept drift. Berdasarkan hal tersebut, naskah ini mengusulkan kerangka Regime-Aware XGBoost sebagai proposal riset, bukan klaim performa, dengan dua mekanisme integrasi: (1) regime label sebagai fitur kategorikal dan (2) regime-triggered switching pada hiperparameter atau strategi. Empat pertanyaan riset empiris (RQ-E1 hingga RQ-E4) diajukan untuk penelitian lanjutan, dengan penegasan bahwa klaim peningkatan performa hanya dapat dibuat setelah validasi empiris melalui eksperimen terkontrol dengan baseline adil, validasi walk-forward, dan uji signifikansi statistik.

6. Referensi

[1] Y. Suganya *et al.*, "Enhancing Cryptocurrency Market Predictability Using Artificial Intelligence: A Platform for Predicting Prices and Trends of Bitcoin, Ethereum, and Cardano," *Int. J. Basic Appl. Sci.*, vol. 14, no. 2, pp. 504–519, Jun. 2025.

[2] Z. Zhang, C. Jiang, and M. Lu, "Fusion of Sentiment and Market Signals for Bitcoin Forecasting: A SentiStack Network Based on a Stacking LSTM Architecture," *Big Data Cogn. Comput.*, vol. 9, no. 6, p. 161, Jun. 2025.

[3] I. Agakishiev, W. K. Härdle, D. Becker, and X. Zuo, "Regime switching forecasting for cryptocurrencies," *Digit. Financ.*, vol. 7, no. 1, pp. 107–131, Jan. 2025.

[4] V. Pakštaitė, E. Filatovas, M. Juodis, and R. Paulavičius, "Bitcoin Price Regime Shifts: A Bayesian MCMC and Hidden Markov Model Analysis of Macroeconomic Influence," *Mathematics*, vol. 13, no. 10, 2025.

[5] S. K. Singh and S. Praveen, "a Comparative Analysis of Tree-Based Ensembles and Deep Learning for Equity Price Forecasting Using Feature-Engineered Advance Technical Indicators," *Int. J. Appl. Math.*, vol. 38, no. 2S, pp. 950–965, Sep. 2025.

[6] V. Srivastava, V. K. Dwivedi, and A. K. Singh, "Cryptocurrency Price Prediction Using Enhanced PSO with Extreme Gradient Boosting Algorithm," *Cybern. Inf. Technol.*, vol. 23, no. 2, pp. 170–187, Jun. 2023.

[7] Y. Zhu *et al.*, "Price Prediction of Bitcoin Based on Adaptive Feature Selection and Model Optimization," *Mathematics*, vol. 11, no. 6, p. 1335, Mar. 2023.

[8] D. L. John, S. Binnewies, and B. Stantic, "Cryptocurrency Price Prediction Algorithms: A Survey and Future Directions," *Forecasting*, vol. 6, no. 3, pp. 637–671, Aug. 2024.

[9] E. Radmand, J. Pirgazi, and A. G. Sorkhi, "A Hybrid TLBO–XGBoost Model With Novel Labeling for Bitcoin Price Prediction," *Int. J. Intell. Syst.*, vol. 2025, no. 1, Jan. 2025.

[10] A. Pagliaro, "Regime-Aware LightGBM for Stock Market Forecasting: A Validated Walk-Forward Framework with Statistical Rigor and Explainable AI Analysis," *Electron.*, vol. 15, no. 6, p. 1334, Mar. 2026.

[11] S. V. Oprea and A. Bâra, "Regime-Aware Adaptive Forecasting Framework for Bitcoin Prices Using Probabilistic Generative Models," *Comput. Econ.*, 2026.

[12] B. R. Manjunath and C. R. Kumar, "Conditional safe haven behavior of bitcoin during market stress using explainable artificial intelligence," *Discov. Artif. Intell.*, vol. 6, no. 1, p. 475, May 2026.

[13] Z. Wen, X. Cheng, R. Xue, J. Ye, Z. Wang, and M. Wang, "A Hardware-Aware Federated Meta-Learning Framework for Intraday Return Prediction Under Data Scarcity and Edge Constraints," *Appl. Sci.*, vol. 16, no. 5, p. 2319, Feb. 2026.

[14] M. Jiménez-Carrión and G. A. Flores-Fernandez, "Machine Learning Algorithms in Predicting Prices in Volatile Cryptocurrency Markets," *HighTech Innov. J.*, vol. 6, no. 1, pp. 257–272, Mar. 2025.

[15] A. El Youssefi, A. Hessane, I. Zeroual, and Y. Farhaoui, "Optimizing Forecast Accuracy in Cryptocurrency Markets: Evaluating Feature Selection Techniques for Technical Indicators," *Comput. Mater. Contin.*, vol. 83, no. 2, pp. 3411–3433, 2025.

[16] A. S. AlRashedy and H. I. Mathkour, "Label-Driven Optimization of Trading Models Across Indices and Stocks: Maximizing Percentage Profitability," *Mathematics*, vol. 13, no. 23, p. 3889, Dec. 2025.

[17] K. Noor and U. Fatima, "Meta Learning Strategies for Comparative and Efficient Adaptation to Financial Datasets," *IEEE Access*, vol. 13, pp. 24158–24170, Dec. 2025.

[18] H. S. Jung, H. Lee, and J. H. Kim, "Detecting Bitcoin Sentiment: Leveraging Language Model Applications in Sentiment Analysis for Bitcoin Price Prediction," *Neural Process. Lett.*, vol. 57, no. 5, 2025.

[19] R. Hasanli and M. Dursun, "Integrating High-Dimensional Technical Indicators into Machine Learning Models for Predicting Cryptocurrency Price Movements and Trading Performance: Evidence from Bitcoin, Ethereum, and Ripple," *FinTech*, vol. 4, no. 4, p. 77, Dec. 2025.

[20] H. S. Jung, J. H. Kim, and H. Lee, "Decoding Bitcoin: leveraging macro- and micro-factors in

time series analysis for price prediction," *PeerJ Comput. Sci.*, vol. 10, pp. e2314--e2314, Sep. 2024.