

Implementasi Trading Strategy pada Saham Sektor Energi dengan Support Vector Machine dan Indikator Teknikal

Giovanka Steviano Harry Premono, Nugroho Agus Haryono², Yuan Lukito³

^{1,2,3}Informatika, Universitas Kristen Duta Wacana, Indonesia

¹giovanka.steviano@ti.ukdw.ac.id, ²nugroho@staff.ukdw.ac.id, ³yuanlukito@ti.ukdw.ac.id

Info Artikel

Riwayat Artikel:

Received 2026-03-11
Revised 2026-05-12
Accepted 2026-05-14

Corresponding Author:

Giovanka Steviano Harry Premono
Email:
giovanka.steviano@ti.ukdw.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstract – The energy sector in the Indonesian capital market is characterized by high volatility, which is sensitive to external factors. This sensitivity leads to complexity in investment decision-making and trader emotional bias. This study employs a Support Vector Machine (SVM)-based trading strategy that incorporates technical indicators, such as Bollinger Bands, the Stochastic Oscillator, On-Balance Volume, and the Average Directional Index, to generate objective transaction signals for 14 energy sector stocks. Historical data from 2015 to 2025 was used, and three kernel types (RBF, polynomial, and sigmoid) were optimized through grid search. The evaluation used classification metrics and backtesting with an initial capital of Rp 100 million. The results showed F1 scores ranging from 35.83% to 47.86%. DEWA achieved the best performance with an accuracy of 66.67% and an F1 score of 47.86%. Backtesting yielded positive returns for 71.4% of stocks, with an average return of 26.85%. RAJA achieved optimal performance, with a 158.97% return and a Sharpe ratio of 1.48, outperforming the buy-and-hold strategy by 37.47%. The main advantage lies in superior risk management, with an average drawdown of -10.64%, compared to the buy-and-hold strategy -48.91%. This results in a 76.1% reduction in risk. The SVM strategy proved effective for low-risk tolerance investors but underperforms during periods of extreme bullish momentum.

Keywords: Backtesting, Energy Sector, Support Vector Machine, Technical Indicator, Trading Strategy

Abstrak – Sektor energi di pasar modal Indonesia dikenal memiliki volatilitas tinggi dan sensitivitas kuat terhadap dinamika eksternal, sehingga menimbulkan tantangan dalam pengambilan keputusan investasi serta meningkatkan potensi bias emosional pelaku pasar. Penelitian ini mengusulkan penerapan strategi trading berbasis Support Vector Machine (SVM) yang dipadukan dengan indikator teknikal Bollinger Bands, Stochastic Oscillator, On-Balance Volume, dan Average Directional Index guna menghasilkan sinyal transaksi yang lebih objektif pada 14 saham sektor energi. Menggunakan data historis periode 2015-2025, tiga jenis kernel (RBF, Polynomial, Sigmoid) dioptimasi melalui grid search. Evaluasi model dilakukan dengan metrik klasifikasi serta backtesting menggunakan modal awal Rp 100 juta. Hasil analisis menunjukkan bahwa nilai F1-score berada pada rentang 35.83%-47.86%, dengan saham DEWA mencatatkan kinerja terbaik (accuracy 66.67%, F1-score 47.86%). Backtesting menunjukkan 71.4% saham menghasilkan imbal hasil positif dengan rata-rata return 26.85%. Saham RAJA mencapai kinerja optimal dengan return 158.97%, dan Sharpe ratio 1.48, melampaui strategi buy and hold sebesar 37.47%. Keunggulan utama strategi ini terletak pada pengelolaan risiko dengan rata-rata drawdown -10,64% jauh lebih rendah dibanding buy and hold sebesar -48,91%, sehingga memberikan reduksi risiko 76,1%. Temuan ini mengindikasikan bahwa strategi SVM efektif bagi investor dengan toleransi risiko rendah, meskipun menunjukkan kinerja kurang optimal pada kondisi pasar dengan momentum bullish ekstrem.

Kata Kunci: Backtesting, Indikator Teknikal, Sektor Energi, Support Vector Machine, Trading Strategy

I. PENDAHULUAN

Sistem ekonomi memiliki peran penting sebagai sarana investasi bagi masyarakat serta sumber pendanaan bagi perusahaan [1]. Dalam konteks Indonesia, perkembangan pasar modal menunjukkan trend pertumbuhan yang kuat. Data Kustodian Sentral Efek Indonesia (KSEI) per Januari 2025 melaporkan jumlah investor sebanyak 14,30 juta jiwa, tumbuh 23,06% dibanding tahun sebelumnya. Pertumbuhan ini mencerminkan perluasan partisipasi publik, namun di saat yang sama menimbulkan tantangan baru, khususnya bagi investor pemula yang menghadapi kondisi pasar dengan volatilitas tinggi dan ketidakpastian arah harga. Kompleksitas tersebut menuntut ketersediaan strategi investasi yang mampu mengelola risiko secara efektif dan mengurangi bias emosional dalam pengambilan keputusan. Peramalan harga saham merupakan salah satu bidang penelitian dan praktik yang paling menantang di bidang

keuangan [2]. Saat ini, prediksi akurat pergerakan harga saham merupakan salah satu alat paling efektif bagi investor. Prediksi ini menjadi lebih menantang ketika pasar saham secara alami bersifat kacau dan tidak pasti [3].

Sektor energi menjadi salah satu sektor yang menarik namun berisiko tinggi di pasar modal Indonesia. Kinerja sektor ini sangat dipengaruhi oleh variabel makroekonomi global seperti harga komoditas energi, geopolitik, serta pertukaran nilai tukar [4], [5]. Pada periode 2019-2024, dinamika sektor energi menunjukkan interaksi kuat antara kenaikan harga energi global, inflasi, dan suku bunga, menghasilkan pola data non-linear dan penuh noise (gangguan), sehingga menyulitkan proses diprediksi [6]. Kondisi ini menegaskan perlunya metode analisis yang mampu menangkap pola kompleks dan non-linear yang tidak tertangkap melalui pendekatan tradisional.

Analisis teknikal konvensional masih menjadi alat utama pelaku pasar dalam memprediksi arah harga, namun penerapannya di pasar dengan volatilitas tinggi seperti sektor energi sering kali tidak efektif. Penggunaan indikator teknikal konvensional yang bersifat lagging seringkali gagal memberikan sinyal yang responsif dan akurat pada kondisi harga yang sangat dinamis [7], [8]. Keterbatasan dalam menangkap pola menggunakan data historis ini mendorong penggunaan pendekatan machine learning yang memiliki kemampuan lebih baik dalam mengenali pola non-linear dan fitur tersembunyi dalam data pasar.

Metode machine learning, khususnya Support Vector Machine (SVM), telah banyak digunakan untuk meningkatkan akurasi prediksi harga saham. SVM dikenal efektif menangani dataset berdimensi tinggi dengan tingkat noise yang signifikan. Penelitian sebelumnya menunjukkan bahwa SVM mampu mengungguli metode lain dalam klasifikasi data yang kompleks, dengan akurasi sebesar 88.09% dibandingkan dengan naive bayes (75.91%), dan Random Forest (81,23%) [9]. Pada pasar saham Indonesia, strategi trading berbasis SVM terbukti menghasilkan return lebih besar dibandingkan strategi buy and hold [10] dan memiliki akurasi yang relatif tinggi [11]. Dalam penggunaan model SVM, terlebih dahulu dilakukan proses seleksi fitur. Seleksi fitur merupakan mekanisme untuk memilih subset fitur yang paling relevan dan informatif dalam menjelaskan atau memprediksi kelas target, sehingga meningkatkan kinerja model [12]. Temuan-temuan tersebut mengindikasikan bahwa algoritma SVM dapat diterapkan pada sektor energi yang memiliki volatilitas tinggi [13].

Di sisi lain, integrasi indikator teknikal dengan algoritma machine learning terbukti meningkatkan kinerja prediksi. Indikator teknikal mampu merepresentasikan kondisi pasar dari berbagai aspek, seperti volatilitas, momentum, kekuatan tren, dan tekanan volume jual/beli. Studi sebelumnya menunjukkan bahwa kombinasi indikator teknikal dengan algoritma machine learning mampu meningkatkan akurasi prediksi dan kualitas sinyal transaksi secara signifikan dibandingkan penggunaan data harga mentah [14]. Stochastic Oscillator mampu meningkatkan akurasi prediksi SVM pada saham dengan fluktuasi tinggi, khususnya pada sektor energi (Agusta et al., 2022). Bollinger Bands terbukti efektif dalam mempresentasikan volatilitas harga sekaligus mengidentifikasi peluang pembelian yang optimal [15], [16]. Sementara itu, indikator OBV berperan dalam menangkap tekanan jual dan beli yang berkontribusi terhadap peningkatan return serta pengurangan risiko portofolio [17]. Lebih lanjut, kombinasi ADX dengan SVM menunjukkan kinerja yang unggul dengan tingkat akurasi mencapai 92,34% dan return sebesar 28,02%, melampaui strategi jual beli manual yang hanya menghasilkan return sebesar 15,91% [18].

Meskipun berbagai indikator teknikal seperti Moving Average, RSI, Stochastic Oscillator, dan MACD terbukti populer di pasar saham Indonesia, sebagian besar penelitian masih menerapkannya secara rule-based tanpa integrasi machine learning [19], [20]. Berbagai penelitian terdahulu telah mengkaji penerapan Support Vector Machine (SVM) dalam prediksi harga saham maupun pembentukan sinyal trading. Secara umum, SVM dilaporkan unggul dibandingkan algoritma lain seperti Naïve Bayes dan Random Forest dalam menangani data pasar yang bersifat non-linear dan berdimensi tinggi. Namun, sebagian besar studi tersebut dilakukan pada indeks pasar secara agregat atau sektor campuran, tanpa memperhatikan karakteristik spesifik sektor dengan volatilitas ekstrem seperti sektor energi Indonesia. Selain itu, evaluasi kinerja model pada penelitian sebelumnya umumnya berfokus pada akurasi atau metrik klasifikasi semata, sehingga kurang mencerminkan kinerja strategi perdagangan dalam konteks investasi riil. Penelitian-penelitian yang mengintegrasikan indikator teknikal dengan SVM memang menunjukkan peningkatan performa prediksi, namun umumnya menggunakan satu hingga dua indikator teknikal, serta jarang menguji ketahanan strategi melalui backtesting jangka panjang. Pendekatan tersebut berpotensi menghasilkan sinyal yang optimal secara statistik tetapi kurang robust ketika diterapkan pada kondisi pasar yang berfluktuasi tajam dan penuh noise. Beberapa studi juga menunjukkan hasil yang kontradiktif, di mana peningkatan akurasi klasifikasi tidak selalu berbanding lurus dengan peningkatan return atau penurunan risiko portofolio, sehingga menimbulkan kesenjangan antara performa model secara teoretis dan aplikatif. Berbeda dari pendekatan-pendekatan tersebut, penelitian ini memposisikan diri secara komparatif dengan menekankan analisis sektoral yang lebih spesifik, integrasi multi-indikator teknikal lintas dimensi pasar (volatilitas, momentum, volume, dan kekuatan tren), serta evaluasi komprehensif yang mengombinasikan metrik klasifikasi dan kinerja investasi berbasis backtesting. Dengan pendekatan ini, penelitian tidak hanya menilai seberapa akurat model dalam memprediksi sinyal, tetapi juga sejauh mana sinyal tersebut dapat diterjemahkan menjadi strategi trading yang efektif dan berkelanjutan di pasar nyata.

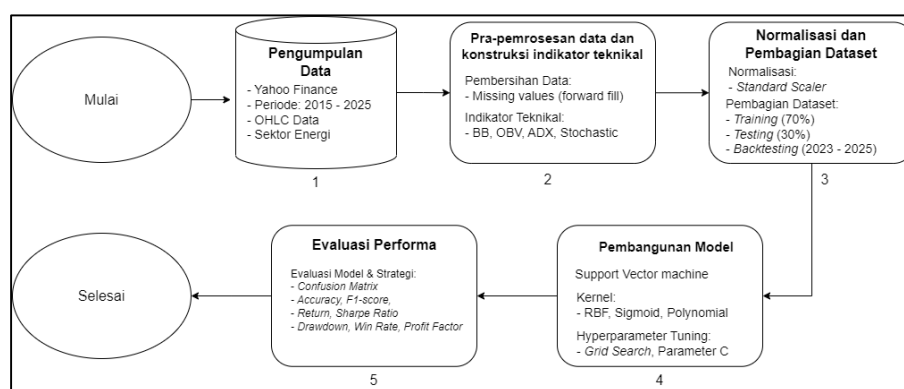
Berdasarkan gap tersebut, Novelty utama dari penelitian ini terletak pada pengembangan dan evaluasi strategi trading berbasis Support Vector Machine (SVM) yang secara khusus difokuskan pada saham sektor energi di pasar modal Indonesia dengan karakter volatilitas tinggi, melalui integrasi simultan empat indikator teknikal utama—

Bollinger Bands, Stochastic Oscillator, On-Balance Volume, dan Average Directional Index—serta evaluasi kinerja berbasis klasifikasi dan backtesting terintegrasi. Berbeda dengan penelitian sebelumnya yang umumnya bersifat general lintas sektor, menggunakan indikator terbatas, atau hanya menitikberatkan pada akurasi prediksi, penelitian ini menekankan evaluasi performa riil strategi perdagangan dengan mempertimbangkan imbal hasil, risiko, dan ketahanan portofolio terhadap fluktuasi ekstrem pasar.

Kontribusi ilmiah dari penelitian ini adalah penyediaan bukti empiris bahwa efektivitas model SVM bersifat spesifik per emiten dan sangat dipengaruhi oleh kombinasi indikator teknikal, jenis kernel, serta horizon prediksi, sehingga menantang asumsi adanya konfigurasi model yang universal optimal. Hasil penelitian ini memperkaya literatur machine learning untuk perdagangan saham dengan menegaskan pentingnya pendekatan adaptif dan berbasis sektor, khususnya pada sektor energi yang memiliki pola non-linear dan noise tinggi.

II. METODE PENELITIAN

Metodologi penelitian ini terdiri dari lima tahapan utama sebagaimana ditampilkan pada Gambar 1, yakni: (1) Pengumpulan Data, (2) Pra-pemrosesan data dan konstruksi indikator teknikal, (3) Normalisasi dan Pembagian Dataset, (4) Pembangunan Model, dan (5) Evaluasi Kinerja.



Gambar 1. Diagram Metode Penelitian

A. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data historis harga saham harian diperoleh dari platform *Yahoo Finance* untuk 14 emiten sektor energi dengan kapitalisasi pasar terbesar di Bursa Efek Indonesia (BEI) per 1 Desember 2025. Periode observasi mencakup rentang waktu 1 Januari 2015 hingga 30 Juni 2025, yang selanjutnya dibagi menjadi dua subset, yaitu: data latih (1 Januari 2015 – 31 Desember 2022) dan data uji untuk validasi strategi trading (1 Januari 2023 – 30 Juni 2025). Variabel yang dikumpulkan meliputi enam komponen utama, yaitu: tanggal (*date*), harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), serta volume perdagangan (*volume*). Seluruh data diunduh menggunakan *Python library yfinance* dengan harga yang telah disesuaikan terhadap *corporate actions* seperti *stock split*, namun tidak dilakukan penyesuaian terhadap dividen. Daftar lengkap emiten yang menjadi objek penelitian disajikan pada Tabel 1.

TABEL 1
DAFTAR EMITEN

Kode Emiten	Nama Perusahaan
ADRO.JK	Alamtri Resources Indonesia Tbk
AKRA.JK	AKR Corporindo Tbk.
BUMI.JK	Bumi Resources Tbk
BYAN.JK	Byan Resources Tbk.
DEWA.JK	Darma Henwa Tbk
DSSA.JK	Dian Swastatika Sentosa Tbk.
ENRG.JK	Energi Mega Persada Tbk.
GEMS.JK	Golden Energy Mines Tbk
ITMG.JK	Indo Tambangraya Megah Tbk.
MEDC.JK	Medco Energi Internasional Tbk.
PGAS. JK	Perusahaan Gas Negara Tbk.
PTBA. JK	Bukit Asam Tbk.
PTRO. JK	Petrosea Tbk.
RAJA.JK	Rukun Rahaja Tbk.

B. Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan kualitas, kelengkapan, dan konsistensi data sebelum digunakan dalam proses pemodelan. Dua langkah utama dilakukan pada tahap ini, yaitu pembersihan data dan perhitungan indikator teknikal. Data historis terlebih dahulu dibersihkan dari nilai kosong (*missing value*) menggunakan metode *forward fill*, di mana setiap nilai yang hilang digantikan dengan harga penutupan terakhir yang tersedia. Metode ini dipilih untuk menjaga kontinuitas data sehingga siap digunakan untuk keperluan analisis [21], dan tidak menimbulkan bias dalam konstruksi indikator teknikal maupun dalam proses pelatihan model.

C. Konstruksi Indikator Teknikal

Empat indikator teknikal digunakan sebagai fitur utama model SVM, dengan masing-masing indikator merepresentasikan dimensi pasar yang berbeda: volatilitas melalui *Bollinger Bands*, momentum melalui *stochastic oscillator*, tekanan volume melalui *on-balance volume*, serta kekuatan tren melalui *Average Directional Index*. Penentuan parameter untuk setiap indikator dilakukan secara sistematis agar sesuai dengan karakteristik data dan tujuan penelitian. Rincian parameter yang digunakan dalam konstruksi indikator teknikal disajikan pada **Error! Reference source not found.**

TABEL 2
PARAMETER INDIKATOR TEKNIKAL

Indikator	Parameter	Nilai
BB	Period, Std Dev	20, 2
Stoch Osc	%K Period, %D period	14, 3
OBV	MA Period	10
ADX	Period	14

Penjelasan rumus dan interpretasi masing-masing indikator adalah sebagai berikut:

1) *Bollinger Bands*: *Bollinger Bands* merupakan indikator volatilitas yang terdiri atas tiga komponen utama, yaitu: *upper band*, *middle band* (*simple moving average*), dan *lower band*. Rumus perhitungan BB ditunjukkan pada persamaan (1) [22].

$$\begin{aligned} \text{UpperBand} &= \text{SMA}_n + K \times \sigma_n \\ \text{LowerBand} &= \text{SMA}_n - K \times \sigma_n \end{aligned} \quad (1)$$

dengan:

SMA_n = *Simple Moving Average* periode n

K = *Multiplier* (nilai umum $K = 2$)

n = Periode *lookback* (nilai umum = 20)

2) *Stochastic Oscillator*: *Stochastic Oscillator* merupakan indikator momentum yang digunakan untuk mengukur posisi harga penutupan relatif terhadap rentang harga dalam suatu periode tertentu [22]. Rumus perhitungan *Stochastic Oscillator* ditunjukkan pada persamaan (2).

$$K^{Fast}(T_K) = \frac{P_t - P \frac{L}{T_K}}{P \frac{H}{T_K} - P \frac{L}{T_K}} \times 100$$

$$\begin{aligned} D^{Fast}(T_{FastD}) &= MA(T_{FastD})[K^{Fast}] \\ K^{Slow}(T_{SlowK}) &= MA(T_{SlowK})[K^{Fast}] \\ D^{Slow}(T_{SlowD}) &= MA(T_{SlowD})[K^{Slow}] \end{aligned} \quad (2)$$

Dengan P_t adalah harga penutupan pada waktu ke- t , $P_{T_K}^L$ dan $P_{T_K}^H$ masing-masing adalah harga terendah dan tertinggi selama periode T_K (default 14 hari). MA menyatakan *simple moving average*. Parameter T_{FastD} adalah periode *moving average* untuk D^{Fast} (default 3 hari), T_{SlowK} adalah periode *moving average* untuk K^{Slow} (default 3 hari), dan T_{SlowD} adalah periode *moving average* untuk D^{Slow} (default 3 hari). Nilai $K > 80$ menunjukkan kondisi *overbought* (jenuh beli), sedangkan $K < 20$ menunjukkan kondisi *oversold* (jenuh jual).

3) *On-Balance Volume (OBV)*: *OBV* merupakan indikator momentum yang menghubungkan volume perdagangan dengan perubahan harga, dan secara teori diasumsikan mampu mendahului pergerakan harga [22]. Nilai *OBV* pada periode saat ini (OBV_t) dihitung dengan menambahkan atau mengurangi volume saat ini terhadap nilai *OBV* periode sebelumnya (OBV_{t-1}), tergantung pada arah harga penutupan. Apabila harga penutupan saat ini (P_t) lebih tinggi dibandingkan harga penutupan sebelumnya (P_{t-1}), maka volume perdagangan ditambahkan ke nilai

OBV sebelumnya. Sebaliknya, apabila harga penutupan saat ini lebih rendah, maka volume perdagangan dikurangkan dari nilai OBV sebelumnya. Rumus perhitungan OBV ditunjukkan pada persamaan (3).

$$OBV_T = \begin{cases} OBV_{t-1} + V_t & \text{Jika } P_t > P_{t-1} \\ OBV_{t-1} - V_t & \text{Jika } P_t < P_{t-1} \\ OBV_{t-1} & \end{cases} \quad (3)$$

4) *Average Directional Index (ADX)*: ADX merupakan indikator teknikal yang digunakan untuk mengukur suatu tren tanpa mempertimbangkan arah pergerakan harga. Perhitungan ADX dilakukan berdasarkan informasi dari dua komponen utama, yaitu selisih antara *Positive Directional Index (PLUSDI)*, dan *Negative Directional Index (MINUSDI)* yang dibagi dengan jumlah keduanya, kemudian dirata-ratakan dengan *Simple Moving Average (SMA)* dan dikalikan 100. Nilai *PLUSDI* dan *MINUSDI* sendiri diperoleh dari *SMA PLUSDM* dan *MINUSDM* yang dinormalisasi dengan *Average True Range (ATR)* [22]. Perhitungan ADX diberikan dalam Persamaan (4).

$$ADX = 100 \times SMA(N)_t \times \frac{|PLUSDI_t - MINUSDI_t|}{PLUSDI_t + MINUSDI_t} \quad (4)$$

D. Pelabelan Data

Pelabelan data dilakukan menggunakan *Python library pandas* dengan pendekatan *triple-class labeling*. Proses pelabelan dimulai dengan menghitung *return* harga penutupan dari waktu t ke $t + h$ menggunakan persamaan (5).

$$Return = \frac{Close_{t+h} - Close_t}{Close_t} \quad (5)$$

Dengan h merepresentasikan *horizon* prediksi dalam satuan hari perdagangan. Penelitian ini digunakan tiga *horizon* berbeda, yaitu 3, 5, dan 10 hari untuk menangkap variasi dinamika jangka pendek, menengah, dan semi menengah pada emiten sektor energi. Setiap observasi kemudian diklasifikasikan ke dalam tiga kelas berdasarkan *neutral band* yang ditentukan secara dinamis menggunakan *ATR*. Ambang batas ditetapkan menggunakan multiplier 1.5 x *ATR*, sehingga kelas target didefinisikan sebagai berikut:

Buy (1): Jika $return > (1.5 \times ATR)$
 Sell (-1): Jika $return < -(1.5 \times ATR)$
 Hold (0): Jika $-(1.5 \times ATR) \leq return \leq (1.5 \times ATR)$

Average True Range (ATR) digunakan karena merupakan ukuran volatilitas yang mampu menangkap ketidakpastian pergerakan harga, termasuk risiko terjadinya *price gap* atau loncatan harga antar periode [23]. Rumus *ATR* ditunjukkan pada persamaan (6).

$$ATR = \frac{(ATR_{t-1} \times (n-1)) + TR_t}{n} \quad (6)$$

dengan:


n : Periode waktu standar (14 Periode).
 ATR : Nilai *ATR* saat ini.
 TR : *True Range* Saat ini.

Nilai *True Range (TR)* mewakili rentang fluktuasi harga tertinggi dalam satu periode dan didefinisikan sebagai nilai maksimum dari tiga komponen absolute berikut: (1)selisih antara *high* dan *low* periode berjalan, (2)selisih absolut antara *high* saat ini dengan *close* periode sebelumnya, dan (3)selisih absolut antara *low* saat ini dengan *close* periode sebelumnya. Penerapan *ATR* sebagai *threshold* dinamis memungkinkan adaptasi terhadap volatilitas emiten, sehingga mampu meminimalkan *noise* dan distorsi sinyal palsu.

E. Normalisasi dan Pembagian Dataset

Proses normalisasi dilakukan untuk menyelaraskan skala antar fitur sehingga tidak terdapat variabel yang secara tidak proporsional mendominasi proses komputasi pada model SVM. Normalisasi menjadi langkah penting karena algoritma SVM sangat sensitif terhadap perbedaan skala antar fitur, khususnya pada perhitungan jarak dan transformasi ruang fitur yang dilakukan oleh fungsi kernel. Oleh karena itu, seluruh fitur numerik dalam penelitian ini dinormalisasi menggunakan metode **Standard Scaler** dari *library scikit-learn*, yang mentransformasikan data menjadi distribusi dengan rata-rata 0 dan standar deviasi 1.

Dataset dibagi dalam dua tahap untuk menghindari *look-ahead* bias dan memastikan evaluasi model yang robust. Tahap pertama menggunakan *time-based splitting*, di mana data periode 2015–2022 digunakan sebagai data untuk membangun model, sedangkan periode 2023–2025 digunakan sebagai data *backtesting* untuk menguji kinerja strategi secara *out-of-sample*. Pembagian berbasis waktu ini konsisten dengan praktik terbaik pemodelan deret waktu dan pengembangan strategi perdagangan berbasis machine learning. Tahap kedua dilakukan pada data latih dengan skema *train-validation split* berasio 70:30, sehingga 70% dialokasikan untuk pelatihan model dan 30% untuk pengujian internal. Pendekatan dua tahap ini memungkinkan model divalidasi terlebih dahulu pada lingkungan *in-sample* sebelum diuji lebih lanjut pada kondisi pasar riil melalui *backtesting*. Struktur pembagian data ini ditunjukkan pada Gambar 2.



Gambar 2. Pembagian Dataset

F. Pembangunan Model

Pembangunan model dilakukan menggunakan *library scikit-learn*, dengan mengimplementasikan algoritma SVM untuk tugas klasifikasi arah pergerakan harga. Tiga jenis fungsi kernel diuji, yakni *Radial Basis Function* (RBF), *Polynomial*, dan *Sigmoid*, untuk mengevaluasi kemampuan masing-masing kernel dalam menangkap pola non-linear pada data harga saham sektor energi yang bersifat volatil. Proses eksplorasi model dilakukan melalui hyperparameter tuning menggunakan *GridSearchCV*, dengan skema *TimeSeriesSplit* guna memastikan bahwa urutan temporal data tetap terjaga dan tidak terjadi *data leakage* selama proses validasi. Pendekatan ini secara khusus relevan untuk data deret waktu keuangan yang sensitif terhadap dependensi temporal. Selain itu, parameter *class_weight='balanced'* diterapkan pada seluruh konfigurasi model untuk mengatasi ketidakseimbangan kelas yang muncul akibat penggunaan *triple-class labeling*. Pendekatan ini memungkinkan bobot kelas dihitung proporsional terhadap frekuensi kemunculannya, sehingga model tidak bias terhadap kelas mayoritas. Daftar lengkap hyperparameter yang dioptimasi untuk masing-masing kernel disajikan pada Tabel 3.

TABEL 3
 PARAMETER TUNING SVM

Kernel	Parameter	Nilai
RBF	C	0,5, 1,0, 2,0, 5,0
Polynomial	C	0,5, 1,0, 2,0, 5,0
Sigmoid	C	0,5, 1,0, 2,0, 5,0

G. Evaluasi Kinerja Model

Evaluasi performa model dilakukan menggunakan *confusion matrix* beserta metrik turunannya untuk menilai kemampuan SVM dalam menghasilkan sinyal transaksi yang akurat. *Confusion matrix* adalah tabel yang memetakan hasil klasifikasi dengan membandingkan label aktual dan label prediksi [24]. Karena penelitian ini menerapkan skema multi-class classification dengan tiga kelas (*Buy, Hold, Sell*), maka struktur *confusion matrix* yang digunakan berbentuk 3×3, di mana setiap baris merepresentasikan kelas aktual dan setiap kolom menunjukkan kelas prediksi. Struktur umum *confusion matrix* untuk klasifikasi multi-class ditunjukkan pada Gambar 3 [22].

		Predicted			TP = True Positive FP = False Positive FN = False Negative
		Sell	Hold	Buy	
Actual	Sell	TP	FN FP Untuk HOLD	FN FP Untuk BUY	
	Hold	FN FP Untuk SELL	TP	FN FP Untuk BUY	
	Buy	FN FP Untuk SELL	FN FP Untuk HOLD	TP	

Gambar 3. Ilustrasi *Confusion Matrix*

Untuk menilai kinerja model secara komprehensif, *confusion matrix* dikombinasikan menjadi beberapa metrik yang mengukur aspek berbeda dari kinerja klasifikasi. Metrik evaluasi yang digunakan adalah:

- *Accuracy*: *Accuracy* mengukur tingkat akurasi dari model yang telah dilatih, adapun rumus untuk menghitung ditunjukkan pada persamaan (7) [22].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

- *Precision* dan *recall*: *Precision* mengukur ketepatan model dalam memprediksi kelas positif, sedangkan *recall* mengukur kemampuan model dalam mengidentifikasi seluruh kasus positif pada *threshold* tertentu, rumus *precision* dan *recall* ditunjukkan pada persamaan (8) [22].

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

- *F1-Score*: *F1-Score* adalah *harmonic mean* dari *precision* dan *recall* yang menekankan nilai terendah antara keduanya. Metrik ini bernilai tinggi jika *precision* dan *recall* sama-sama baik, sehingga cocok untuk menilai keseimbangan performa klasifikasi. [22]. Formula *F1-Score* ditunjukkan pada persamaan (9)

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (9)$$

Backtesting dilakukan untuk memvalidasi kinerja *trading strategy* menggunakan data historis [25]. Simulasi menggunakan asumsi: modal awal Rp 100 juta, ukuran posisi 10% per transaksi, dan biaya transaksi 0,15% (*Buy*) serta 0,25% (*Sell*). Aturan eksekusi: sinyal "*Buy*" mengeksekusi pembelian pada harga penutupan hari yang sama, "*Sell*" menjual seluruh posisi, dan "*Hold*" tidak melakukan transaksi. Lima metrik kinerja dievaluasi untuk menilai performa *strategy* (Jansen, 2020).

- *Return*: *Return* menghitung keuntungan atau kerugian investasi sebagai perubahan nilai portofolio relatif terhadap dana awal selama periode tertentu [22]. Formula *return* ditampilkan pada persamaan (10).

$$Return = \frac{Nilai\ akhir - Nilai\ awal}{Nilai\ Awal} \times 100\% \quad (10)$$

- *Sharpe Ratio*: *Sharpe ratio* mengukur kinerja portofolio dengan membandingkan *return* berlebih terhadap tingkat risiko yang diambil, yang direpresentasikan oleh volatilitas *return* [22]. Formula *sharpe ratio* ditunjukkan pada persamaan (11).

$$S = \frac{R_p - R_f}{\sigma_p} \quad (11)$$

- *Drawdown*: *Drawdown* adalah salah satu metrik yang mengukur seberapa besar penurunan nilai portofolio dari titik puncaknya ke titik terendah dalam periode tertentu [22]. Rumus *drawdown* ditampilkan pada persamaan (12).

$$DD = \frac{Peak_t - Value_t}{Peak_t} \times 100\% \quad (12)$$

- *Profit Factor*: *Profit factor* Adalah rasio antara total keuntungan dan total kerugian dalam periode tertentu [22]. Formula *profit factor* ditunjukkan pada persamaan (13).

$$R = \frac{Total\ Profit}{Total\ Loss} \quad (13)$$

- *Win Rate*: *Win rate* mengukur seberapa sering strategi menghasilkan keuntungan dibandingkan dengan seluruh jumlah transaksi. Win rate adalah persentase transaksi yang untung [26]. Rumus *win rate* diberikan pada persamaan (14).

$$WR = \frac{Transaksi\ Profit}{Total\ Transaksi} \times 100\% \quad (14)$$

III. HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil pemodelan dan implementasi strategi perdagangan berbasis SVM yang diterapkan pada 14 emiten sektor energi. Hasil analisis mencakup performa klasifikasi model dalam menghasilkan sinyal transaksi serta kinerja investasi yang diperoleh melalui proses backtesting. Pembahasan difokuskan pada relevansi temuan dengan dinamika pasar energi Indonesia yang bervolatilitas tinggi.

A. Hasil Grid Search dan Pemilihan Model Terbaik


Optimasi *hyperparameter* dilakukan melalui *grid search* untuk menemukan konfigurasi terbaik bagi setiap emiten. Hasil dari *grid search* ditunjukkan pada Tabel 4, dimana tabel tersebut menampilkan kombinasi optimal dari *kernel*, parameter *C*, dan *lookup period* yang menghasilkan *F1-score* tertinggi. Hasil *grid search* menunjukkan variasi performa klasifikasi yang signifikan antar emiten. DEWA mencatat performa terbaik dengan *F1-score* 47.86%, menggunakan kombinasi empat indikator (BB, Stochastic, OBV, ADX), *kernel Polynomial*, dan *lookup period* 5 hari. Sebaliknya, PGAS memiliki *F1-score* terendah (35.83%) meskipun menggunakan dua indikator (BB & Stochastic) dan *kernel Sigmoid*, menandakan bahwa penambahan jumlah indikator tidak selalu meningkatkan akurasi. Emiten lainnya menunjukkan performa menengah dengan *F1-score* berkisar antara 36.15% hingga 44.33%, menunjukkan bahwa optimalisasi kombinasi indikator, *kernel*, dan parameter *lookup period* bersifat spesifik per emiten. Hal ini menekankan pentingnya penyesuaian konfigurasi model untuk tiap saham agar performa klasifikasi maksimal.

TABEL 4
KONFIGURASI OPTIMAL DAN PERFORMA KLASIFIKASI MODEL PER EMITEN

Emiten	Indikator	Lookup Period	Kernel	C	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
ADRO	BB	10	Sigmoid	0,5	44,08	38,93	38,28	38,03
AKRA	BB, Stochastic, OBV	10	RBF	5,0	41,50	38,63	38,42	37,50
BUMI	BB, Stochastic, OBV, ADX	10	Polynomial	0,5	50,70	42,28	43,22	42,54
BYAN	BB	10	Polynomial	5,0	45,88	41,29	39,14	39,55
DEWA	BB, Stochastic, OBV, ADX	5	Polynomial	5,0	66,67	47,56	56,49	47,86
DSSA	BB, Stochastic	10	Sigmoid	1,0	40,42	40,96	40,97	40,39
ENRG	BB, Stochastic, OBV, ADX	10	RBF	0,5	51,78	43,86	46,80	44,33
GEMS	BB	5	Polynomial	2,0	52,47	44,65	45,05	43,21
ITMG	BB, Stochastic, OBV, ADX	10	Polynomial	0,5	38,44	38,77	40,59	38,10
MEDC	BB, Stochastic	10	Sigmoid	0,5	38,91	39,41	40,56	38,45
PGAS	BB, Stochastic	5	Sigmoid	2,0	44,35	37,27	38,75	35,83
PTBA	BB, Stochastic, OBV	10	Sigmoid	1,0	38,64	36,93	36,35	36,15
PTRO	BB, Stochastic, OBV, ADX	5	Polynomial	1,0	46,87	36,86	37,54	36,19
RAJA	BB, Stochastic	10	RBF	1,0	40,41	40,79	41,13	37,70


1. Pembahasan Konfigurasi Optimal

Distribusi frekuensi pemilihan *kernel* pada model terbaik menunjukkan pola yang jelas, sebagaimana ditunjukkan pada Gambar 4 yang menunjukkan bahwa *kernel Polynomial* paling sering dipilih (6 emiten), diikuti *Sigmoid* (5 emiten) dan *RBF* (3 emiten). Perbedaan distribusi ini menunjukkan bahwa tidak ada satu *kernel* yang universal optimal untuk semua emiten. Setiap emiten memiliki karakteristik data yang berbeda, sehingga memerlukan pemilihan *kernel* yang disesuaikan. Temuan ini menekankan pentingnya penyesuaian konfigurasi model per emiten untuk mencapai performa optimal.



Gambar 4. Diagram Frekuensi *Kernel* optimal


Visualisasi frekuensi kombinasi indikator pada model terbaik disajikan pada Gambar 5. Kombinasi lengkap empat indikator (BB, *Stochastic*, OBV, ADX) paling banyak digunakan pada 5 emiten, diikuti oleh BB & *Stochastic* pada 4 emiten, BB tunggal pada 3 emiten, dan kombinasi tiga indikator (BB, *Stochastic*, OBV) pada 2 emiten. Hasil ini menunjukkan bahwa penambahan jumlah indikator tidak selalu menghasilkan performa optimal. Setiap saham memiliki karakteristik pasar yang unik, sehingga pemilihan indikator harus disesuaikan untuk setiap emiten secara spesifik.



Gambar 5. Diagram Frekuensi Kombinasi Indikator


2. Confusion Matrix

Setelah mengidentifikasi konfigurasi optimal, performa klasifikasi model dievaluasi secara komprehensif menggunakan *confusion matrix* berukuran 3×3 untuk memvisualisasikan distribusi prediksi model terhadap tiga kelas: *Sell*, *Hold*, dan *Buy*. Tiga emiten dipilih untuk merepresentasikan performa: DEWA (performa terbaik), PTRO (*balanced prediction*), dan AKRA (*extreme bias*). Sebagaimana ditunjukkan pada Gambar 6, DEWA mencatatkan performa tertinggi (*f1-score* 47,86%, *accuracy* 66,67%) menggunakan kombinasi BB, *Stochastic*, OBV, ADX dengan *kernel Polynomial* dan *lookup period* 5 hari. Model menunjukkan deteksi *HOLD* yang sangat baik, namun gagal mendeteksi kelas *BUY* sama sekali, mengindikasikan model cenderung konservatif. Meskipun demikian, konfigurasi ini efektif mengidentifikasi kondisi pasar *sideways* pada DEWA yang memiliki karakteristik harga relatif stabil.



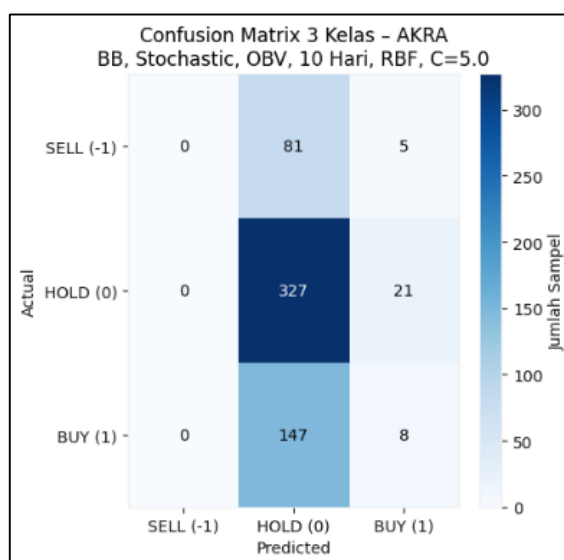
Gambar 6. Matriks Confusion saham DEWA

Kinerja seimbang diberikan oleh saham PTRO (*f1-score* 36,19%, *accuracy* 46,87%) menggunakan kombinasi empat indikator dengan *kernel Polynomial* dan *lookup period* 5 hari seperti ditunjukkan oleh Gambar 7. Berbeda dengan DEWA, model PTRO mampu mendeteksi tiga kelas sinyal tanpa ada yang diabaikan sepenuhnya, meskipun bias moderat terhadap prediksi *SELL*. Pola seperti ini lebih diandalkan karena model dapat memberikan sinyal untuk berbagai kondisi pasar, menghindari situasi dimana investor tidak mendapat sinyal sama sekali untuk kondisi tertentu.



Gambar 7. Matriks Confusion saham PTRO

Pola yang bermasalah diperlihatkan oleh saham AKRA dengan $f1$ -score 37,50% dan akurasi sebesar 41,50%, seperti ditunjukkan pada Gambar 8. *Confusion matrix* mengungkapkan bias ekstrem dimana model hanya mampu mendeteksi kelas *HOLD*, sementara kelas *SELL* dan *BUY* gagal total tanpa satu pun prediksi benar. Kondisi ini mengindikasikan *overfitting* pada kelas mayoritas, sehingga model gagal memberikan rekomendasi *trading* yang bisa ditindaklanjuti.



Gambar 8. Matriks Confusion saham AKRA

Perbandingan ketiga contoh ini mengilustrasikan bahwa $f1$ -score agregat tidak cukup untuk menilai performa model. DEWA memiliki *accuracy* tinggi namun terbatas pada kelas tertentu, PTRO menunjukkan *balance* yang lebih baik meski akurasi moderat, dan AKRA mengkonfirmasi bahwa *class imbalance* ekstrem dapat menghasilkan model yang tampak baik secara statistik namun tidak berguna untuk *trading*.

B. Hasil Backtesting Trading Strategy

Hasil backtesting trading strategy berbasis SVM pada periode pengujian 2023-2025 disajikan pada Tabel 5.

TABEL 5
RINGKASAN KINERJA BACKTESTING TRADING STRATEGY PADA 14 EMITEN SEKTOR ENERGI

Emiten	Return (%)	Buy and Hold (%)	Win Rate (%)	Profit Factor (%)	Sharpe Ratio (%)	Max Drawdown (SVM) (%)	Max Drawdown (B&H) (%)
ADRO	0,00	-50,14	0,00	0,00	N/A	0,00	-59,28
AKRA	41,37	-14,08	100,00	∞	1,88	0,00	-51,35
BUMI	23,48	-29,81	66,67	9,54	4,13	-0,61	-58,43
BYAN	12,93	-8,00	100,00	∞	0,08	0,00	-41,61
DEWA	47,65	232,08	51,61	2,18	1,31	-9,11	-40,69
DSSA	80,73	1352,63	59,26	6,05	2,28	-4,05	-38,31
ENRG	29,02	12,84	39,47	1,60	1,14	-18,12	-47,70
GEMS	7,30	30,14	66,67	33,18	0,81	-0,24	-53,27
ITMG	8,90	-44,38	50,00	1,64	0,96	-4,15	-46,93
MEDC	-12,48	16,51	48,00	0,83	-0,09	-27,21	-43,84
PGAS	5,54	-10,92	84,62	1,16	-0,18	-32,15	-38,79
PTBA	-8,92	-34,96	24,44	0,80	-0,68	-15,91	-44,44
PTRO	-18,55	495,79	42,86	0,70	-0,60	-28,19	-55,14
RAJA	158,97	121,50	66,04	5,32	0,69	-9,26	-65,01
Rata-Rata (%)	26,85	147,80	57,12	5,25	0,73	-10,64	-48,91
Standar Dev (%)	48,56	376,88	28,73	9,70	1,39	12,23	15,76

Hasil *backtesting* strategi berbasis SVM pada 14 emiten sektor energi menunjukkan variasi performa yang signifikan. Sepuluh saham mencatat *return* positif dengan rata-rata 26.85%, sedangkan strategi *Buy and Hold* rata-rata 147.80%, meskipun beberapa emiten seperti PTRO (-18.55%) dan PTBA (-8.92%) mengalami *return* negatif. RAJA mencatat performa terbaik dengan *return* 158.97%, *profit factor* 5.32, dan *Sharpe ratio* 0.69, sementara ADRO *return* 0% karena tidak melakukan transaksi. Strategi SVM terbukti mengurangi risiko, dengan rata-rata *max drawdown* -10,64% dibanding *Buy & Hold* -48.91%, meskipun *win rate* rata-rata hanya 57.12%.

Standar deviasi *return* sebesar 48.56% menunjukkan volatilitas tinggi antar emiten, sementara standar deviasi *max drawdown* (12.23% untuk SVM, 15.76% untuk B&H) mengindikasikan pengelolaan risiko yang lebih stabil. Temuan ini menunjukkan bahwa strategi SVM lebih konsisten dalam mengendalikan fluktuasi ekstrem dan tetap memerlukan penyesuaian per emiten untuk mengoptimalkan hasil.

Perbandingan kinerja strategi *Support Vector Machine* (SVM) dan *Buy and Hold* pada saham ENRG dan AKRA selama periode pengujian menunjukkan perbedaan pola pertumbuhan portofolio yang signifikan, sebagaimana ditunjukkan pada Gambar 9 dan Gambar 10. Pada saham ENRG, diagram *return* SVM terlihat lebih stabil dengan pertumbuhan yang bertahap, sementara *Buy and Hold* mengalami fluktuasi yang lebih tajam. Hingga akhir periode, nilai portofolio SVM berada di atas *Buy and Hold*, mengindikasikan bahwa model mampu menghindari sebagian fase penurunan harga serta memanfaatkan momentum kenaikan secara lebih selektif. Pada saham AKRA, perbedaan kinerja tampak lebih signifikan. *Buy and Hold* mengalami penurunan yang cukup dalam saat fase *bearish*, sedangkan SVM menunjukkan tren kenaikan yang relatif konsisten. Secara umum, kedua visualisasi memperlihatkan bahwa strategi SVM tidak hanya berpotensi menghasilkan *return* yang lebih tinggi, tetapi juga lebih defensif dalam mengelola risiko dengan menekan *drawdown* dibandingkan pendekatan pasif *Buy and Hold*.

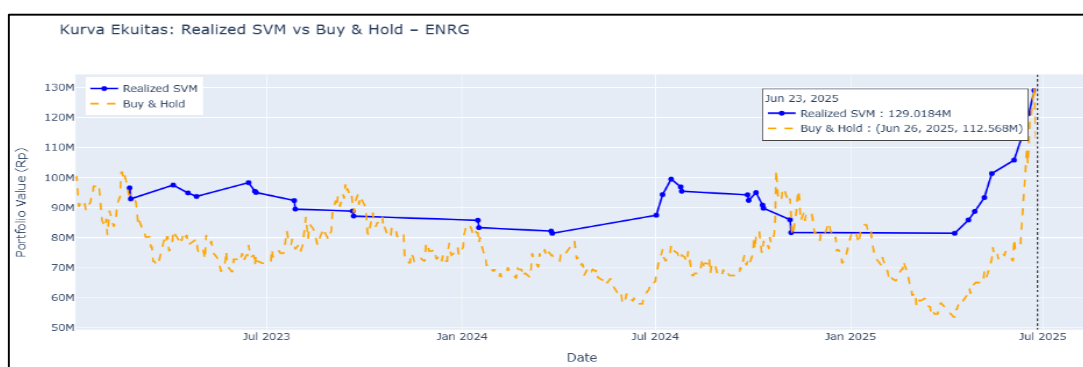
Secara umum, hasil penelitian menunjukkan bahwa tujuan utama penelitian, yaitu mengembangkan strategi trading berbasis *Support Vector Machine* (SVM) yang mampu menghasilkan sinyal transaksi objektif sekaligus mengelola risiko pada saham sektor energi Indonesia, telah tercapai sebagian. Meskipun performa klasifikasi model berada pada kategori moderat dengan nilai F1-score berkisar antara 35,83% hingga 47,86%, implementasi sinyal tersebut dalam strategi perdagangan menunjukkan bahwa 71,4% emiten menghasilkan *return* positif dan rata-rata maximum *drawdown* berhasil ditekan secara signifikan dibandingkan strategi *buy and hold*. Hal ini mengindikasikan bahwa keberhasilan strategi tidak semata-mata ditentukan oleh tingkat akurasi klasifikasi, melainkan oleh kemampuan model dalam menghindari fase penurunan ekstrem dan menghasilkan keputusan yang lebih defensif, sejalan dengan tujuan pengelolaan risiko pada sektor yang bervolatilitas tinggi.

Jika dibandingkan dengan penelitian terdahulu, hasil penelitian ini setara hingga lebih baik dari sisi manajemen risiko, namun relatif lebih rendah dari sisi akurasi prediksi. Beberapa studi sebelumnya melaporkan akurasi di atas 80% hingga 90% pada dataset tertentu, tetapi umumnya tidak melakukan evaluasi berbasis *backtesting* atau hanya menggunakan satu hingga dua indikator teknikal. Penelitian ini justru menunjukkan bahwa meskipun akurasi lebih rendah, strategi SVM mampu menciptakan kinerja investasi yang lebih stabil dengan reduksi *drawdown* rata-rata sebesar 76,1%, yang jarang dilaporkan secara eksplisit pada studi-studi sebelumnya. Perbedaan ini dapat dijelaskan oleh karakteristik saham sektor energi yang memiliki non-linearitas tinggi, noise yang kuat, serta distribusi kelas yang tidak seimbang, sehingga membatasi kemampuan model dalam menghasilkan sinyal BUY dan SELL secara agresif.

Keberhasilan strategi SVM pada beberapa emiten, seperti RAJA dan BUMI, dapat dikaitkan dengan kecocokan pola harga saham terhadap kombinasi indikator teknikal dan kernel yang digunakan, serta relatif stabilnya regime pasar selama periode pengujian. Sebaliknya, kegagalan pada emiten tertentu, seperti PTRO dan PTBA, menunjukkan bahwa model kurang adaptif terhadap fase bull market ekstrem, di mana strategi *buy and hold* justru lebih unggul.

Selain itu, penerapan triple-class labeling berbasis ATR cenderung menghasilkan sinyal yang konservatif, sehingga membatasi frekuensi transaksi dan potensi akumulasi return ketika harga bergerak naik secara tajam. Dari sisi metodologis, keterbatasan utama penelitian ini terletak pada penggunaan data historis tunggal (*Yahoo Finance*), keterbatasan eksplorasi fitur non-teknikal seperti faktor fundamental atau sentimen pasar, serta penggunaan SVM sebagai model statis yang belum sepenuhnya adaptif terhadap perubahan regime pasar.

Implikasi dari temuan ini menunjukkan bahwa strategi trading berbasis SVM lebih sesuai diterapkan oleh investor dengan toleransi risiko rendah hingga menengah, yang mengutamakan stabilitas portofolio dibandingkan maksimalisasi return jangka pendek. Bagi industri dan pengembang sistem perdagangan, hasil penelitian ini menegaskan pentingnya evaluasi berbasis kinerja riil (*return-risk trade-off*), bukan hanya akurasi prediksi, serta perlunya pengembangan sistem trading yang adaptif dan kontekstual terhadap karakteristik sektor.



Gambar 9. Perbandingan Return SVM vs Buy and Hold pada saham ENRG



Gambar 10. Perbandingan Return SVM vs Buy and Hold pada saham AKRA

IV. SIMPULAN

Berdasarkan hasil penelitian, strategi trading berbasis Support Vector Machine (SVM) pada saham sektor energi terbukti efektif sebagai alat bantu pengambilan keputusan beli-jual. Dari 14 emiten yang diuji, sebanyak 10 emiten (71,4%) menghasilkan return positif dengan rata-rata imbal hasil 26,85% dan nilai Sharpe ratio 0,73. Keunggulan utama strategi ini terletak pada kemampuannya dalam mengelola risiko, tercermin dari rata-rata *maximum drawdown* hanya -10,64%, jauh lebih rendah dibandingkan strategi buy and hold yang mencatat -48,91%, sehingga memberikan reduksi risiko sebesar 76,10%. Emiten RAJA menunjukkan kinerja paling menonjol dengan return 158,97% dan Sharpe ratio 1,48, mengindikasikan bahwa model SVM mampu bekerja optimal pada kondisi pasar yang selaras dengan pola sinyal yang dihasilkan model. Namun demikian, nilai F1-score yang berada pada kisaran moderat (35,83%–47,86%) serta fenomena PGAS (win rate tinggi 84,62% tetapi return kurang optimal) menunjukkan bahwa model cenderung menghasilkan sinyal konservatif dan kurang responsif terhadap fase pasar dengan momentum bullish ekstrem. Temuan ini menegaskan perlunya optimasi parameter yang lebih spesifik per emiten serta penerapan manajemen risiko tambahan, termasuk stop loss yang lebih disiplin, untuk meningkatkan efektivitas strategi SVM pada kondisi pasar yang dinamis dan bergejolak. Penelitian selanjutnya dapat difokuskan pada pengembangan model yang lebih adaptif melalui optimasi hyperparameter berbasis rolling window, integrasi algoritma mesin pembelajaran lain seperti ensemble learning atau deep learning, serta perluasan dataset dengan memasukkan variabel fundamental, makroekonomi, maupun sentimen pasar guna meningkatkan responsivitas model terhadap perubahan regime pasar dan fase bullish ekstrem.

UCAPAN TERIMAKASIH

Terima kasih kami sampaikan kepada Fakultas Teknologi Informasi, Universitas Kristen Duta Wacana yang telah membantu dalam memfasilitasi penelitian ini.

DAFTAR PUSTAKA

- [1] D. Hakim and Y. Sudaryo, *Manajemen Investasi dan Teori Portofolio*. Yogyakarta: Penerbit Andi, 2022.
- [2] K. Liagkouras and K. Metaxiotis, "Stock Market Forecasting by Using Support Vector Machines," Cham: Springer International Publishing, 2020, pp. 259–271. doi: 10.1007/978-3-030-49724-8_11.
- [3] A. Mahmoodi, L. Hashemi, M. Jasemi, S. Mehraban, J. Laliberté, and R. C. Millar, "A developed stock price forecasting model using support vector machine combined with metaheuristic algorithms," *OPSEARCH*, vol. 60, no. 1, pp. 59–86, Mar. 2023, doi: 10.1007/s12597-022-00608-x.
- [4] Anggita Wigianti, Made Irma Lestari, and Hidayatullah, "The Impact of Oil-Gas and Agriculture Exports on Energy and Consumer Non-Cyclical Sector Stock Prices in Indonesia: A Case Study of the Russia-Ukraine War," *International Journal of Business, Humanities, Education and Social Sciences (IJBHES)*, vol. 7, no. 1, pp. 81–91, Jun. 2025, doi: 10.46923/ijbhes.v7i1.472.
- [5] E. Endri, M. Rinaldi, D. A. Ian, B. Saing, and A. Aminudin, "Oil price and stock return: Evidence of mining companies in Indonesia," *International Journal of Energy Economics and Policy*, vol. 11, no. 2, pp. 110–114, 2021, doi: 10.32479/ijeep.10608.
- [6] F. Adhani and R. Nurazi, "Effects of Energy Price Fluctuations on Stock Return of Energy Companies in Indonesia: The Effect of Macroeconomic Variables and Subsidy Policy," *JASa (Jurnal Akuntansi, Audit dan Sistem Informasi Akuntansi)*, vol. 9, no. 2, pp. 436–447, Aug. 2025, doi: 10.36555/jasa.v9i2.2904.
- [7] T. Kusmini and B. Wibowo, "Analysis of The Volatility and Asymmetric Stocks Information in The Energy Sector on The Indonesia Stock Exchange 2021-2024," *Eduvest - Journal of Universal Studies*, vol. 5, no. 10, pp. 12805–12818, Oct. 2025, doi: 10.59188/eduvest.v5i10.51300.
- [8] M. A. Pratama and K. Kamaludin, "Analysis Of The Use Of Technical Indicators And Trendlines In Maximizing Stock Investment Profits In The Capital Market Indonesia," *The Manager Review*, vol. 7, no. 1, pp. 23–30, Mar. 2025, doi: 10.33369/tmr.v7i1.41291.
- [9] M. S. Hasibuan and A. Serdano, "Analisis Sentimen Kebijakan Pembelajaran Tatap Muka Menggunakan Support Vector Machine dan Naive Bayes," *JRST (Jurnal Riset Sains dan Teknologi)*, vol. 6, no. 2, p. 199, Nov. 2022, doi: 10.30595/jrst.v6i2.15145.
- [10] D. A. Chalid and V. R. Cokrodiharjo, "Peramalan Harga Saham Menggunakan Metode Support Vector Machine (SVM)," *Jurnal Pasar Modal dan Bisnis*, vol. 3, no. 1, pp. 61–74, Feb. 2021, doi: 10.37194/jpmb.v3i1.59.
- [11] I. M. A. I. Agusta, A. Barakbah, and A. Fariza, "Technical Analysis Based Automatic Trading Prediction System for Stock Exchange using Support Vector Machine," *EMITTER International Journal of Engineering Technology*, pp. 279–293, Dec. 2022, doi: 10.24003/emitter.v10i2.740.
- [12] D. E. Waluyo, H. W. Kinasih, C. Paramita, D. Pergiwati, R. Nohan, and F. A. Rafrastara, "Komparasi dan Implementasi Algoritma Regresi Machine Learning untuk Prediksi Indeks Harga Saham Gabungan," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 9, no. 1, pp. 12–17, Feb. 2024, doi: 10.30591/jpit.v9i1.6105.
- [13] R. Rosillo, J. Giner, J. Puente, and B. Ponte, "Different Stock Market Models Using Support Vector Machines," *International Journal of Trade, Economics and Finance*, pp. 310–313, 2013, doi: 10.7763/IJTEF.2013.V4.307.
- [14] I. M. A. I. Agusta, A. Barakbah, and A. Fariza, "Technical Analysis Based Automatic Trading Prediction System for Stock Exchange using Support Vector Machine," *EMITTER International Journal of Engineering Technology*, pp. 279–293, Dec. 2022, doi: 10.24003/emitter.v10i2.740.
- [15] D. A. Daniswara, H. Widjanarko, and K. Hikmah, "THE ACCURACY TEST OF TECHNICAL ANALYSIS OF MOVING AVERAGE, BOLLINGER BANDS, AND RELATIVE STRENGTH INDEX ON STOCK PRICES OF COMPANIES LISTED IN INDEX LQ45," *Indikator: Jurnal Ilmiah Manajemen dan Bisnis*, vol. 6, no. 2, p. 16, Apr. 2022, doi: 10.22441/indikator.v6i2.14806.
- [16] G. SETIADI, O. A. PUTRI, G. ARDILIA, and Z. AZMI, "ANALISIS TEKNIKAL SAHAM MENGGUNAKAN INDIKATOR RSI DAN BOLLINGER BANDS PADA SAHAM BERBASIS KOMODITAS TIMAH DAN NIKEL," *ACCOUNTIA JOURNAL (Accounting Trusted, Inspiring, Authentic Journal)*, vol. 6, no. 01, pp. 47–53, Apr. 2022, doi: 10.35915/accountia.v6i01.611.
- [17] A. A. P. Santos and H. S. Torrent, "Markowitz meets technical analysis: Building optimal portfolios by exploiting information in trend-following signals," *Financ. Res. Lett.*, vol. 49, p. 103063, Oct. 2022, doi: 10.1016/j.frl.2022.103063.
- [18] E. A. Nida, "Analisis Kinerja Algoritma Support Vector Machine (SVM) Guna Pengambilan Keputusan Beli/Jual Pada Saham PT Elnusa Tbk. (ELSA)," *Jurnal Transformatika*, vol. 17, no. 2, pp. 160–170, Jan. 2020, doi: 10.26623/transformatika.v17i2.1649.
- [19] D. R. Irahadi, M. S. Sianturi, and S. S. Kim, "Penggunaan Indikator Analisa Teknikal Pada Pasar Saham Di Indonesia," *JMBI UNSRAT*, vol. 9, no. 2, pp. 808–827, 2022.
- [20] I. S. Muis, M. I. Prajawati, and B. S., "Analisis Teknikal Return Saham dengan Indikator-Indikator Bollinger Band, Parabolic SAR, dan Stochastic Oscillator," *Jurnal Samudra Ekonomi dan Bisnis*, vol. 12, no. 2, pp. 143–153, Jan. 2021, doi: 10.33059/jseb.v12i2.2467.
- [21] B. D. Fadillah and N. Hendrastuty, "Prediksi Stok Barang di Toko Eko Helm Menggunakan Metode Time series Analysis," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 10, no. 2, pp. 278–291, Apr. 2025, doi: 10.30591/jpit.v10i2.8584.
- [22] Stefan. Jansen, *Machine learning for algorithmic trading: predictive models to extract signals from market and alternative data for systematic trading strategies with Python*. Packt Publishing, 2020.
- [23] I. Gurrib, F. Kamalov, O. Starkova, A. Makki, A. Mirchandani, and N. Gupta, "Performance of Equity Investments in Sustainable Environmental Markets," *Sustainability*, vol. 15, no. 9, p. 7453, May 2023, doi: 10.3390/su15097453.
- [24] M. F. Amin, "Confusion Matrix in Binary Classification Problems: A Step-by-Step Tutorial," *Journal of Engineering Research*, vol. 6, no. 5, pp. 0–0, Dec. 2022, doi: 10.21608/erjeng.2022.274526.
- [25] H. Arian, D. Noruzi Mobarekeh, and L. Seco, "Backtest overfitting in the machine learning era: A comparison of out-of-sample testing methods in a synthetic controlled environment," *Knowl. Based. Syst.*, vol. 305, p. 112477, Dec. 2024, doi: 10.1016/j.knosys.2024.112477.
- [26] S. Sun, R. Wang, and B. An, "Reinforcement Learning for Quantitative Trading," *ACM Trans. Intell. Syst. Technol.*, vol. 14, no. 3, pp. 1–29, Jun. 2023, doi: 10.1145/3582560.