

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Penelitian mengenai prediksi harga saham telah banyak dilakukan dengan menggunakan berbagai algoritma *Machine Learning* dan *Deep Learning*. Berikut adalah ringkasan beberapa penelitian relevan yang menjadi acuan dalam penyusunan penelitian ini:

Tabel 2. 1 Jurnal Penelitian Terdahulu

No	Referensi Peneliti	Algoritma	Hasil Akurasi/Metrik	Deskripsi	Keterkaitan/Perbedaan dengan Penelitian Ini
1	[2]	LSTM, SVR	MAE (lebih rendah)	Membandingkan <i>deep learning</i> dengan <i>machine learning</i> pada pasar saham Asia.	Menggunakan perbandingan algoritma yang sama, namun penelitian ini berfokus pada saham tunggal sektoral di Indonesia (TLKM), bukan indeks regional Asia.
2	[3]	Hybrid LSTM-SVR	Akurasi > Stand-alone	Mengembangkan model hibrida untuk fitur temporal saham.	Penelitian ini tidak menggabungkan model menjadi <i>hybrid</i> , melainkan menguji performa LSTM dan SVR secara terpisah (<i>stand-alone</i>) sebagai perbandingan langsung.

3	[4]	LSTM, GRU, SVR	Peningkatan performa LSTM	Menguji pengaruh <i>wavelet-based data preprocessing</i> pada model.	Penelitian ini menggunakan metode <i>preprocessing</i> normalisasi linier standar (<i>Min-Max Scaler</i>) untuk menjaga orisinalitas pola data sebelum dimodelkan.
4	[13]	LSTM, SVR	<i>Training time</i> lebih cepat	Meneliti prediksi indeks saham gabungan berskala besar (<i>Big Data</i>).	Berfokus pada sampel data yang lebih terisolasi dan spesifik (saham TLKM) dibandingkan indeks gabungan bursa yang sangat luas.
5	[14]	LSTM, SVR	<i>Non-linear dependencies</i>	Studi komparatif arsitektur <i>recurrent</i> dan algoritma kernel.	Memiliki tujuan pengujian yang serupa (komparatif), namun diaplikasikan pada dinamika pasar pasca-pandemi dengan batasan waktu terbaru (2021-2025).
6	[15]	Hybrid LSTM-SVR	Prediksi tren lebih akurat	Mengintegrasikan sentimen berita via SVR dengan data historis LSTM.	Penelitian ini membatasi input hanya pada data kuantitatif (<i>Close Price</i>) tanpa melibatkan data tidak terstruktur seperti analisis sentimen teks.

7	[16]	Bi-LSTM, SVR	RMSE (lebih rendah)	Memfaatkan <i>Bidirectional</i> LSTM untuk melihat pola simultan.	Penelitian ini menggunakan arsitektur LSTM konvensional (<i>unidirectional</i>) yang memproses data murni dari masa lalu ke masa depan.
8	[17]	LSTM, SVR	<i>Robust</i> terhadap <i>shock</i>	Prediksi selama krisis dengan tingkat <i>resilience</i> tinggi.	Evaluasi dilakukan pada fase pemulihan (<i>recovery</i>) pasar modal dan stabilitas operasional emiten teknologi, bukan hanya pada fase krisis.
9	[18]	LSTM, SVR	<i>Timeframe</i> pendek (SVR)	Evaluasi <i>high-frequency trading data</i> dan <i>trendline</i> .	Penelitian ini tidak menggunakan data berfrekuensi tinggi (menit/detik), melainkan pergerakan harga pada <i>timeframe</i> harian (<i>daily stock price</i>).
10	[19]	Optimized LSTM, SVR	Optimasi <i>Hyperparameter</i>	Optimasi meta-heuristik untuk peramalan harga sektoral.	Penelitian ini membandingkan kinerja model berdasarkan arsitektur dasar dengan <i>hyperparameter</i> standar tanpa algoritma optimasi meta-heuristik tambahan.

Berdasarkan Tabel 2.1 mengenai penelitian terdahulu, sebagian besar literatur telah membuktikan bahwa algoritma *Long Short-Term Memory* (LSTM) dan *Support Vector Regression* (SVR), maupun kombinasinya, merupakan metode yang sangat efektif untuk memprediksi data deret waktu (*time-series*) keuangan. Penelitian oleh [5] dan [6] menunjukkan keunggulan LSTM dalam mempelajari pola saham yang kompleks dan ketergantungan temporal jangka panjang. Di sisi lain, penelitian oleh

[7] dan [8] membuktikan ketangguhan SVR, khususnya dengan penggunaan fungsi kernel RBF, dalam memberikan tingkat akurasi dan stabilitas yang tinggi pada data finansial. Mengacu pada temuan tersebut, penelitian ini mengadopsi LSTM sebagai model utama dan SVR berbasis kernel RBF sebagai model *machine learning* pembandingan. Kinerja kedua model tersebut kemudian akan diukur menggunakan metrik MAE dan RMSE, yang telah diakui secara luas dalam evaluasi prediksi finansial.

Pembeda utama (*gap analysis*) dari penelitian ini terletak pada fokus objek, rentang data, dan skema evaluasi yang dirancang lebih terarah. Penelitian ini secara khusus mengonfrontasikan performa kedua algoritma tersebut secara langsung pada saham sektor telekomunikasi, yaitu PT Telkom Indonesia Tbk (TLKM). Pengujian ini memanfaatkan data historis harian dari awal tahun 2021 hingga tahun 2026 guna menguji konsistensi model dalam merespons dinamika dan volatilitas pasar pasca-pandemi. Melalui penerapan pembagian data secara sekuensial dan skema evaluasi yang identik bagi kedua algoritma, penelitian ini bertujuan untuk menyajikan perbandingan performa yang jauh lebih terkontrol dan objektif antara LSTM dan SVR di pasar modal Indonesia.

2.2 Definisi dan Konsep Dasar Saham

Menurut Undang-Undang Republik Indonesia Nomor 8 Tahun 1995 tentang Pasar Modal, pasar modal didefinisikan sebagai suatu kegiatan yang bersangkutan dengan penawaran umum dan perdagangan efek, perusahaan publik yang berkaitan dengan efek yang diterbitkannya, serta lembaga dan profesi yang berkaitan dengan efek[11].

Secara konseptual, pasar modal bertindak sebagai lembaga perantara (*financial intermediary*) yang menghubungkan dua pihak dengan kepentingan yang saling melengkapi, yaitu:

1. Pihak yang Kelebihan Dana (*Surplus Unit / Investors*): Individu atau institusi yang ingin mengalokasikan modal mereka untuk mendapatkan imbal hasil (*return*) di masa depan.

2. Pihak yang Membutuhkan Dana (*Deficit Unit / Issuers*): Perusahaan atau badan hukum yang memerlukan suntikan modal jangka panjang untuk melakukan ekspansi bisnis, membayar utang, atau mendanai operasional platform.

Melalui pasar modal, perusahaan dapat memperoleh pendanaan tanpa harus bergantung sepenuhnya pada pinjaman perbankan yang memiliki beban bunga tetap (*interest-bearing debt*).

2.2.1 Pengertian Saham (Stock)

Dalam perkembangannya, saham yang diperdagangkan di bursa efek dapat diklasifikasikan menjadi beberapa jenis berdasarkan hak klaimnya, seperti saham biasa (*common stock*) dan saham preferen (*preferred stock*). Saham biasa merupakan jenis yang paling banyak dimiliki oleh publik karena menawarkan potensi keuntungan yang linear dengan pertumbuhan perusahaan, meskipun memiliki prioritas paling akhir jika terjadi likuidasi [12].

Selain sebagai instrumen pencarian modal bagi emiten, nilai saham di pasar sekunder juga sering kali dijadikan indikator performa ekonomi makro secara real-time. Perubahan harga saham secara agregat merefleksikan ekspektasi kolektif para investor terhadap profitabilitas perusahaan di masa mendatang, yang kemudian membentuk tren harga komparatif yang kompleks dan fluktuatif [13].

Kebutuhan akan Prediksi Saham yang Akurat dalam Konteks Pasar Modal Indonesia

Di pasar modal Indonesia, prediksi saham yang akurat sangat penting untuk memberikan kepercayaan dan kestabilan bagi para investor, baik domestik maupun internasional. Sebagai pasar yang sedang berkembang, Indonesia menghadapi volatilitas yang cukup tinggi, sehingga investor memerlukan alat yang dapat membantu mereka mengurangi risiko dan memaksimalkan potensi keuntungan. Selain itu, akurasi dalam prediksi juga mendukung efisiensi pasar dan memperkuat kepercayaan investor dalam berinvestasi di saham-saham lokal.

2.2.2 Peran Machine Learning dalam Prediksi Saham

Dalam era digitalisasi finansial saat ini, teknologi *machine learning* memegang peranan yang semakin krusial dan transformatif dalam ranah prediksi harga saham. Hal ini didasari oleh kemampuan superior algoritma kecerdasan buatan tersebut dalam mengidentifikasi, mengekstrak, dan mempelajari pola-pola tersembunyi yang bersifat non-linear dari sekumpulan data berskala besar (*big data*) serta memiliki kompleksitas tinggi. Pasar modal pada hakikatnya merupakan sebuah sistem dinamis yang sangat sensitif dan dipengaruhi oleh banyak faktor eksternal tak terduga, sehingga pendekatan statistik konvensional sering kali gagal dalam menangkap anomali pasar secara tepat.

Guna mengatasi keterbatasan tersebut, pemanfaatan algoritma mutakhir seperti *Long Short-Term Memory* (LSTM), *Support Vector Regression* (SVR) atau *Support Vector Regression* (SVR), hingga *K-Nearest Neighbors* (K-NN) menjadi solusi metodologis yang sangat efektif. Algoritma-algoritma ini memiliki kapabilitas tinggi untuk memproses secara simultan berbagai jenis data historis terstruktur seperti fluktuasi harga saham (*open, high, low, close*), , hingga data tidak terstruktur seperti analisis sentimen berita ekonomi dan media sosial demi menghasilkan output proyeksi dengan tingkat akurasi yang jauh lebih presisi.

Kelebihan utama dari implementasi *machine learning* dibandingkan dengan model matematika statis terletak pada aspek fleksibilitas dan kemampuan adaptasinya yang adaptif. Sistem *machine learning* dirancang untuk dapat memperbarui parameter internal dan bobot komputasinya secara mandiri (*self-updating*) seiring dengan masuknya data deret waktu (*time series*) yang paling baru. Kemampuan pembelajaran berkelanjutan (*continuous learning*) ini membuat model prediktif tetap relevan dan tangguh dalam merespons pergeseran tren pasar yang volatil, meminimalkan risiko *error* akibat perubahan struktural ekonomi, serta memberikan pemetaan risiko yang lebih terukur. Pada akhirnya, integrasi teknologi ini menjadi instrumen analitis yang sangat kuat bagi para investor, manajer investasi, dan pelaku pasar modal dalam mengambil keputusan strategis, mengeksekusi momentum perdagangan

secara objektif, serta menyusun portofolio investasi berdasarkan hasil analisis prediktif yang jauh lebih komprehensif dan berbasis data (*data-driven*).

2.3 Algoritma Long Short-Term Memory (LSTM)

2.3.1 Konsep Dasar LSTM

- **Arsitektur Jaringan Saraf LSTM**

LSTM adalah jenis jaringan saraf tiruan yang dirancang untuk mengatasi masalah dalam memproses data berurutan, terutama pada data *time series*. LSTM memiliki struktur yang unik dengan sel-sel memori yang memungkinkan jaringan untuk menyimpan, melupakan, atau mengingat informasi sesuai kebutuhan. [14]

- **Mekanisme Kerja LSTM**

LSTM bekerja melalui tiga jenis "gate" utama:

- **Input Gate:** Mengontrol informasi baru yang masuk ke sel memori.

$$it = \sigma(Wi \cdot [ht - 1, xt] + bi)$$

$$C \sim t = \tanh(WC \cdot [ht - 1, xt] + bC)$$

$$Ct = ft \odot Ct - 1 + it \odot C \sim t$$

- **Forget Gate:** Memutuskan informasi mana yang perlu dilupakan dari sel memori.

$$ft = \sigma(Wf \cdot [ht - 1, xt] + bf)$$

- **Output Gate:** Menentukan informasi yang harus dikeluarkan dari sel memori dan diteruskan ke lapisan berikutnya. Kombinasi dari ketiga gate ini memungkinkan LSTM untuk mempertahankan informasi penting dari titik waktu sebelumnya, yang berguna dalam menangani data berurutan.

$$ot = \sigma(Wo \cdot [ht - 1, xt] + bo)$$

$$ht = ot \odot \tanh(Ct)$$

- Keunggulan LSTM dalam Data Berurutan dan *Time Series*

LSTM unggul dalam memproses data yang bergantung pada urutan waktu karena kemampuan memorinya untuk "mengingat" informasi dalam jangka panjang. Hal ini menjadikannya sangat cocok untuk aplikasi di mana pola atau tren dalam data historis sangat relevan, seperti harga saham [15].

2.3.2 LSTM dalam Prediksi Saham

- Kemampuan Identifikasi Pola Non-Linear Kompleks: Teknologi *machine learning* memegang peranan yang semakin krusial dan transformatif dalam ranah prediksi harga saham karena kemampuan superior algoritma kecerdasan buatan tersebut dalam mengidentifikasi, mengekstrak, dan mempelajari pola-pola tersembunyi yang bersifat non-linear dari sekumpulan data berskala besar (*big data*) serta memiliki kompleksitas tinggi. [16]
- Solusi Metodologis terhadap Volatilitas Pasar: Pasar modal pada hakikatnya merupakan sebuah sistem dinamis yang sangat sensitif dan dipengaruhi oleh banyak faktor eksternal tak terduga, sehingga pendekatan statistik konvensional sering kali gagal dalam menangkap anomali pasar secara tepat. Guna mengatasi keterbatasan tersebut, pemanfaatan algoritma mutakhir seperti *Long Short-Term Memory* (LSTM), *Support Vector Regression* (SVR/SVR), hingga *K-Nearest Neighbors* (K-NN) menjadi solusi metodologis yang sangat efektif. [17]
- Pemrosesan Data Multimodal secara Simultan: Algoritma-algoritma ini memiliki kapabilitas tinggi untuk memproses secara simultan berbagai jenis data historis terstruktur seperti fluktuasi harga saham (*open, high, low, close*), hingga data tidak terstruktur seperti analisis sentimen berita ekonomi dan media sosial demi menghasilkan output proyeksi dengan tingkat akurasi yang jauh lebih presisi. [18]

- **Fleksibilitas dan Kemampuan Adaptasi Dinamis:** Kelebihan utama dari implementasi *machine learning* dibandingkan dengan model matematika statis terletak pada aspek fleksibilitas dan kemampuan adaptasinya yang dinamis. Sistem *machine learning* dirancang untuk dapat memperbarui parameter internal dan bobot komputasinya secara mandiri (*self-updating*) seiring dengan masuknya data deret waktu (*time series*) yang paling baru [19]
- **Mitigasi Risiko Keuangan dan Pendukung Keputusan:** Kemampuan pembelajaran berkelanjutan (*continuous learning*) ini membuat model prediktif tetap relevan dan tangguh dalam merespons pergeseran tren pasar yang volatil, meminimalkan risiko *error* akibat perubahan struktural ekonomi, serta memberikan pemetaan risiko yang lebih terukur. Pada akhirnya, integrasi teknologi ini menjadi instrumen analitis yang sangat kuat [20].

2.3.3 Kelebihan dan Kekurangan LSTM

2.3.3.1 Keunggulan dan Kekuatan Utama LSTM

- **Kapabilitas Retensi Memori Jangka Panjang:** Keunggulan paling fundamental dari LSTM adalah kemampuannya yang luar biasa dalam menangkap dan mempertahankan pola ketergantungan jangka panjang (*long-term dependencies*) di dalam data yang bersifat sekuensial. Karakternya yang adaptif membuat LSTM menjadi pilihan ideal untuk mengolah data deret waktu (*time series*) yang kompleks seperti fluktuasi harga saham [21].
- **Ekstraksi Pola Tersembunyi via Memori Internal:** Melalui mekanisme arsitektur *cell state* dan struktur gerbangnya (*gates*), LSTM memiliki struktur memori internal yang mampu mengenali tren makro, siklus musiman, maupun anomali pasar yang sering kali terlewat oleh algoritma statistik tradisional (seperti ARIMA) atau model regresi linier sederhana [22].
- **Solusi Terhadap Masalah Gradient Jaringan Saraf:** Secara arsitektural, penggunaan *forget gate* pada LSTM bertindak sebagai solusi matematis

yang sangat efektif untuk mengatasi fenomena *vanishing gradient* atau *exploding gradient* yang sering melanda model *Recurrent Neural Network* (RNN) biasa ketika memproses sekuensial data yang terlalu panjang [23].

2.3.3.2 Kendala dan Keterbatasan Umum pada LSTM

- Kompleksitas Arsitektur dan Beban Komputasi Tinggi: Meskipun sangat efektif untuk prediksi jangka panjang, algoritma ini memiliki kelemahan dari sisi struktur model yang sangat kompleks karena melibatkan banyak parameter dan perhitungan matriks di setiap *gate*. Kompleksitas ini secara otomatis menuntut waktu komputasi (*training time*) yang jauh lebih tinggi serta spesifikasi perangkat keras (*hardware*) yang lebih mumpuni dibandingkan dengan model *machine learning* konvensional [24].
- Ketergantungan yang Tinggi pada Skala Data (*Data Hungry*): Sebagai bagian dari keluarga *deep learning*, LSTM cenderung membutuhkan volume dataset historis dalam skala yang sangat besar guna melakukan proses pembelajaran bobot secara optimal. Jika ukuran sampel data deret waktu yang digunakan terlalu kecil atau terlalu pendek, model jaringan saraf ini tidak akan mampu melakukan generalisasi fitur secara maksimal [25].
- Kerentanan Terhadap Risiko *Overfitting*: Tantangan besar lainnya dalam implementasi LSTM adalah risiko terjadinya *overfitting*, di mana model mempelajari data pelatihan terlalu detail termasuk *noise* atau fluktuasi acak di dalamnya. Fenomena *overfitting* ini dapat menurunkan performa akurasi secara drastis ketika model diuji menggunakan data baru yang belum pernah dilihat sebelumnya (*unseen data*), sehingga memerlukan teknik regularisasi tambahan seperti pencantuman lapisan *dropout* [26].

2.4 Algoritma Support Vector Regression (SVR)

2.4.1 Konsep Dasar SVR

- Konsep SVR, Hyperplane, dan Margin Maksimal

Support Vector Regression (SVR) adalah algoritma pembelajaran mesin yang populer untuk tugas klasifikasi dan regresi [27]. Dalam SVR, data dipisahkan oleh sebuah garis (atau *hyperplane* dalam dimensi yang lebih tinggi) yang memaksimalkan jarak atau margin antara dua kelas data [28]. Tujuan SVR adalah menemukan *hyperplane* optimal yang memisahkan data dengan margin terbesar, sehingga memungkinkan pemisahan yang lebih jelas dan mengurangi risiko kesalahan [29].

- Kegunaan SVR dalam Klasifikasi dan Regresi

SVR dapat digunakan untuk klasifikasi dengan membagi data menjadi dua kelas atau lebih, serta untuk regresi dengan mengestimasi nilai kontinyu. Dalam konteks prediksi saham, SVR digunakan untuk mengklasifikasikan kondisi pasar (bullish atau bearish) atau untuk memprediksi harga saham berdasarkan variabel yang relevan.

- Persamaan Hyperplane

$$f(x) = w \cdot x + b$$

Fungsi Tujuan (Optimisasi Margin)

$$w, b \text{ min } \frac{1}{2} \|w\|^2$$

Fungsi Optimasi (untuk Margin Maksimum)

Tujuan utama dari SVR adalah menemukan hyperplane pemisah dengan margin terbesar (maximum margin). Secara matematis, proses pencarian margin maksimum ini dirumuskan sebagai masalah optimasi kuadratik konvensional sebagai berikut:

$$\text{Minimalisasi: } \frac{1}{2} \|w\|^2$$

Dengan kendala: $y_i * (w * x_i + b) \geq 1$

Di mana:

- $\|w\|$ = Norm dari vektor bobot w (yang menentukan orientasi dan ketebalan margin hyperplane).
- b = Bias atau pergeseran posisi hyperplane dari titik pusat koordinat.
- y_i = Label kelas untuk titik data ke- i (biasanya bernilai -1 atau +1).

x_i = Vektor fitur input atau representasi untuk titik data ke- i .

Fungsi Kernel (Radial Basis Function - RBF)

Ketika menghadapi sebaran data yang bersifat non-linier (tidak dapat dipisahkan secara lurus pada ruang aslinya), SVR menggunakan kernel trick untuk memetakan data ke dimensi yang lebih tinggi. Salah satu fungsi kernel yang paling populer dan efektif adalah Radial Basis Function (RBF), yang didefinisikan melalui persamaan berikut:

$$K(x, x') = \exp(-\gamma * \|x - x'\|^2)$$

Di mana:

$K(x, x')$ = Fungsi kernel RBF yang mengukur nilai kemiripan atau kedekatan antara dua titik data x dan x' .

$\|x - x'\|^2$ = Jarak kuadrat Euclidean antara dua buah vektor fitur x dan x' .

γ = Parameter kernel yang mengontrol seberapa jauh jangkauan pengaruh dari satu titik sampel tunggal (menentukan kelengkungan batasan keputusan).

2.4.2 SVR dalam Prediksi Saham

- Penerapan SVR untuk Prediksi Saham

SVR sering diterapkan dalam prediksi saham karena kemampuannya dalam menangani data berdimensi tinggi dan mengurangi risiko overfitting, terutama ketika jumlah data terbatas. Algoritma ini bekerja dengan mencari pola dalam data

historis saham, kemudian menerapkan pola tersebut untuk memprediksi harga di masa depan.

- Contoh Studi atau Hasil Penelitian yang Menerapkan SVR pada Data

Finansial

Banyak studi menunjukkan bahwa SVR dapat memberikan hasil yang akurat dalam prediksi harga saham, terutama pada dataset yang kecil atau ketika data tidak berurutan (*non-time series*). Beberapa penelitian juga membuktikan bahwa SVR dapat mengklasifikasikan saham berdasarkan kondisi pasar, memungkinkan investor untuk menilai potensi kenaikan atau penurunan harga dalam waktu dekat.

2.4.3 Kelebihan dan Kekurangan SVR

2.4.3.1 Keunggulan SVR dalam Prediksi Saham dengan Data Terbatas

- Efektivitas Tinggi pada Dataset Skala Kecil: Keunggulan utama dari algoritma *Support Vector Regression* (SVR) atau *Support Vector Regression* (SVR) terletak pada efektivitas performanya ketika bekerja pada dataset yang berukuran relatif kecil atau terbatas. Hal ini membuat SVR menjadi pilihan yang sangat andal untuk kasus-kasus analisis finansial di mana data historis yang tersedia cenderung sedikit, memiliki rentang waktu pendek, atau tidak cukup mendetail.
- Optimalisasi Batas Keputusan via Prinsip Margin Maksimal: Ketangguhan SVR pada data terbatas didorong oleh prinsip dasarnya yang berfokus pada minimalisasi risiko struktural (*structural risk minimization*) untuk mencari *hyperplane* dengan margin maksimal. Dengan memaksimalkan jarak pemisah antar pola data, algoritma ini secara otomatis dapat mencegah terjadinya fenomena *overfitting* yang sering kali melanda model jaringan saraf tiruan ketika dipaksa berlatih pada sampel data yang sedikit.
- Kestabilan dan Kemampuan Generalisasi yang Kuat: Melalui bantuan *support vectors* (titik-titik data terluar yang berada paling dekat dengan

hyperplane), SVR mampu membentuk batas keputusan yang stabil. Karakteristik ini memberikan keunggulan berupa kemampuan generalisasi yang sangat baik, sehingga model tetap dapat memberikan prediksi yang akurat meskipun diuji menggunakan data baru di luar data pelatihan.

2.4.3.2 Kendala SVR dalam Menangani Data yang Besar dan Kompleks

- Penurunan Efisiensi Komputasi pada Skala *Big Data*: Kendala utama yang dihadapi oleh SVR adalah skalabilitasnya yang kurang efisien ketika dipaksa untuk menangani dataset berukuran sangat besar (*large-scale data*) atau memiliki tingkat kompleksitas fitur yang tinggi (Smola & Schölkopf, 2004). Karena proses optimasi SVR melibatkan penyelesaian masalah pemrograman kuadratik konvensional, proses pencarian *hyperplane* yang ideal akan membutuhkan waktu eksekusi (*training time*) yang sangat lambat seiring dengan bertambahnya jumlah baris data.
- Penurunan Performa pada Pola Non-Linear yang Sangat Volatil: Dalam konteks analisis dan prediksi pasar saham, harga sering kali merepresentasikan pola non-linear yang sangat bervariasi dan fluktuatif. Ketika dihadapkan pada volatilitas ekstrem ini, fungsi *kernel* pada SVR dapat mengalami kesulitan dalam memetakan ruang fitur secara konsisten, yang pada akhirnya memicu penurunan performa akurasi prediksi.
- Keterbatasan Kritis terhadap Data yang Memiliki Ketergantungan Waktu: Berbeda dengan arsitektur berulang seperti LSTM yang memiliki memori sekuensial, SVR pada dasarnya memperlakukan setiap baris data sebagai entitas yang independen. Ketiadaan mekanisme retensi memori temporal ini membuat SVR kurang optimal jika diterapkan pada studi kasus prediksi saham yang memiliki ketergantungan waktu (*temporal dependencies*) yang sangat signifikan atau membutuhkan analisis kontekstual jangka panjang.