

Analisis Algoritma LSTM dan SVR untuk Memprediksi Saham Perbankan di Pasar Indonesia

Dina Agustina ^{✉1}, Devni Prima Sari ²

Universitas Negeri Padang^{1,2} (Matematika, Universitas Negeri Padang, Indonesia)
email: dinagustina@fmipa.unp.ac.id¹, devniprimasari@fmipa.unp.ac.id²

Received 08 September 2024 , Accepted 27 September 2024, Published 30 Sept3mber 2024

Abstrak

Penelitian ini membahas analisis perbandingan algoritma *Long Short-Term Memory* (LSTM) dan *Support Vector Regression* (SVR) untuk memprediksi harga saham dari empat bank di Indonesia: Bank BCA (BBCA.JK), Bank BNI (BBNI.JK), Bank BRI (BBRI.JK), dan Bank Mandiri (BMRI.JK). Studi ini dilakukan karena pentingnya prediksi harga saham yang akurat di pasar saham Indonesia untuk pengambilan keputusan yang lebih baik di sektor perbankan. Metodologi yang digunakan yaitu algoritma LSTM dan SVR pada data saham historis dan mengevaluasi kinerjanya dengan *Root Mean Square Error* (RMSE). Tujuannya dari penelitian ini untuk mengetahui algoritma mana yang memiliki akurasi prediktif yang lebih baik untuk saham perbankan di pasar Indonesia. Hasilnya menunjukkan perbedaan nilai RMSE antara model LSTM dan SVR pada bank-bank yang dipilih. LSTM menghasilkan nilai RMSE sebesar 84.2712, 103.7936, 15.5974, dan 26.8980 untuk masing-masing bank (BCA, BNI, BRI dan Mandiri), sementara SVR menunjukkan nilai RMSE yang lebih rendah, yaitu 4.9627, 5.4234, 5.4234, dan 2.5470 (BCA, BNI, BRI dan Mandiri). Berdasarkan hasil penelitian diperoleh bahwa algoritma SVR lebih baik dibandingkan LSTM dalam memprediksi harga saham perbankan, serta menunjukkan potensi penerapannya di pasar saham Indonesia untuk meningkatkan proses pengambilan keputusan investasi.

Kata Kunci: LSTM, RMSE, SVR, saham perbankan

Abstract

This paper delves into the comparative analysis of Long Short-Term Memory (LSTM) and Support Vector Regression (SVR) algorithms for predicting stock prices of four prominent Indonesian banks: Bank BCA (BBCA.JK), Bank BNI (BBNI.JK), Bank BRI (BBRI.JK), and Bank Mandiri (BMRI.JK). The study is motivated by the increasing importance of accurate stock price prediction in the Indonesian market for informed decision-making in the banking sector. The methodology involves training LSTM and SVR algorithm using historical market data and evaluating their predictive performance based on Root Mean Square Error (RMSE) metrics. The objective is to determine which algorithm offers superior predictive accuracy for banking stocks in the Indonesian market. Results reveal notable differences in RMSE values between LSTM and SVR models across the selected banks. LSTM yields RMSE values of 84.2712, 103.7936, 15.5974, and 26.8980 for the respective banks ((BCA, BNI, BRI dan Mandiri), while SVR demonstrates lower RMSE values of 4.9627, 5.4234, 5.4234, and 2.5470 (BCA, BNI, BRI dan Mandiri). These findings underscore the effectiveness of SVR over LSTM in predicting banking

stock prices, highlighting its potential applicability in the Indonesian market for enhancing investment decision-making processes.

Keywords: LSTM, RMSE, SVR, Banking Stocks

✉ Corresponding author

PENDAHULUAN

Pasar modal Indonesia telah mengalami pertumbuhan yang signifikan dalam beberapa tahun terakhir. Seiring dengan perkembangan ekonomi negara dan peningkatan jumlah investor, kebutuhan akan analisis yang akurat dan prediksi yang tepat untuk saham perbankan menjadi semakin penting. Saham perbankan merupakan salah satu sektor yang paling diminati oleh investor di Indonesia, mengingat peran strategis industri perbankan dalam mendukung pertumbuhan ekonomi nasional.

Prediksi harga saham yang akurat memiliki dampak signifikan terhadap investor dalam membuat keputusan investasi yang tepat. Dengan memahami pola pergerakan harga saham di masa depan, investor dapat meminimalkan risiko dan memaksimalkan keuntungan[1], [2]. Namun, memprediksi harga saham menghadapi tantangan karena banyaknya faktor yang mempengaruhinya, seperti faktor ekonomi, politik, dan sentimen pasar. Faktor-faktor ini dapat membuat pergerakan harga saham bersifat non-linear dan sulit diprediksi menggunakan metode konvensional[3].

Salah satu pendekatan yang sering digunakan dalam prediksi harga saham adalah analisis teknikal. Analisis teknikal adalah metode untuk memprediksi pergerakan harga saham di masa depan berdasarkan data historis harga[4]. Metode ini berasumsi bahwa pola pergerakan harga di masa lalu dapat memberikan indikasi pergerakan harga di masa depan. Meskipun analisis teknikal telah banyak digunakan, akurasi prediksinya masih terbatas dan seringkali tidak konsisten[4]. Hal ini disebabkan oleh sifat kompleks data harga saham yang dipengaruhi oleh banyak faktor yang sulit dimodelkan menggunakan metode analisis teknikal tradisional.

Dalam upaya meningkatkan akurasi prediksi harga saham, beberapa penelitian telah mengeksplorasi penggunaan algoritma *machine learning* dan *deep learning*[5], [6], [7]. Algoritma ini memiliki kemampuan untuk mengekstraksi pola tersembunyi dan hubungan dari data historis yang kompleks, sehingga dapat memberikan prediksi yang lebih akurat [8], [9], [10], [11], [12]. Salah satu keunggulan utama dari *algoritma machine learning* dan *deep learning* adalah kemampuannya untuk menangani data non-linear dan mengenali pola data jangka panjang [8], [9], [10], [11], [12].

Salah satu algoritma *deep learning* yang banyak digunakan untuk prediksi harga saham adalah *Long Short-Term Memory* (LSTM) [13], [14], [15]. LSTM adalah jenis jaringan saraf tiruan khusus yang dirancang untuk menangani data berurutan seperti data harga saham historis[16], [17]. Dengan kemampuannya mengenali pola data jangka panjang, LSTM telah menunjukkan kinerja yang baik dalam memprediksi harga saham di berbagai pasar modal[14], [18]. Keunggulan lain dari LSTM adalah kemampuannya mengatasi masalah *vanishing gradient* (masalah dalam pelatihan jaringan saraf (neural network) di mana gradien yang dihitung selama proses

backpropagation menjadi sangat kecil (mendekati nol)) yang sering terjadi pada jaringan saraf tiruan biasa, sehingga memungkinkan pelatihan jaringan yang lebih efisien [16].

Di sisi lain, *Support Vector Regression* (SVR) adalah *algoritma machine learning* yang populer digunakan untuk masalah regresi, termasuk prediksi harga saham [14]. SVR bekerja dengan mencari *hyperplane* terbaik yang memisahkan data menjadi dua kelas, dengan tujuan memaksimalkan margin antara *hyperplane* dan data terdekat dari masing-masing kelas [13]. Algoritma ini terbukti efektif dalam menangani data non-linear dan telah berhasil diterapkan di berbagai permasalahan, termasuk prediksi harga saham. Salah satu keunggulan utama SVR adalah kemampuannya menangani *overfitting*, yang merupakan masalah umum dalam pemodelan regresi [13].

Meskipun LSTM dan SVR telah banyak digunakan dalam memprediksi harga saham di berbagai pasar modal, penelitian yang secara khusus menganalisis kinerja kedua algoritma ini dalam memprediksi saham perbankan di pasar modal Indonesia masih terbatas. LSTM dan SVR merupakan algoritma yang diterapkan dalam *machine learning*. Oleh karena itu, diperlukan analisis yang lebih mendalam untuk mengevaluasi sejauh mana LSTM dan SVR dapat beradaptasi dengan karakteristik pasar modal Indonesia, terutama dalam memprediksi saham perbankan.


Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja LSTM dan SVR dalam memprediksi harga saham perbankan di pasar modal Indonesia. Dengan menggunakan data historis harga saham perbankan, penelitian ini akan mengevaluasi kemampuan kedua algoritma untuk menangkap pola dan tren dalam data, serta mengukur akurasi prediksi yang dihasilkan. Faktor-faktor seperti ukuran data pelatihan, parameter optimasi, dan teknik pra-pemrosesan data akan dipertimbangkan untuk memastikan kinerja terbaik dari masing-masing algoritma.

Model LSTM dan SVR akan dilatih dan diuji menggunakan rasio data 7:3, dan kinerja prediksi mereka akan dinilai menggunakan metrik evaluasi seperti *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Analisis komprehensif akan dilakukan untuk membandingkan efektivitas relatif LSTM dan SVR dalam memprediksi harga saham perbankan.

Dengan membandingkan kinerja algoritma LSTM dan SVR, penelitian ini bertujuan untuk memberikan wawasan berharga tentang efektivitas alat analitik prediktif dalam menghadapi kompleksitas pasar keuangan. Pada akhirnya, temuan penelitian ini dapat memberikan informasi dan memberdayakan pemangku kepentingan untuk membuat keputusan investasi yang lebih efektif di sektor perbankan Indonesia.

METODOLOGI

Penelitian ini menggunakan pendekatan prediktif untuk menganalisis harga saham perbankan di pasar Indonesia dengan algoritma LSTM dan SVR. Proses metodologi digambarkan dalam flowchart berikut.




Gambar 1. Flowchart Penelitian

Untuk memahami proses flowchart, berikut ini diberikan penjelasan terkait teori yang digunakan.

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis *recurrent neural network* (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* pada RNN tradisional, sehingga efektif dalam mempelajari dependensi jangka panjang dalam data berurutan[14]. LSTM terdiri dari sel memori dan mekanisme pengaturan yang mengontrol aliran informasi melalui jaringan.

Jaringan LSTM unggul dalam menangani masalah data *time series* seperti klasifikasi, pemrosesan, dan prediksi dengan efektif menangkap dependensi temporal antara peristiwa dengan durasi yang bervariasi. Setiap unit LSTM mencakup sebuah sel dan tiga *gate*—input, output, dan forget—yang mengoordinasikan aliran masuk dan keluar informasi dalam sel, memfasilitasi retensi nilai-nilai sepanjang berbagai rentang waktu[3], [13], [14], seperti yang diilustrasikan pada Gambar 1.



Gambar 2. Struktur LSTM

Langkah-langkah yang terlibat dalam pemrosesan LSTM meliputi:

1. *Input Gate*: Menentukan informasi mana dari input saat ini yang harus disimpan dalam sel memori.

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (1)$$
2. *Forget Gate*: Memutuskan informasi mana dari status sel sebelumnya yang harus dihapus.

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$
3. *Update Gate*: Menggabungkan informasi dari gerbang input dan gerbang lupa untuk memperbarui status sel memori

$$g_t = \tanh(W_g x_t + U_g h_{t-1} + b_g) \quad (3)$$
4. *Output Gate*: Menentukan informasi mana dari status sel saat ini yang harus dikeluarkan ke lapisan berikutnya.

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b) \quad (4)$$

Mekanisme pengaturan ini memungkinkan jaringan LSTM untuk mempertahankan dan memanfaatkan informasi dalam jangka waktu yang panjang, sehingga mampu menangkap pola dan dependensi temporal dalam data secara efektif. Hal ini menjadikan LSTM cocok untuk berbagai tugas seperti prediksi deret waktu, pengenalan suara, dan pemrosesan bahasa alami.

Support Vector Regression (SVR)

Support Vector Regression (SVR) adalah teknik machine learning yang berasal dari Support Vector Machines (SVM) yang terutama digunakan untuk tugas regresi. Berbeda dengan metode regresi tradisional yang bertujuan untuk meminimalkan kesalahan prediksi, SVR bertujuan untuk menyesuaikan sebanyak mungkin titik data di dalam margin yang ditentukan sambil meminimalkan pelanggaran margin. Konsep inti dari SVR berputar pada pencarian *hyperplane* yang paling baik menangkap tren dalam data[3]. *Hyperplane* ini ditentukan oleh subset dari titik data pelatihan, yang disebut sebagai *support vectors*, yang terletak paling dekat dengan *hyperplane* [13].

Formulasi matematis dari SVR dapat dijelaskan sebagai berikut:

1. Fungsi Regresi Linear

$$f(x) = w^T x + b \quad (5)$$
2. Memaksimalkan Margin

Untuk nilai epsilon (ϵ) yang diberikan, untuk menentukan fungsi $f(x)$ yang memiliki deviasi maksimum ϵ dari target y_i untuk semua *training data* (x_i, y_i) , dengan $i = 1, 2, \dots, n$. Memaksimalkan margin dapat dirumuskan sebagai masalah optimasi berikut:

Meminimalkan: $\frac{1}{2} \|w\|^2$

(6)

Kendala: $|y_i - f(x_i)| \leq \varepsilon, \forall i$.

3. Variabel Slack (ξ, ξ^*)

Untuk menangani data yang tidak memenuhi kondisi margin ε , diperkenalkan variabel slack ξ dan ξ^* yang mewakili deviasi atas dan bawah dari margin. Formulasi optimasi menjadi:

$$\text{Meminimalkan: } \frac{1}{2} \|w\|^2 + C^* \sum (\xi_i + \xi_i^*) \quad (7)$$

Dengan $i = 1, 2, \dots, n$

Kendala:

$$y_i - w^T x_i - b \leq \varepsilon + \xi_i, w^T x_i + b - y_i \leq \varepsilon + \xi_i^*, \xi_i, \xi_i^* \geq 0$$

4. Formulasi Dual

Dengan menggunakan pengali Lagrange dan kondisi Karush-Kuhn-Tucker, masalah optimisasi dapat diubah menjadi formulasi dual:

Maksimalkan:

$$-\frac{1}{2} \sum \sum (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_i, x_j) - \varepsilon \sum (\alpha_i + \alpha_i^*) + \sum y_i (\alpha_i - \alpha_i^*)$$

Kendala: $\sum (\alpha_i - \alpha_i^*) = 0$, dan $0 \leq \alpha_i, \alpha_i^* \leq C$

Dengan $K(x_i, x_j)$ adalah fungsi kernel yang digunakan untuk mentransformasikan data ke ruang fitur yang lebih tinggi.

5. Fungsi Prediksi SVR

$$f(x) = \sum (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (8)$$

Root Mean Square Error (RMSE)

RMSE adalah metrik yang banyak digunakan dalam analisis statistik dan *machine learning* untuk mengevaluasi akurasi ramalan atau estimasi model prediktif. RMSE mengukur besarnya rata-rata kesalahan antara nilai yang diprediksi dan nilai yang diamati dalam sebuah dataset. RMSE memberikan penilaian komprehensif terhadap kinerja prediktif model dengan mempertimbangkan baik magnitudo maupun arah kesalahan. Secara matematis, RMSE dihitung dengan mengambil akar kuadrat dari rata-rata kuadrat selisih antara nilai yang diprediksi dan nilai yang diamati. Proses ini melibatkan penjumlahan kesalahan kuadrat, membagi dengan jumlah observasi, dan kemudian mengambil akar kuadrat dari hasil tersebut. Nilai RMSE yang dihasilkan merepresentasikan deviasi tipikal nilai prediksi dari nilai aktual dalam dataset. Nilai RMSE yang lebih rendah menunjukkan akurasi prediktif yang lebih baik, sementara nilai RMSE yang lebih tinggi menunjukkan deviasi yang lebih besar antara nilai yang diprediksi dan nilai yang diamati.

Rumus untuk menghitung RMSE adalah sebagai berikut [19]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

Mean Absolute Percentage Error (MAPE)

MAPE adalah metrik yang umum digunakan dalam peramalan dan pemodelan prediktif untuk mengevaluasi akurasi prediksi dengan mengukur deviasi persentase rata-rata antara nilai yang diprediksi dan nilai yang diamati. MAPE mengungkapkan kesalahan prediksi sebagai persentase dari nilai aktual, sehingga memudahkan interpretasi dan perbandingan antara berbagai dataset dan model. Secara matematis, MAPE dihitung dengan mengambil selisih absolut antara nilai yang diprediksi dan

nilai yang diamati, membaginya dengan nilai yang diamati, dan kemudian menghitung rata-rata persentase ini di seluruh observasi. Nilai MAPE yang dihasilkan merepresentasikan kesalahan persentase rata-rata dari prediksi model relatif terhadap nilai aktual. Nilai MAPE yang lebih rendah menunjukkan akurasi prediktif yang lebih baik, dengan nilai nol mewakili prediksi yang sempurna.

Rumus untuk menghitung MAPE adalah sebagai berikut [20]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (10)$$

Dimana:

n = jumlah observasi

y_i = nilai actual pada periode ke i

$\hat{y}_i$ = nilai prediksi pada periode ke i

Nilai MAPE berkisar antara 0% hingga tak terhingga, dengan nilai yang lebih rendah menunjukkan akurasi prediksi yang lebih baik. Secara umum, nilai MAPE di bawah 10% dianggap sangat baik, sedangkan nilai di atas 20% dianggap kurang akurat.

HASIL DAN PEMBAHASAN

Dataset untuk peramalan harga saham perusahaan perbankan Indonesia, termasuk Bank BCA (BBCA.JK), Bank BNI (BBNI.JK), Bank BRI (BBRI.JK), dan Bank Mandiri (BMRI.JK), diambil dari Yahoo Finance dengan rentang waktu dari 1 Maret 2022 hingga 1 Maret 2024. Keempat bank ini dipilih sebagai subjek penelitian karena efisiensi dan signifikansinya dalam sektor perbankan Indonesia. Dataset ini terdiri dari harga saham penutupan harian untuk setiap bank, memberikan pandangan komprehensif tentang kinerjanya selama periode waktu yang ditentukan.

Untuk analisis peramalan, digunakan dua algoritma LSTM dan SVR. LSTM dipilih karena kemampuannya untuk menangkap dependensi jangka panjang dan pola kompleks yang melekat dalam data berurutan, sehingga cocok untuk memodelkan data deret waktu seperti harga saham. Sementara itu, SVR digunakan karena efektivitasnya dalam menangani hubungan non-linear dalam data dan kemampuannya untuk menggeneralisasi dengan baik pada data yang tidak terlihat. Dengan menerapkan algoritma-algoritma ini pada dataset yang dikumpulkan, studi ini bertujuan untuk mengevaluasi dan membandingkan kinerja mereka dalam memprediksi harga saham bank-bank yang dipilih, sehingga menawarkan wawasan berharga bagi investor dan pemangku kepentingan di pasar perbankan Indonesia.



Gambar 3. Harga 4 Saham Bank Indonesia

Pada Gambar 2, terlihat bahwa harga saham BBKA lebih tinggi dibandingkan dengan ketiga saham lainnya. Keempat saham menunjukkan fluktuasi harga, dengan tren umum yang naik dari tahun 2022 hingga 2024. Meskipun terjadi fluktuasi, terdapat peningkatan konsisten dalam harga saham secara keseluruhan selama periode waktu ini. Hal ini menunjukkan pertumbuhan dan momentum positif di sektor perbankan, yang diwakili oleh keempat saham ini, selama periode analisis. Harga saham BBKA yang lebih tinggi mungkin mencerminkan kinerja atau persepsi pasar yang lebih kuat dibandingkan dengan saham perbankan lainnya

Tabel 1. RMSE dan MAPE dari Model LSTM dan SVR

Nama Saham	RMSE	MAPE	RMSE	MAPE
Bank BCA (BBKA.JK)	84.2712	1.2533	4.9627	1.7011
Bank BNI (BBNI.JK)	103.7936	2.0893	5.4234	2.4901
Bank BRI (BBRI.JK)	15.5974	1.3889	5.4234	2.3994
Bank Mandiri (BMRI.JK)	26.8980	1.4899	2.5470	2.0340

Pada Tabel 1, hasil yang diperoleh menunjukkan kinerja algoritma LSTM dan SVR dalam memprediksi harga saham untuk empat bank di Indonesia: Bank BCA (BBKA.JK), Bank BNI (BBNI.JK), Bank BRI (BBRI.JK), dan Bank Mandiri (BMRI.JK). Nilai *Root Mean Square Error* (RMSE) menunjukkan perbedaan signifikan antara kedua algoritma, dengan LSTM menunjukkan nilai RMSE yang lebih tinggi dibandingkan dengan SVR untuk semua bank. Secara khusus, LSTM menghasilkan nilai RMSE berkisar antara 15.5974 hingga 103.7936, yang menunjukkan kesalahan prediksi yang relatif lebih tinggi, sementara SVR menunjukkan nilai RMSE lebih rendah berkisar antara 2.5470 hingga 5.4234, yang mengindikasikan akurasi prediksi yang lebih baik.


Selain itu, nilai *Mean Absolute Percentage Error* (MAPE) lebih lanjut menekankan kinerja superior SVR dibandingkan dengan LSTM, dengan SVR secara konsisten menunjukkan nilai MAPE yang lebih rendah di semua bank. Temuan ini menegaskan efektivitas SVR dalam memberikan prediksi yang lebih akurat untuk harga saham perbankan di pasar Indonesia dibandingkan dengan LSTM.

Lebih lanjut, perbedaan yang diamati dalam nilai RMSE dan MAPE antara LSTM dan SVR menunjukkan pentingnya memilih pendekatan pemodelan prediktif yang sesuai untuk peramalan harga saham yang akurat. Meskipun LSTM menawarkan keuntungan dalam menangkap dependensi temporal dalam data, kinerjanya dalam konteks ini tampaknya kalah saing dibandingkan dengan SVR, yang secara efektif menangani hubungan non-linear dan meminimalkan kesalahan prediksi. Oleh karena itu, investor dan pemangku kepentingan di sektor perbankan Indonesia mungkin mendapatkan manfaat dari memanfaatkan SVR sebagai algoritma pilihan untuk prediksi harga saham, sebagaimana ditunjukkan oleh akurasi prediktifnya yang superior dalam analisis ini.

Analisis Algoritma LSTM dan SVR untuk Memprediksi Saham Perbankan di Pasar Indonesia




(4a) Prediksi Saham BCA dengan LSTM



(4b) Prediksi Saham BNI dengan LSTM




(4c) Prediksi Saham BRI dengan LSTM




(4d) Prediksi Saham Mandiri dengan LSTM

Gambar 4. Harga Prediksi Saham dengan Algoritma LSTM


Berdasarkan Gambar 4, analisis Peramalan Harga Saham menggunakan algoritma LSTM menunjukkan hasil yang baik, seperti yang ditunjukkan oleh nilai MAPE yang relatif kecil, berkisar antara 1.2533 hingga 2.0893. Nilai-nilai ini menunjukkan bahwa harga saham yang diprediksi cukup sesuai dengan harga saham yang sebenarnya, menunjukkan akurasi algoritma LSTM dalam menangkap dan meramalkan pergerakan harga saham di masa depan. Hal ini mengindikasikan bahwa investor dan analis dapat mengandalkan prediksi LSTM dengan keyakinan, karena mereka memberikan wawasan yang berharga tentang tren dan fluktuasi yang diharapkan dalam harga saham untuk bank-bank yang dianalisis.




(5a) Prediksi Saham BBKA dengan SVR



(5b) Prediksi Saham BNI dengan LSTM



(5c) Prediksi Saham BRI dengan LSTM



(5d) Prediksi Saham Mandiri dengan LSTM

Gambar 5. Harga Prediksi Saham dengan Algoritma SVR

Pada Gambar 5, Peramalan Harga Saham menggunakan algoritma SVR menunjukkan hasil yang baik, seperti yang ditunjukkan oleh nilai MAPE yang relatif rendah, berkisar antara 1.2533 hingga 2.0893. Angka-angka ini mengindikasikan adanya kesesuaian yang dekat antara harga saham yang diprediksi dan harga saham yang sebenarnya, menekankan presisi algoritma SVR dalam meramalkan pergeseran harga saham yang akan datang. Dengan demikian, investor dan analis dapat mempercayai prediksi SVR, karena algoritma ini memberikan *insight* mengenai tren dan variasi harga saham yang diharapkan untuk bank-bank yang diperiksa.

SIMPULAN

Dalam penelitian ini, dilakukan perbandingan kinerja algoritma LSTM dan SVR dalam memprediksi harga saham Bank BCA (BBCA.JK), Bank BNI (BBNI.JK), Bank BRI (BBRI.JK), dan Bank Mandiri (BMRI.JK). Berdasarkan nilai evaluasi RMSE, algoritma SVR menunjukkan kinerja yang lebih baik dengan nilai RMSE yang lebih rendah, yaitu 4.9627, 5.4234, 5.4234, dan 2.5470 untuk masing-masing saham dibandingkan LSTM, yang menghasilkan RMSE sebesar 84.2712, 103.7936, 15.5974, dan 26.8980. Hal ini menunjukkan bahwa SVR lebih akurat dalam memprediksi harga saham keempat bank tersebut dibandingkan LSTM. Sebagai hasilnya, investor dan pemangku kepentingan di sektor perbankan dapat memanfaatkan prediksi SVR untuk membuat keputusan investasi yang terinformasi dan mengoptimalkan kinerja portofolio mereka. Untuk penelitian mendatang, disarankan untuk mengeksplorasi penggunaan model hybrid atau mengkombinasikan teknik-teknik lain seperti feature engineering atau hyperparameter tuning guna meningkatkan kinerja LSTM, mengingat potensinya dalam menangkap pola temporal yang lebih kompleks pada data saham.

DAFTAR PUSTAKA

- [1] P. Jorion, *Value at Risk: The New Benchmark Managing Financial*, Third. McGraw-Hill, 2006.
- [2] M. Leo, S. Sharma, and K. Maddulety, "Machine learning in banking risk management: A literature review," *Risks*, vol. 7, no. 1, Mar. 2019, doi: 10.3390/risks7010029.
- [3] M. Zheng, "Studying Stock Prediction in the Context of Machine Learning Exemplified by Analyzing SVM and LSTM Models," 2024.
- [4] R. D. Edwards, John Magee, and WH Charles Bassetti., *Technical analysis of stock trends*. CRC press, 2018.
- [5] R. Fernandez Martinez, P. Jimbert, J. Ibarretxe, and M. Iturrondobeitia, "Use of support vector machines, neural networks and genetic algorithms to characterize rubber blends by means of the classification of the carbon black particles used as reinforcing agent," *Soft comput*, vol. 23, no. 15, pp. 6115–6124, Aug. 2019, doi: 10.1007/s00500-018-3262-2.

- [6] Y. Ma, R. Han, and W. Wang, "Portfolio optimization with return prediction using deep learning and machine learning," *Expert Syst Appl*, vol. 165, Mar. 2021, doi: 10.1016/j.eswa.2020.113973.
- [7] M. Liangyu and J. Dong, "Robust mean-risk portfolio optimization using machine learning-based trade-off parameter," *Appl Soft Comput*, 2021.
- [8] B. Jyotirmayee and A. Kumar Pasayat, "Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets," *Eng Appl Artif Intell*, 2023.
- [9] E. Ruiz, D. Ferreño, M. Cuartas, A. López, V. Arroyo, and F. Gutiérrez-Solana, "Machine learning algorithms for the prediction of the strength of steel rods: an example of data-driven manufacturing in steelmaking," *Int J Comput Integr Manuf*, vol. 33, no. 9, pp. 880–894, Sep. 2020, doi: 10.1080/0951192X.2020.1803505.
- [10] S. Hamori, M. Kawai, T. Kume, Y. Murakami, and C. Watanabe, "Ensemble Learning or Deep Learning? Application to Default Risk Analysis," *Journal of Risk and Financial Management*, vol. 11, no. 1, p. 12, Mar. 2018, doi: 10.3390/jrfm11010012.
- [11] J. Brownlee Disclaimer, "Deep Learning for Time Series Forecasting Predict the Future with MLPs, CNNs and LSTMs in Python Acknowledgements Copyright Deep Learning for Time Series Forecasting," 2019.
- [12] Z. Hu, Y. Zhao, and M. Khushi, "A survey of forex and stock price prediction using deep learning," Mar. 01, 2021, MDPI AG. doi: 10.3390/ASI4010009.
- [13] G. Li, W. Chen, D. Li, D. Wang, and S. Xu, "Comparative Study of Short-Term Forecasting Methods for Soybean Oil Futures Based on LSTM, SVR, ES and Wavelet Transformation," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, 2020. doi: 10.1088/1742-6596/1682/1/012007.
- [14] Q. Q. Abuein, M. Q. Shatnawi, E. Y. Aljawarneh, and A. Manasrah, "Time Series Forecasting Model for the Stock Market using LSTM and SVR," *International Journal of Advances in Soft Computing and its Applications*, vol. 16, no. 1, pp. 169–185, 2024, doi: 10.15849/IJASCA.240330.10.
- [15] Y. Song, C. Cai, D. Ma, and C. Li, "Modelling and forecasting high-frequency data with jumps based on a hybrid nonparametric regression and LSTM model," *Expert Syst Appl*, vol. 237, Mar. 2024, doi: 10.1016/j.eswa.2023.121527.
- [16] R. C. Staudemeyer and E. R. Morris, "Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks," Sep. 2019, [Online]. Available: <http://arxiv.org/abs/1909.09586>
- [17] J. Brownlee Disclaimer, "Deep Learning for Time Series Forecasting Predict the Future with MLPs, CNNs and LSTMs in Python Acknowledgements Copyright Deep Learning for Time Series Forecasting," 2019.

- [18] J. Wang, J. Zhang, and X. Wang, "Bilateral LSTM: A two-dimensional long short-term memory model with multiply memory units for short-term cycle time forecasting in re-entrant manufacturing systems," *IEEE Trans Industr Inform*, vol. 14, no. 2, pp. 748–758, 2018, doi: 10.1109/TII.2017.2754641.
- [19] D. Rosadi, W. Andriyani, D. Arisanty, and D. Agustina, "Prediction of Forest Fire Occurrence in Peatlands using Machine Learning Approaches," in *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2020*, 2020. doi: 10.1109/ISRITI51436.2020.9315359.
- [20] A. Molino and S. Carlo, "Forecasting value at risk and conditional value at risk using option market data," *J Forecast*, vol. 7, pp. 1190–1213, 2021.