

Sistem Simulasi Pembelian Saham Bank Berbasis Deep Learning Dengan Metode Transformers

Yudo Nidlom Firmansyah¹, Rafli Ardiansyah²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹yudonidlomfirmansyah@gmail.com, ²rafardiansyahfli@gmail.com

Abstrak – Saham adalah sebuah bukti kepemilikan sebuah perusahaan, ketika investor membeli sebuah saham dari sebuah perusahaan, maka investor membeli sebagian perusahaan tersebut. Melakukan simulasi sebelum melakukan pembelian saham jarang di lakukan oleh investor untuk mengurangi potensi kerugian saat membeli saham, maka dibutuhkan sistem simulasi dengan bantuan mesin atau sistem yang dapat mempelajari pola pergerakan saham dengan baik, pada penelitian ini sistem simulasi dilengkapi dengan model deep learning transformers yang dapat mengenali pola pergerakan harga saham dengan baik. Dengan sistem simulasi yang dilengkapi dengan transformers, investor dapat memperkirakan dan membuat strategi pembelian saham dimasa depan dan mengurangi kerugian yang besar. Hasil dari penelitian ini membuktikan bahwa transformers memberikan error yang sangat rendah dengan rata rata error 0.124062516 dan rata rata koefisien determinasi sebesar 0.923312, dengan error yang sangat kecil dan kemampuan model dalam mengenali pola sebesar 93% maka simulasi di harapkan akan memberikan hasil yang akurat.

Kata Kunci — saham, investor, perusahaan, sistem, simulasi, pola, transformers, harga, strategi, kerugian, deep learning, koefisien determinasi.

1. PENDAHULUAN

Menurut [1], saham adalah sebuah produk yang paling banyak diminati oleh investor ketika melakukan investasi, karena saham memiliki hasil return yang tinggi. Ketika seorang investor membeli sebuah saham maka investor tersebut sama dengan membeli sebagian dari perusahaan tersebut, investor dapat melakukan pembelian saham pada pasar modal, pasar modal adalah tempat untuk meperjual-belian sebuah instrumen keuangan jangka panjang dalam bentuk modal atau hutang, yang diterbitkan oleh pemerintah atau perusahaan swasta [2].

Dalam pembelian saham di pasar modal, investor perlu membuat strategi untuk mengurangi resiko kerugian yang besar atau return yang kecil, menurut [3], return saham adalah pengembalian berupa keuntungan ataupun kerugian yang dihasilkan dari penjualan saham yang di lakukan selama periode waktu tertentu. Maka perlu dibuat sistem simulasi yang membantu investor dalam membuat sebuah keputusan dan strategi, dengan perkembangan teknologi saat ini, simulasi tersebut dapat dibantu dengan sebuah algoritma *deep learning* untuk mengoptimalkan hasil simulasi yang diinginkan.


Penelitian tentang penggunaan deep learning untuk memprediksi saham telah dilakukan oleh beberapa peneliti seperti penelitian dari [4], dimana penelitian tersebut membahas tentang prediksi data saham AGROPHOS dan TAINIWALCHM dengan algoritma *LSTM* dan membandingkan nya dengan beberapa algoritma lain seperti *SVR* (*Suport vector Regression*), *KNN* (*K-Nearst Neighbor Regression*), *Random Forest Regression*, *XG-Boost* dan penggabungan *Random Forest + XG-Bosst + LSTM*, penelitian ini memberikan hasil bahwa penggabungan *Random Forest + XG-Bosst + LSTM*, memiliki *R2 score* yang tinggi yaitu 0.9921, tetapi penelitian tersebut menunjukan kelemahan pada algoritma *deep learning* yang berdiri sendiri yaitu *LSTM* dengan *R2 score* 0.8867 dan juga penggabungan *Random Forest + XG-Bosst + LSTM* juga beresiko mengalami overfitting atau data leakage.

Oleh karena itu penelitian ini mengusulkan model *transformers* dan melakukan training pada dua data bank lain selain BRI yaitu bank Mandiri dan bank BCA, dimana *transformers* sendiri adalah bentuk *LSTM* yang lebih kompleks dan besar, pendekatan ini diharapkan dapat memberikan hasil simulasi yang lebih optimal dan mendapatkan *R2 score* yang tinggi dibanding dengan *LSTM*, karena *transformers* memiliki mekanisme *attention* (perhatian) dan *positional* (posisi) yang memungkinkan model dapat mengenali pola dengan lebih baik.

2. METODE PENELITIAN

Pada penelitian ini menggunakan sebuah pendekatan komprehensif untuk melakukan prediksi dan simulasi pada harga saham bank diindonesia, proses penelitian prediksi harga saham bank mencakup beberapaproses seperti, pengumpulan data yang dimana data dikumpulkan dalam sebuah file, lalu melakukan *preprocessing* dengan membersihkan dan mengatur data untuk di gunakan pada training dan testing, lalu proses modeling

dimana model dibuat dan ditentukan bagaimana parameternya, lalu model dilakukan training dan evaluasi untuk memastikan model dapat memprediksi data dengan akurasi yang tinggi, alur penelitian ini telah dicantumkan pada gambar 1.




Gambar 1, Diagram *Waterfall*

2.1 Data

Penelitian ini menggunakan data sekunder dimana data penelitian ini diambil melalui yahoo finance dengan bantuan library yfinance pada bahasa pemrograman python, data utama untuk sistem simulasi nya adalah data dari bank BRI dengan kode (BBRI.JK) dan dua data pembanding yaitu bank BCA (BBCA.JK) dan bank Mandiri (BMRI.JK) tahun 2015-01-01 hingga 2025-09-25.

2.1.1 Bank BRI

Bank BRI atau PT. Bank Rakyat Indonesia (Persero) Tbk adalah bank yang dimiliki oleh pemerintah indonesia dan salah satu bank terbesar di indonesia dengan jaringan yang luas [5]. Visualisasi pergerakan data harga bank BRI dapat dilihat pada gambar 2.




Gambar 2, A) Visualisai Harga Pembukaan Bank BRI Secara Parsial Pertahun, B) Visualisai Harga Penutupan Bank BRI Secara Parsial Pertahun, C) Visualisai Harga Penutupan Dan Pembukaan Bank BRI Secara Simultan (2015-2025).

Dari gambar 2, menunjukan bahwa saham bank BRI terus mengalami peningkatan dari tahun 2015 sampai 2025 dan lonjakan harga yang ekstim terjadi di antara 2020 hingga 2025 ini terjadi karena pemulihan ekonomi setelah bencana pandemi yang melumpuhkan ekonomi dimana dapat dilihat pada harga saham 2019 hingga 2020 harga saham mengalami penurunan yang drastis, ini bisa terjadi karena faktor seperti Saat *lockdown*/PSBB diberlakukan di 2020, pedagang pasar dan pengusaha kecil (nasabah utama BRI) adalah yang pertama kali kehilangan pendapatan dan Investor sempat khawatir kredit macet (NPL) BRI akan meledak karena UMKM tidak bisa bayar utang. Ini sebabnya grafik BRI di tahun 2020 terlihat "anjlok".

2.1.2 Bank BCA

Bank BCA atau PT. Bank Central Asia, Tbk adalah bank swasta terbesar di indonesia dengan jaringan luas dan manajemen yang profesional [6]. Visualisasi pergerakan data harga bank BCA dapat di lihat pada gambar 3.




Gambar 3, A) Visualisai Harga Pembukaan Bank BCA Secara Parsial Tahun, B) Visualisai Harga Penutupan Bank BCA Secara Parsial Tahun, C) Visualisai Harga Penutupan Dan Pembukaan Bank BCA Secara Simultan (2015-2025).

Dari gambar 3, menunjukan bahwa saham bank BCA terus mengalami peningkatan dari tahun 2015 sampai 2025 dan lonjakan harga yang ekstim terjadi di antara 2020 hingga 2025 ini terjadi karena pemulihan ekonomi setelah bencana pandemi yang melumpuhkan ekonomi, tetapi pada gambar 3 menunjukan peningkatan secara perlahan pada harga saham BCA dapat dilihat pada harga saham 2020 hingga 2022 harga saham mengalami peningkatan, kemungkinan ini bisa terjadi karena Saat krisis pandemi melanda, investor cenderung panik dan menarik uang dari saham-saham berisiko tinggi. Mereka memindahkan dananya ke saham "Blue Chip" yang dianggap paling aman dan anti-bangkrut. Dimana manajemen risiko BCA sangat ketat (NPL/kredit macet rendah), sehingga kerugian akibat nasabah gagal bayar saat pandemi lebih terkontrol dibanding kompetitornya.

2.1.3 Bank Mandiri

Bank Mandiri atau PT. Bank Mandiri Persero, Tbk adalah bank milik BUMN dengan jumlah pengolahan aset terbesar kedua di Indonesia dengan jumlah aset yang dikelola sebesar 1.405,85 triliun pada paruh ketiga 2020 [7]. Visualisasi pergerakan data harga bank Mandiri dapat dilihat pada gambar 4.



Gambar 4, A) Visualisai Harga Pembukaan Bank Mandiri Secara Parsial Tahun, B) Visualisai Harga Penutupan Bank Mandiri Secara Parsial Tahun, C) Visualisai Harga Penutupan Dan Pembukaan Bank Mandiri Secara Simultan (2015-2025).

Pada gambar 4, menunjukan bahwa saham bank Mandiri terus meningkat dari tahun 2019 sampai 202, tetapi terjadi penurunan pada tahun 2019 sampai 2022, ini dikarenakan bank Mandiri memiliki kondisi yang sama dengan bank BRI dimana, karena faktor seperti Saat *lockdown*/PSBB diberlakukan di 2020, pedagang pasar dan pengusaha kecil (nasabah utama) adalah yang pertama kali kehilangan pendapatan dan Investor sempat khawatir kredit macet (NPL) BRI akan meledak karena UMKM tidak bisa bayar utang. Ini sebabnya grafik bank Mandiri di tahun 2020 terlihat "anjlok".

2.2 Preprocessing Data

Pada penelitian ini, data disajikan dalam bentuk file yang didapat dari mengunduh data saham melalui sebuah library yfinance dan di rubah menjadi file dengan bantuan library pandas, pandas adalah sebuah library python yang ditujukan untuk membantu masalah pengolahan data *scientific computing* dan *statistical computing* [8], sedangkan yfinance adalah library yang populer untuk mengunduh data historis saham, dimana yfinance sudah terintegrasi dengan pandas [9], contoh hasil download data historis saham dapat di lihat pada tabel 1.


Table 1, Raw Data Untuk Data Historis Saham Bank

Date	Close	High	Low	Open	Volume
2015-01-02 00.00.00	1727,265	1731,254	1715,298	1719,287	84546800
2015-01-05 00.00.00	1723,275	1731,254	1715,297	1731,254	33363200
2015-01-06 00.00.00	1711,308	1727,264	1703,33	1715,297	58600000
2015-01-07 00.00.00	1731,254	1731,254	1711,308	1715,297	50244400

Setelah data disimpan data ditata dan dibersihkan, yang pertama dilakukan adalah menghapus nilai nan setelah di lakukan penghapusan nilai nan, maka langkah selanjutnya adalah membersihkan outlier dengan rumus IQR (rumus 1).


$$IQR(x) = (x_{Q(0,75)} - x_{Q(0,25)}); low = x_{Q(0,25)} - 1,5 \times IQR(x); Upper = x_{Q(0,25)} + 1,5 \times IQR(x) \dots\dots (1)$$

IQR sendiri adalah metode yang di gunakan untuk mebersihkan outlier data yang kemungkinan berkontribusi dalam hasil error yang besar saat prediksi [10]. Data outlier dapat di visualisaikan dengan *boxplot* (gambar 5 – gambar 7) di bawah ini.




Gambar 5, *Boxplot* Bank Mandiri

Pada gambar 5, menunjukan data yang telah bersih dari outlier tanpa dilakukan pembersihan dengan IQR, dimana semua value berada pada range yang rata tidak ada data yang melebihi kumis blok (garis panjang ke atas dan ke bawah) dimana garis tersebut menunjukan nilai maximum dan minimum data pada tahun tertentu, jadi tidak dilakukan *preprocessing* untuk data saham bank Mandiri.



Gambar 6, *Boxplot* Bank BRI

Pada gambar 6, menunjukan data yang telah bersih dari outlier tanpa dilakukan pembersihan dengan IQR, dimana semua value berada pada range yang rata tidak ada data yang melebihi kumis blok (garis panjang ke atas dan ke bawah), dimana garis tersebut menunjukan nilai maximum dan minimum data pada tahun tertentu, meskipun ada data yang melebihi batas minimum (data close tahun 2025), tetapi data tersebut masih berada pada batas minimum, jadi tidak dilakukan *preprocessing* untuk data saham bank BRI.



Gambar 7, Boxplot Bank BCA

Pada gambar 7, menunjukkan data yang telah bersih dari outlier tanpa dilakukan pembersihan dengan IQR, dimana semua value berada pada range yang rata tidak ada data yang melebihi kumis blok (garis panjang ke atas dan ke bawah), dimana garis tersebut menunjukkan nilai maximum dan minimum data pada tahun tertentu, meskipun ada data yang melebihi batas minimum (data close tahun 2015 dan 2023) dan tahun 2025 pada data open, tetapi data tersebut masih berada pada batas minimum harga pada tahun lain, jadi tidak dilakukan *preprocessing* untuk data saham bank BCA.


Setelah di lakukan visualisai outlier, ternyata data pada 3 bank yang di pilih tidak memiliki outlier pada data nya, jika sudah di rasa bersih dari outlier dan nilai nan, maka data akan di di lakukan drop pada kolom yang tidak di butuhkan seperti, low (harga terendah), high (harga tertinggi), volume (volume saham yang di perjual belikan) dan hasil preprocessing dapat dilihat pada tabel 2, setelah data di proses maka data siap untuk di gunakan dalam training model simulasi nya.

Table 2, Hasil Preprocessing Data Dari Data Historis Saham Bank

Close	Open	year	month	day
1727,265	1719,287	2015	1	2
1723,275	1731,254	2015	1	5
1711,308	1715,297	2015	1	6

2.3 Transformers

Menurut [11], transformers adalah model deep learning yang ditujukan untuk permasalahan NLP (Natural Language Processing) dengan tipe model sequence to sequence. Didalam model transformers terdapat 2 bagian penting yaitu encoder dan decoder, menurut [12], encoder mengubah sekumpulan simbol tertulis ($x_1, \dots, x_n$) menjadi sekumpulan notasi reguler yang saling terkait $z = (z_1, \dots, z_n)$, decoder kemudian membuat sekumpulan simbol keluaran ($y_1, \dots, y_m$) satu per satu, menggunakan z . Dimana z adalah input untuk attention pada decoder atau bisa di sebut sebagai cross-attention, pada penelitian ini encoder adalah bagian yang akan di pakai untuk model prediksi yang akan di lakukan, dimana transformers memiliki 3 mekanisme yaitu attention, positional dan feedforward network, arsitektur encoder dapat di lihat pada gambar 8.



Gambar 8, Transformer Encoder Architecture dari [12]


2.3.1 Attention

Menurut [12], attention adalah mekanisme yang mengolah input query, key dan value, yang mana query, key akan di olah untuk menghasilkan output weighted sum dan akan di proses perkalian matrix dengan value, dimana value inilah yang membawa hasil dari pemrosesan attention. Di dalam attention terdapat sebuah perhitungan yang menjadi nyawa pada untuk mekanisme attention, yaitu scale-dot-product (rumus 2).

$$f(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{\text{dim}_k}}\right)V \dots \dots \dots (2)$$

Pada arsitektur transformer menggunakan attention lebih dari satu atau multihead-attention dimana, pertama input di pecah berdasarkan jumlah attention yang di tentukan, contoh jumlah attention nya ada 4 dan dimensi

input nya 128, jadi setiap kepala akan mendapat input sebesar $(128/4 = 32)$ 32 data, yang nanti nya akan di satukan kembali untuk input mekanisme selanjutnya.



Gambar 9, Multi-Head Attention Architecture dari [12]

2.3.2. Positional


Positional encoding adalah sebuah mekanisme yang menghitung posisi dari data dengan menambahkan token dengan posisi yang di dihasilkan dari arange $x_{shape[-1]}$, ini memberikan informasi tentang absolut posisi pada sequence [13]. Dengan informasi posisi tersebut maka akan membantu attention dalam memberikan pembobotan perhatian.

2.3.3. Feed Forward Network

Setiap lapisan dalam encoder dan decoder terdapat jaringan feed-forward yang terhubung sepenuhnya, jaringan ini diterapkan pada setiap posisi dalam input, dengan operasi yang persis sama dilakukan di setiap titik, jaringan ini dibangun dari dua transformasi linier dan satu buah fungsi aktivasi [12]. Pada penelitian ini fungsi aktivasi yang di gunakan adalah GELU (Gaussian Error Linear Unit) (rumus 3).

$$GELU(x) = 0.5 \times x \times \left(1 + \tanh \left(\sqrt{\frac{2}{\pi}} \times (x + 0.044715 \times x^3) \right) \right) \dots (3)$$

Dimana GELU (Gaussian Error Linear Unit) ini adalah fungsi aktivasi yang meloloskan nilai negatif dan merubah nilai negatif tersebut menjadi lebih smooth (gambar 10). Feed forward network ini adalah mekanisme yang menjadi kan input memiliki variasi, sehingga menghindari overfitting.



Gambar 10, Visualisai fungsi aktivasil GELU

2.4 LSTM (Long Short-Term Memory)

LSTM (Long Short-Term Memory) adalah salah satu algoritma memory network yang di kembangkan dari RNN yang memiliki kemampuan menyimpan pola informasi lebih panjang di banding dengan RNN [14]. LSTM memiliki 5 gate, gate pertama adalah input gate (i_t) (rumus 4), forgate gate (f_t) (rumus 5), cell gate (c_t) (rumus 6), output gate (o_t) (rumus 7) dan hidden gate (h_t) (rumus 8), srsitektur LSTM dapat di lihat pada gambar 11.


$$i_t = \sigma(W_{xi}x_t + W_{ci}c_{t-1} + W_{hi}h_{t-1} + b_i) \dots (4)$$

$$f_t = \sigma(W_{xf}x_t + W_{cf}c_{t-1} + W_{hf}h_{t-1} + b_f) \dots (5)$$

$$c_t = f_t + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \dots (6)$$

$$o_t = \sigma(W_{xo}x_t + W_{co}c_{t-1} + W_{ho}h_{t-1} + b_o) \dots (7)$$

$$h_t = o_t \tanh(c_t) \dots (8)$$



Gambar 11, Arsitektur LSTM dari [14]

2.5 Training Setup

Pada penelitian ini transformers menggunakan parameter head = 12 (jumlah attention pada Encoder), num_embedding = 10000 (jumlah bobot embedding) , dropout_rate = 0.5 (rate jumlah neuron yang di matikan), hidden_model = 128 (ukuran dimensi data yang mengalir dalam model). LSTM menggunakan setting parameter inputsize = 128, hidden = 128, out_size = 1, n_layer = 2, Batch_first = True.

2.6 Fungsi Loss Dan Fungsi Optimasi

Penelitian ini menggunakan fungsi loss SmoothL1Loss (rumus 9), SmoothL1Loss adalah rumus L1 loss yang di lengkapi dengan smoother, dan fungsi loss ini sudah tahan terhadap outlier [15].

$$L(x) = \sum \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases} \dots\dots\dots (9)$$

Lalu untuk fungsi optimasi menggunakan Adam optimizer dengan seting learning rate 0.01(menentukan seberapa cepat model belajar), *adam optimizer* adalah Teknik yang dirancang untuk optimasi stokastik yang efisien hanya menggunakan gradien orde pertama dan membutuhkan memori minimal. Pendekatan ini menentukan laju pembelajaran yang unik dan dapat disesuaikan untuk berbagai parameter dengan menilai perkiraan momen pertama dan kedua dari gradien tersebut [16].

2.7 Metric Evaluasi

Penelitian ini menggunakan koefisien determinasi atau *R2 score* (rumus 10), menurut [17], *R2 score* adalah metric untuk task regresi yang di gunakan sebagai pengganti akurasi, dimana *R2 score* memiliki rentan 0 sampai 1 dimana nilai tersebut menjelaskan seberapa besar bagian data yang mampu di pahami oleh model.


$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2} \dots\dots\dots (10)$$

Lalu untuk fungsi loss pada evaluasi dipakai rumus MAPE (*Mean Absolute Percentage Error*) (rumus 11), menurut , MAPE (*Mean Absolute Percentage Error*) adalah rumus yang sering dipakai untuk melakukan evaluasi pada model regresi dengan permasalahan seperti *time* atau data *forecasting* [18].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - Y_t}{X_t} \right| \times 100\% \dots\dots\dots (11)$$

3. HASIL DAN PEMBAHASAN

Pada penelitian ini di lakukan komparasi terhadap 2 model yang berbeda dengan 3 data yang berbeda yaitu bank BRI dengan kode (BBRI.JK) dan dua data pembanding yaitu bank BCA (BBCA.JK) dan bank Mandiri (BMRI.JK) tahun 2015-01-01 hingga 2025-09-25, sehingga di dapatkan hasil sebagai berikut.




Gambar 12, Hasil Training Dari Transformers

Dari gambar 12, R2 Score dari training dengan epoch 20,000 menunjukkan hasil yang sangat baik, tetapi pada epoch 5,000 tiba tiba R2 score turun secara drastis, kemungkinan ini di sebabkan oleh gradiend yang tiba tiba membengkak dan di epoch selanjutnya R2 score kembali normal. Lalu pada bagian grafik loss pada epoch 5,000 seperti pernyataan sebelum nya pada epoch 5,000 terjadi ledakan gradient yang di akibatkan oleh loss yang besar, karena nilai loss lah yang menentukan bagaimana gradient di alirkan saat melakukan *backpropagasi*.

Table 3, Hasil Testing Model Transformers Data Dari Data Historis Saham Bank

NO	Bank	R2 Score	MAPE
1	BRI (Bank Rakyat Indonesia)	0.9179197549819946	0.1065606
2	BCA(Bank Central Asia)	0.9345501065254211	0.1354593
3	Bank Mandiri	0.9174664616584778	0.13016765
4	Rata – Rata	0.923312169	0.124062517

Tabel 3, menunjukan hasil testing yang baik dengan rata rata R2 score 0.923312169 dimana ini menunjukan bahwa model dapat menjelaskan data sebesar 92% dan 8% lain nya di anggap noise oleh model, lalu rata rata MAPE (*Mean Absolute Precentage Error*) adalah 0.124062517, dimana ini adalah angka yang sangat kecil, mengingat bahwa data yang di ukur untuk MAPE (*Mean Absolute Precentage Error*) adalah data dengan value asli atau ribuan bukan (0-1) atau normalisasi.



Gambar 13, Hasil Training Dari Transformers


Dari gambar 13, R2 score memberikan hasil yang baik dan berjalan dengan konsisten tanpa ada ledakan gradient, lalu pada grafik untuk loss memberikan hasil yang berjalan secara konsisten, tetapi ketika model di lakukan test model mengalami perbedaan yang sangat jauh dari saat di training, hasil tersebut dapat di lihat pada tabel 4 di bawah.

Table 4, Hasil Testing Model LSTM Data Dari Data Historis Saham Bank

NO	Bank	R2 Score	MAPE
1	BRI (Bank Rakyat Indonesia)	0.5672228336334229	0.16904102
2	BCA(Bank Central Asia)	0.5489183664321899	0.22429293
3	Bank Mandiri	0.5420390367507935	0.15550248
4	Rata – Rata	0.552726746	0.1829

Tabel 4, menunjukan hasil testing yang tidak stabil dengan rata rata R2 score 0.552726746 dimana ini menunjukan bahwa model dapat menjelaskan data sebesar 55% dan 45% lain nya di anggap noise oleh model, lalu rata rata MAPE (*Mean Absolute Precentage Error*) adalah 0.1829, dimana ini adalah angka yang sangat kecil, mengingat bahwa data yang di ukur untuk MAPE (*Mean Absolute Precentage Error*) adalah data dengan value asli atau ribuan bukan (0-1) atau normalisasi, ketidak konsistenan ini terjadi karena model mengalami *overfitting* saat training, *overfitting* ini bisa terjadi karena model terlalu memahami data mengingat *LSTM* memiliki kemampuan menyimpan informasi yang kompleks dan data yang sederhana.

Setelah dilakukan testing dan training maka model transformers di pilih berdasarkan konsistensi antara hasil training dan testing dan data yang di pakai untuk melakukan simulasi adalah data bank BRI, bank BRI di pilih karena bank BRI adalah bank milik BUMN dan terbesar di indonesia, setelah model di pilih selanjutnya adalah pembuatan antarmuka untuk melakukan simulasi pada model dengan range data yang ekstrem, hasil antarmuka dapat dilihat pada gambar 14.



Gambar 14, *User Interface (UI)* dari simulasi prediksi penjualan saham bank

a. Input data

User dapat menginputkan data dari tahun kapanpun, dengan batas hingga tahun 10000, dan user dapat memilih bulan berapapun untuk di cek mulai dari bulan pertama sampai bulan ke 12, dengan ini user dapat dengan leluasa untuk melakukan simulasi prediksi harga saham bank BRI.

b. Grafik dan tabel

Setelah user melakukan input, secara otomatis sistem akan memprediksi selama satu bulan atau model akan menghasilkan 30 data, lalu data di sajikan dalam bentuk tabel dan grafik, dengan ini user dapat melihat bagaimana pergerakan saham selama bulan dan tahun tersebut.

c. Rekomendasi Cerdas

Rekomendasi cerdas pada gambar 14 di hasilkan dari sistem pencarian linear dimana sistem mencari satu persatu data dari tabel hingga mendapatkan nilai maximum dan minimum, dimana ini menguntungkan untuk melihat kapan harus menjual dan membeli saham.

4. SIMPULAN

Dari percobaan yang telah di lakukan dengan melakukan training pada 2 algoritma yang berbeda (*Transformers* dan *LSTM*) dengan menggunakan 3 data saham bank yang berbeda yaitu, bank BRI dengan kode (BBRI.JK) dan dua data pembandingan yaitu bank BCA (BBKA.JK) dan bank Mandiri (BMRI.JK) tahun 2015-01-01 hingga 2025-09-25, sehingga di dapatkan kesimpulan bahwa model LSTM lebih rentan terhadap *overfitting* hasil tersebut dapat dibuktikan pada gambar 13 dan tabel 4, dan model *transformers* lebih tahan terhadap *overfitting* dan memberikan hasil yang konsisten hasil tersebut dapat dilihat pada tabel 3 dan gambar 12, sehingga sistem simulasi ini memakai model *transformers* di bandingkan dengan LSTM, dan pada sistem simulasi digunakan data dari bank BRI untuk di pakai sebagai simulasi, karena bank BRI adalah bank yan terbesar milik negara.

5. SARAN

Transformers memang memiliki hasil yang lebih baik di banding dengan LSTM pada penelitian ini tetapi transformers memiliki R2 Score yang tidak maksimal, pada penelitian selanjutnya diharapkan penelitian ini dapat menjadi patokan untuk perbaikan penggunaan model transformers untuk melakukan prediksi harga saham yang lebih optimal dan akurat.

DAFTAR PUSTAKA

- [1] P. Pandaya, P. D. Julianti, and I. Suprpta, "Pengaruh faktor fundamental terhadap return saham," *Jurnal akuntansi*, vol. 9, no. 2, pp. 233–243, 2020.
- [2] I. N. Sujana, "Pasar modal yang efisien," *Ekuitas: Jurnal Pendidikan Ekonomi*, vol. 5, no. 2, pp. 33–40, 2017.
- [3] H. C. Yap and F. Firnanti, "Faktor-faktor yang mempengaruhi return saham," *Jurnal Bisnis Dan Akuntansi*, vol. 21, no. 1a–1, pp. 27–38, 2019.
- [4] G. Sonkavde, D. S. Dharrao, A. M. Bongale, S. T. Deokate, D. Doreswamy, and S. K. Bhat, "Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications," *International Journal of Financial Studies*, vol. 11, no. 3, p. 94, 2023.

- [5] P. Clara, “Alur Prosedur Menjadi Agen Brilink Pada PT. Bank BRI Mikro BO Palembang A Rivai,” *Jurnal Bisnis Dan Manajemen (JURBISMAN)*, vol. 2, no. 1, pp. 23–36, 2024.
- [6] S. O. Bunga and H. Riofita, “Strategi Pemasaran Bank BCA dalam Menciptakan Nilai Kepuasan dan Loyalitas Pelanggan,” *PENG: Jurnal Ekonomi dan Manajemen*, vol. 2, no. 2, pp. 1971–1976, 2025.
- [7] N. D. Astari, D. Hermawan, and R. Pakpahan, “Analisis Tingkat Kesehatan Bank Dengan Menggunakan Metode RGEC: Studi Kasus Pada PT Bank Mandiri (Persero), Tbk,” *Indonesian Journal of Economics and Management*, vol. 1, no. 3, pp. 615–627, 2021.
- [8] W. McKinney, “pandas: a foundational Python library for data analysis and statistics,” *Python for high performance and scientific computing*, vol. 14, no. 9, pp. 1–9, 2011.
- [9] A. Mandal, Y. Shao, and X. Liu, “Automatic Historical Stock Price Dataset Generation Using Python,” *arXiv preprint arXiv:2308.13414*, 2023.
- [10] A. Alabrah, “An improved CCF detector to handle the problem of class imbalance with outlier normalization using IQR method,” *Sensors*, vol. 23, no. 9, p. 4406, 2023.
- [11] F. Giuliani, I. Hasan, M. Cristani, and F. Galasso, “Transformer networks for trajectory forecasting,” in *2020 25th international conference on pattern recognition (ICPR)*, IEEE, 2021, pp. 10335–10342.
- [12] A. Vaswani *et al.*, “Attention Is All You Need,” Jun. 2017, [Online]. Available: <http://arxiv.org/abs/1706.03762>
- [13] P.-C. Chen, H. Tsai, S. Bhojanapalli, H. W. Chung, Y.-W. Chang, and C.-S. Ferng, “A simple and effective positional encoding for transformers,” *arXiv preprint arXiv:2104.08698*, 2021.
- [14] A. Graves, “Generating Sequences With Recurrent Neural Networks,” Aug. 2013, [Online]. Available: <http://arxiv.org/abs/1308.0850>
- [15] R. Girshick, “Fast R-CNN,” Apr. 2015, [Online]. Available: <http://arxiv.org/abs/1504.08083>
- [16] Kingma D P and Ba J, “ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION,” *arXiv preprint arXiv:1412.6980*, vol. 1412, no. 6, 2014.
- [17] D. J. Olive, “Multiple linear regression,” in *Linear regression*, Springer, 2017, pp. 17–83.
- [18] A. De Myttenaere, B. Golden, B. Le Grand, and F. Rossi, “Mean absolute percentage error for regression models,” *Neurocomputing*, vol. 192, pp. 38–48, 2016.