https://doi.org/10.37817/ikraith-informatika.v11i1
P-ISSN : 2580-4316
E-ISSN : 2654-8054

Komparasi LSTM dan GRU untuk Prediksi Harga XAUUSD dan Sinyal Trading

Chandra Wijaya[1]
Janter Napitupulu[2]
Rikardo H Siahaan[3]
Program Studi Teknik Informatika, Fakultas Teknologi Industri, Institut Sains & Teknologi TD Pardede Medan
E-mail:
mrhead004@gmail.com [1]
jantermh@gmail.com [2]
ricardoricardo3010@gmail.com [3]

ABSTRAK

Pasar valuta asing dan instrumen XAUUSD memiliki volatilitas tinggi sehingga memerlukan pendekatan prediksi yang mampu memodelkan dependensi temporal. Penelitian ini membandingkan Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi harga penutupan XAUUSD dan membangkitkan sinyal Buy, Sell, dan Hold sebagai keluaran sistem pendukung keputusan pada strategi swing trading. Data Gold Futures ticker GC=F diperoleh dari Yahoo Finance pada timeframe harian untuk periode 2 Januari 2020 sampai 28 April 2026. Sebanyak 1.596 baris data diproses menggunakan fitur Close, normalisasi MinMaxScaler, sliding window 60 hari, dan pembagian sekuensial 80% data latih serta 20% data uji. Arsitektur kedua model dikontrol agar setara dan dievaluasi menggunakan RMSE, MAE, MAPE, serta waktu training. Pada run detail yang dilaporkan, GRU menghasilkan RMSE 82,2814, MAE 52,9155, dan MAPE 1,3290%, sedangkan LSTM menghasilkan RMSE 102,4626, MAE 65,0265, dan MAPE 1,5705%. LSTM lebih cepat dilatih, yaitu 91,90 detik dibandingkan GRU 156,43 detik. Dengan threshold perubahan prediksi sebesar ±0,5%, GRU menghasilkan proporsi Hold lebih tinggi, yaitu 49,7%, sehingga lebih selektif dalam merekomendasikan entry. Hasil ini menunjukkan bahwa GRU lebih unggul pada akurasi run detail, sedangkan LSTM unggul pada efisiensi pelatihan.
Kata kunci: LSTM; GRU; XAUUSD; prediksi harga; swing trading; sistem pendukung keputusan

ABSTRACT

The foreign exchange market and the XAUUSD instrument are highly volatile, requiring forecasting methods that can model temporal dependencies. This study compares Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) for forecasting XAUUSD closing prices and generating Buy, Sell, and Hold signals as decision-support outputs for swing trading. Gold Futures data with ticker GC=F were collected from Yahoo Finance at a daily frequency from 2 January 2020 to 28 April 2026. A total of 1,596 rows were processed using the Close feature, MinMaxScaler normalization, a 60-day sliding window, and a sequential split of 80% training and 20% testing data. The two architectures were controlled to be comparable and evaluated using RMSE, MAE, MAPE, and training time. In the reported detailed run, GRU obtained RMSE 82.2814, MAE 52.9155, and MAPE 1.3290%, whereas LSTM obtained RMSE 102.4626, MAE 65.0265, and MAPE 1.5705%. LSTM trained faster, requiring 91.90 seconds compared with 156.43 seconds for GRU. With a ±0.5% prediction-change threshold, GRU generated a higher Hold proportion of 49.7%, indicating more selective entry recommendations. The results indicate that GRU is superior in detailed-run accuracy, while LSTM is superior in training efficiency.
Keywords: LSTM; GRU; XAUUSD; price forecasting; swing trading; decision support system

1. PENDAHULUAN

Pasar valuta asing (foreign exchange/Forex) merupakan pasar keuangan global dengan likuiditas yang sangat tinggi. Laporan Bank for International Settlements menunjukkan bahwa rata-rata turnover harian Forex mencapai lebih dari US$7,5 triliun pada April 2022 (Bank for International Settlements, 2022). Besarnya skala transaksi menjadikan Forex menarik bagi trader ritel, tetapi likuiditas dan pergerakan harga yang cepat juga meningkatkan tuntutan terhadap kualitas analisis serta disiplin pengambilan keputusan.

XAUUSD merepresentasikan harga emas terhadap dolar Amerika Serikat dan sering diperlakukan sebagai instrumen safe haven. Pergerakannya dipengaruhi oleh suku bunga, inflasi, kekuatan dolar, serta ketidakpastian geopolitik. Pada kondisi volatil, perubahan harga dapat berlangsung tajam sehingga keputusan entry yang hanya mengandalkan intuisi berisiko menghasilkan posisi yang tidak sesuai arah pasar. Dalam penelitian

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i1

prediksi finansial, sifat data yang nonlinier, bernoise, dan berubah terhadap waktu membuat model deret waktu menjadi pilihan penting (Ayitey Junior et al., 2023; Liang et al., 2022).

Swing trading berupaya menangkap pergerakan harga selama beberapa hari sampai beberapa minggu. Karena fokusnya bukan pada fluktuasi intrahari, timeframe Daily dapat digunakan untuk mereduksi noise sekaligus mempertahankan informasi tren. Kendala praktisnya adalah mengubah keluaran prediksi harga menjadi rekomendasi yang mudah dipahami. Prediksi regresi saja belum memberikan jawaban operasional mengenai kapan trader sebaiknya membuka posisi atau menunggu.

Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) merupakan turunan Recurrent Neural Network (RNN) yang banyak digunakan untuk pemodelan data sekuensial. LSTM memiliki cell state dan tiga gerbang, sedangkan GRU menyederhanakan mekanisme tersebut menjadi hidden state dengan update gate dan reset gate. Sejumlah penelitian memperlihatkan bahwa performa relatif kedua arsitektur bergantung pada karakteristik aset, periode observasi, serta konfigurasi eksperimen (Kobiela et al., 2022; Pahlevi et al., 2023; Yurtesver, 2021).

Kesenjangan yang diangkat dalam penelitian ini terdiri atas dua aspek. Pertama, komparasi langsung LSTM dan GRU yang secara spesifik menggunakan XAUUSD sebagai objek masih terbatas. Kedua, sebagian penelitian berhenti pada keluaran prediksi harga, sedangkan trader membutuhkan interpretasi berbasis aturan yang dapat membantu keputusan Buy, Sell, atau Hold. Penelitian ini karena itu merancang eksperimen terkontrol untuk membandingkan kedua arsitektur pada dataset dan preprocessing yang sama, kemudian memetakan perubahan prediksi menjadi tiga sinyal.

Tujuan penelitian adalah mengimplementasikan LSTM dan GRU pada data historis XAUUSD, membandingkan akurasinya menggunakan RMSE, MAE, dan MAPE, menilai efisiensi melalui waktu training, serta menghasilkan sinyal Buy, Sell, dan Hold dengan threshold 0,5%. Kontribusi penelitian bersifat metodologis dan praktis: metodologis melalui komparasi arsitektur pada kondisi terkontrol, dan praktis melalui penyajian keluaran sebagai sistem pendukung keputusan, bukan sebagai sistem eksekusi transaksi otomatis.

2. LANDASAN TEORI

2.1 Data deret waktu dan swing trading

Data deret waktu adalah observasi yang tersusun menurut urutan waktu dan memiliki dependensi temporal. Pada data finansial, nilai saat ini dapat berkaitan dengan nilai sebelumnya melalui pola tren, volatilitas, dan perubahan rezim. Ketergantungan tersebut menyebabkan pembagian data tidak boleh dilakukan secara acak karena informasi masa depan dapat masuk ke data latih dan menimbulkan data leakage. Swing trading memanfaatkan pergerakan menengah; oleh sebab itu, jendela historis dan timeframe harus dipilih dengan mempertimbangkan horizon keputusan.

2.2 LSTM dan GRU

RNN standar memperbarui hidden state dengan memanfaatkan input saat ini dan hidden state sebelumnya. Namun, propagasi gradien melalui urutan yang panjang dapat menyebabkan vanishing gradient atau exploding gradient. LSTM mengatasi masalah tersebut melalui cell state dan mekanisme gerbang. Forget gate menentukan informasi lama yang dipertahankan, input gate mengatur informasi baru yang disimpan, dan output gate menentukan informasi yang diteruskan sebagai hidden state. Mekanisme ini membuat LSTM sesuai untuk dependensi temporal jangka panjang (Althelaya et al., 2021; Livieris et al., 2020).

GRU menyederhanakan LSTM dengan mengintegrasikan fungsi memori ke dalam hidden state. Update gate mengatur keseimbangan antara informasi lama dan kandidat informasi baru, sedangkan reset gate mengontrol seberapa jauh hidden state sebelumnya digunakan ketika membentuk kandidat. Karena jumlah gerbang dan parameter lebih sedikit, GRU sering diasumsikan lebih efisien. Asumsi tersebut tetap harus diuji karena waktu komputasi aktual juga dipengaruhi batch size, strategi learning rate, callback, dan perangkat keras (Hamayel & Owda, 2021; Seabe et al., 2023).

2.3 Sistem pendukung keputusan dan evaluasi

Sistem pendukung keputusan (SPK) memadukan data, model, dan antarmuka

https://doi.org/10.37817/ikraith-informatika.v11i1
P-ISSN : 2580-4316
E-ISSN : 2654-8054

rekomendasi untuk membantu pengguna mengambil keputusan. Dalam penelitian ini, database berupa histori XAUUSD, model management berupa LSTM dan GRU, sedangkan antarmuka konseptualnya adalah sinyal Buy, Sell, dan Hold. Keputusan akhir tetap berada pada trader karena keluaran tidak mengandung eksekusi otomatis dan tidak menggantikan manajemen risiko.

Akurasi prediksi diukur menggunakan RMSE, MAE, dan MAPE. RMSE memberikan penalti lebih besar terhadap error ekstrem, MAE menggambarkan besaran error absolut rata-rata, sedangkan MAPE menyatakan error secara relatif dalam persentase. Nilai yang lebih kecil menunjukkan performa yang lebih baik. Waktu training digunakan sebagai metrik efisiensi tambahan, bukan sebagai pengganti metrik akurasi.

$$RMSE = \sqrt{[(1/n)\,\Sigma(y_i - \hat{y}_i)^2]};\quad MAE = (1/n)\,\Sigma|y_i - \hat{y}_i|;\quad MAPE = (100/n)\,\Sigma|(y_i - \hat{y}_i)/y_i|$$

3. METODOLOGI

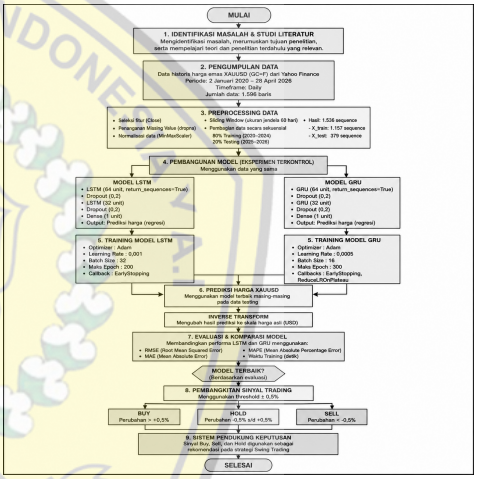
3.1 Desain penelitian dan data

Penelitian menggunakan desain controlled experiment komparatif. LSTM dan GRU dilatih pada dataset yang sama, menggunakan fitur, jendela, fungsi loss, dan prosedur evaluasi yang sama. Perbedaan arsitektur menjadi variabel utama yang diamati. Learning rate dan callback disesuaikan berdasarkan konfigurasi eksperimen pada skripsi karena karakteristik konvergensi masing-masing arsitektur berbeda; penyesuaian tersebut dilaporkan secara eksplisit agar komparasi dapat direproduksi.

Data diambil dari Yahoo Finance melalui ticker GC=F yang merepresentasikan Gold Futures. Periode observasi adalah 2 Januari 2020 sampai 28 April 2026 dengan frekuensi harian. Dataset mentah terdiri atas 1.596 baris dan menyediakan Open, High, Low, Close, serta Volume. Penelitian hanya menggunakan Close agar interpretasi tetap terfokus pada harga penutupan dan kompleksitas model tidak meningkat tanpa analisis ablation tambahan.

Tabel 1. Spesifikasi dataset dan preprocessing

Komponen	Nilai	Keterangan
Sumber	Yahoo Finance, GC=F	Gold Futures
Periode	2 Jan 2020–28 Apr 2026	Data harian
Baris mentah	1.596	Hari perdagangan
Fitur tersedia	OHLCV	Close dipilih
Normalisasi	MinMaxScaler [0,1]	Dibalik dengan inverse transform
Sliding window	60 hari	Memprediksi Close hari berikutnya
Sequence	1.536	Setelah pembentukan window
Pembagian	80% : 20%	Sekuensial, bukan acak



Gambar 1. Alur penelitian dan pembangkitan sinyal

Seperti ditunjukkan pada Gambar 1, alur penelitian dimulai dari identifikasi masalah dan pengumpulan data, dilanjutkan dengan preprocessing, pembangunan dua model, training, evaluasi, dan pembangkitan sinyal. Urutan ini menjaga agar transformasi data dan pemisahan periode uji dilakukan sebelum interpretasi keluaran model.

3.2 Preprocessing dan pembentukan sequence

Nilai Close diperiksa terhadap missing value setelah proses pengunduhan. Baris yang tidak lengkap dihapus menggunakan dropna(). Selanjutnya, data dinormalisasi menggunakan MinMaxScaler dengan persamaan $x' = (x - x_{min})/(x_{max} - x_{min})$. Normalisasi membantu menjaga nilai masukan pada rentang yang sesuai dengan fungsi aktivasi sigmoid dan tanh. Setelah prediksi diperoleh, skala dikembalikan ke

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i1

satuan harga menggunakan inverse transform sebelum metrik dihitung.

Teknik sliding window berukuran 60 digunakan untuk membentuk pasangan input-output. Setiap sampel input memuat 60 harga penutupan berurutan dan labelnya adalah harga pada hari berikutnya. Pembagian data dilakukan berdasarkan tanggal, dengan periode training 2 Januari 2020–31 Desember 2024 dan periode testing 1 Januari 2025–28 April 2026. Kompensasi terhadap panjang window menghasilkan 1.157 sequence training dan 379 sequence testing.

3.3 Arsitektur dan skenario training

Kedua model menggunakan dua lapisan recurrent dan dua dropout. Lapisan pertama memiliki 64 unit dan return_sequences=True, sedangkan lapisan kedua memiliki 32 unit dan return_sequences=False. Output diteruskan ke Dense satu unit untuk regresi harga. Dropout 0,2 digunakan setelah setiap lapisan recurrent. LSTM memiliki 29.345 parameter, sementara GRU memiliki 22.305 parameter.

Tabel 2. Konfigurasi model dan hyperparameter

Parameter	LSTM	GRU
Lapisan recurrent	LSTM 64 → LSTM 32	GRU 64 → GRU 32
Dropout	0,2 setelah tiap layer	0,2 setelah tiap layer
Output	Dense 1	Dense 1
Parameter	29.345	22.305
Optimizer	Adam, lr 0,001	Adam, lr 0,0005
Loss	MSE	MSE
Maksimum epoch	200	300
Batch size	32	16
Validation split	10%	10%
Early stopping	Patience 20	Patience 30
ReduceLROnPlateau	Tidak	Factor 0,5; patience 10

Optimizer Adam dipilih karena menggabungkan momentum dan penyesuaian learning rate. Early stopping memantau validation loss dan mengembalikan bobot terbaik. Pada GRU, ReduceLROnPlateau menurunkan learning rate ketika validation loss mengalami plateau, dengan batas minimum 0,00001. LSTM dilatih paling banyak 200 epoch dengan batch 32, sedangkan GRU diberi maksimum 300 epoch dengan batch 16.

3.4 Pembangkitan sinyal

Sinyal dihitung dari perubahan relatif prediksi berurutan: $\Delta_t=(\hat{y}_t-\hat{y}_{t-1})/\hat{y}_{t-1}$. Jika Δ_t lebih besar dari 0,5%, sistem menghasilkan BUY; jika lebih kecil dari −0,5%, sistem menghasilkan SELL; dan jika berada pada interval −0,5% sampai 0,5%, sistem menghasilkan HOLD. Threshold tersebut digunakan untuk mengurangi frekuensi sinyal akibat noise kecil dan mempertahankan karakteristik swing trading. Sinyal diposisikan sebagai rekomendasi, bukan instruksi otomatis untuk membuka posisi.

3.5 Evaluasi

Prediksi pada data uji dikembalikan ke skala harga aktual, lalu RMSE, MAE, dan MAPE dihitung. Waktu training dicatat dari awal sampai akhir proses fit. Selain hasil run detail, abstrak skripsi melaporkan ringkasan tiga running untuk memperoleh hasil yang lebih robust. Karena rincian nilai setiap running tidak tersedia, penelitian ini tidak menghitung interval kepercayaan atau uji signifikansi baru.

4. HASIL DAN PEMBAHASAN

4.1 Hasil preprocessing

Dataset berhasil diperoleh dari Yahoo Finance tanpa missing value yang signifikan setelah dropna(). Rentang harga Close pada skripsi dilaporkan sekitar US$1.472 pada Maret 2020 sampai sekitar US$3.500 pada Februari 2026, dengan tren keseluruhan bullish dan volatilitas yang meningkat pada 2024–2026. Setelah normalisasi dan windowing, terbentuk 1.536 sequence berukuran 60 timestep dan 1 fitur. Pembagian sekuensial menjaga evaluasi tetap out-of-sample terhadap periode 2025–2026.

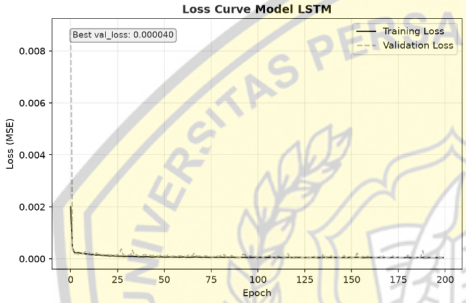
4.2 Hasil training dan kompleksitas model

LSTM berjalan sekitar 191 epoch dari maksimum 200 epoch dan memerlukan 91,90 detik. GRU berjalan sekitar 189 epoch dari maksimum 300 epoch dan memerlukan 156,43 detik. Kedua model mencapai konvergensi dengan early stopping. Walaupun parameter GRU lebih sedikit, waktu training aktualnya lebih lama karena batch size lebih kecil dan adanya ReduceLROnPlateau. Temuan ini menegaskan bahwa jumlah parameter bukan satu-satunya penentu durasi training.

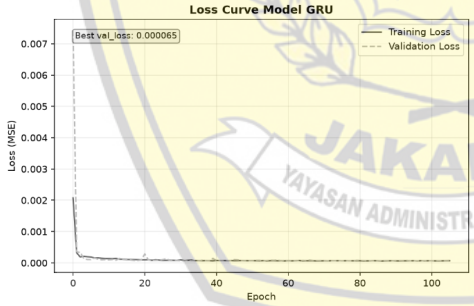
https://doi.org/10.37817/ikraith-informatika.v11i1
P-ISSN : 2580-4316
E-ISSN : 2654-8054

Tabel 3. Hasil training dan evaluasi run detail

Metrik	LSTM	GRU	Model unggul
Epoch aktual	191 ±	189 ±	Relatif sama
Parameter	29.345	22.305	GRU, lebih ringan
Waktu training	91,90 detik	156,43 detik	LSTM, lebih cepat
RMSE	102,4626	82,2814	GRU
MAE	65,0265	52,9155	GRU
MAPE	1,5705%	1,3290%	GRU



Gambar 2. Kurva loss training dan validasi model LSTM



Gambar 3. Kurva loss training dan validasi model GRU

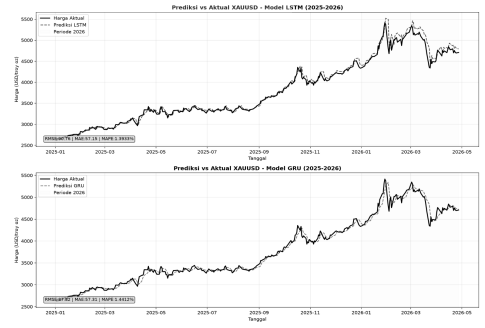
Kurva loss pada Gambar 2 dan Gambar 3 memperlihatkan penurunan tajam pada epoch awal dan kemudian stabil di sekitar nilai loss yang kecil. Pola training dan validation loss yang relatif berdekatan menunjukkan bahwa dropout dan early stopping membantu membatasi overfitting pada dataset berukuran sedang. Namun, kurva loss tidak boleh dibaca sebagai bukti profitabilitas karena loss berada pada ruang data yang telah dinormalisasi, sedangkan keputusan finansial memerlukan evaluasi tambahan.

4.3 Perbandingan akurasi prediksi

Pada run detail, GRU unggul pada ketiga metrik akurasi. RMSE turun dari 102,4626 pada LSTM menjadi 82,2814 pada GRU, atau lebih rendah sekitar 19,70%. MAE turun dari 65,0265 menjadi 52,9155, atau sekitar 18,62%. MAPE GRU sebesar 1,3290% lebih rendah daripada LSTM sebesar 1,5705%, sehingga keduanya masuk kategori sangat akurat berdasarkan batas MAPE di bawah 10% yang digunakan dalam skripsi. Secara relatif, MAPE GRU lebih baik sekitar 15,38%.

Hasil ini sejalan dengan studi yang menunjukkan bahwa GRU dapat kompetitif pada aset finansial dan memiliki struktur lebih ringkas (Hamayel & Owda, 2021; Pahlevi et al., 2023). Pada objek emas, efektivitas GRU juga dilaporkan oleh Sudiatmika et al. (2024). Meskipun demikian, klaim keunggulan harus dibatasi pada desain, periode, fitur, dan konfigurasi penelitian ini; tidak berarti GRU selalu lebih baik pada semua instrumen atau kondisi pasar.

Skripsi juga mencantumkan rerata tiga running pada abstrak, yaitu LSTM RMSE 91,7235, MAE 58,1113, MAPE 1,4200% dan GRU RMSE 86,9691, MAE 56,7519, MAPE 1,4273%. Nilai rerata tersebut tidak sepenuhnya sama dengan run detail pada Tabel 3, bahkan pada MAPE rerata LSTM lebih kecil daripada GRU. Perbedaan ini disajikan apa adanya karena rincian setiap running tidak tersedia. Dengan demikian, kesimpulan utama artikel menggunakan run detail yang memiliki tabel lengkap, sedangkan rerata tiga running diperlakukan sebagai laporan tambahan dari skripsi dan bukan sebagai dasar uji statistik.



Gambar 4. Perbandingan prediksi dan harga aktual XAUUSD pada periode uji

Gambar 4 menunjukkan bahwa kedua model mampu mengikuti arah tren umum pada periode pengujian. Prediksi cenderung

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i1

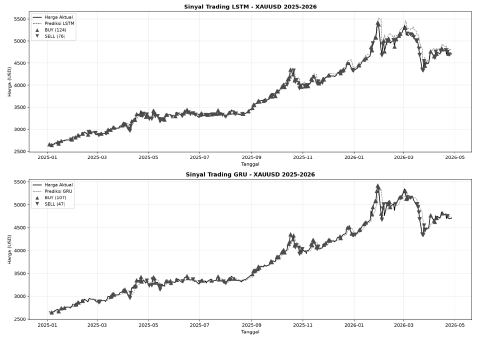
lebih dekat pada fase tren yang relatif stabil dan mengalami keterlambatan ketika terjadi perubahan tajam. Pada periode volatilitas tinggi, LSTM cenderung mengalami overshoot lebih besar, sedangkan GRU lebih dekat terhadap harga aktual pada sebagian besar rentang yang diamati. Pola lagging tetap muncul karena model hanya menerima histori harga Close dan tidak memasukkan berita, suku bunga, indeks dolar, atau variabel fundamental lainnya.

4.4 Pembangkitan dan interpretasi sinyal

Tabel 4. Distribusi sinyal trading pada periode pengujian

Sinyal	LSTM n (%)	GRU n (%)	Interpretasi
BUY	126 (38,2%)	111 (33,6%)	LSTM lebih agresif
SELL	75 (22,7%)	55 (16,7%)	LSTM lebih sering memberi sinyal
HOLD	129 (39,1%)	164 (49,7%)	GRU lebih selektif
Total	330 (100%)	330 (100%)	Hari/sampel sinyal

Dengan threshold ±0,5%, LSTM menghasilkan 126 BUY, 75 SELL, dan 129 HOLD. GRU menghasilkan 111 BUY, 55 SELL, dan 164 HOLD. Perbedaan paling penting terdapat pada HOLD: GRU memberikan 35 sinyal HOLD lebih banyak atau 10,6 poin persentase di atas LSTM. Dalam kerangka SPK, HOLD berarti model tidak menemukan perubahan prediksi yang cukup besar untuk membenarkan rekomendasi entry. Sikap lebih konservatif tersebut dapat membantu mengurangi bad entry, tetapi belum dapat disebut mengurangi kerugian secara empiris karena penelitian tidak melakukan backtesting profit/loss, stop loss, take profit, atau biaya transaksi.



Gambar 5. Sinyal Buy dan Sell dari prediksi LSTM dan GRU

Sebagaimana diperlihatkan pada Gambar 5, sinyal BUY dan SELL mengikuti perubahan prediksi yang melewati threshold, sedangkan area tanpa perubahan cukup besar tidak diberi posisi baru. Visual ini mendukung interpretasi bahwa GRU lebih selektif, bukan membuktikan bahwa seluruh sinyalnya menguntungkan. Validasi finansial tetap membutuhkan target transaksi yang eksplisit, simulasi eksekusi, dan metrik seperti directional accuracy, Sharpe ratio, maximum drawdown, serta expectancy.

4.5 Implikasi, perbandingan, dan keterbatasan

Dari perspektif sistem, penelitian ini menghubungkan tiga lapisan SPK. Lapisan data menyediakan histori harga, lapisan model menghasilkan prediksi numerik, dan lapisan rekomendasi menerjemahkan perubahan prediksi menjadi Buy, Sell, atau Hold. Posisi pengguna tetap sentral karena trader dapat memeriksa support/resistance, tren, kondisi fundamental, dan risk management sebelum mengambil keputusan. Pendekatan ini berbeda dari sistem automated trading berbasis reinforcement learning yang mengeksekusi tindakan secara langsung (Ansari et al., 2022).

Temuan penelitian mendukung studi yang menunjukkan efektivitas deep learning untuk prediksi harga emas maupun valuta asing (Kalami, 2024; Sudiatmika et al., 2024). Pada saat yang sama, penelitian terdahulu juga mengingatkan bahwa arsitektur yang lebih kompleks, hybrid, atau bidirectional tidak otomatis menjamin generalisasi karena hasil bergantung pada objek dan rancangan evaluasi (Seabe et al., 2023; Islam & Hossain, 2021). Oleh karena itu, kontribusi artikel ini diletakkan pada kombinasi komparasi LSTM-GRU, objek XAUUSD, split temporal, dan keluaran sinyal SPK.

Tabel 5. Keterbatasan penelitian dan arah pengembangan

Keterbatasan	Dampak	Arah pengembangan
Hanya fitur Close	Informasi intrahari dan volume tidak digunakan	Uji multivariat OHLCV dan indikator teknikal
Faktor fundamental diabaikan	Respons terhadap berita dapat terlambat	Integrasikan suku bunga, inflasi,

https://doi.org/10.37817/ikraith-informatika.v11i1
P-ISSN : 2580-4316
E-ISSN : 2654-8054

Keterbatasan	Dampak	Arah pengembangan
		DXY, dan sentimen
Threshold statis 0,5%	Tidak adaptif terhadap volatilitas	Gunakan ATR atau threshold dinamis
Uji hanya 16 bulan	Generalisasi lintas rezim belum teruji	Walk-forward dan periode uji yang lebih panjang
Belum ada backtesting	Profitabilitas sinyal belum diketahui	Uji biaya transaksi, SL/TP, Sharpe, drawdown

Keterbatasan tersebut penting agar istilah "sangat akurat" tidak disalahartikan sebagai jaminan keuntungan. MAPE yang kecil hanya menunjukkan kedekatan prediksi harga terhadap nilai aktual pada sampel uji. Untuk menyatakan manfaat trading, penelitian lanjutan harus menghubungkan sinyal dengan aturan posisi, ukuran lot, biaya, slippage, manajemen risiko, dan evaluasi out-of-sample yang bebas dari kebocoran informasi.

4.6 Validitas interpretasi dan reproduksibilitas

Validitas internal penelitian dijaga melalui penggunaan periode data yang sama, urutan preprocessing yang konsisten, arsitektur dasar yang sepadan, serta evaluasi pada data uji yang dipisahkan berdasarkan waktu. Penggunaan split sekuensial lebih sesuai daripada random split karena model prediksi finansial harus diuji pada informasi yang tersedia setelah periode training. Walaupun learning rate, batch size, dan callback berbeda, seluruh perbedaan tersebut dicatat sebagai bagian dari konfigurasi eksperimen dan tidak boleh diabaikan ketika hasil dibandingkan dengan penelitian lain.

Validitas eksternal masih terbatas. Dataset hanya merepresentasikan Gold Futures ticker GC=F dan bukan seluruh variasi kuotasi XAUUSD dari broker. Perbedaan sesi perdagangan, spread, rollover kontrak, dan sumber harga dapat menyebabkan hasil di lingkungan lain berbeda. Selain itu, MAPE relatif mudah dipahami tetapi tidak mengukur arah prediksi, kualitas timing entry, maupun besarnya return. Oleh sebab itu, artikel ini menyimpulkan keunggulan model pada metrik regresi yang dihitung, bukan pada profitabilitas strategi.

Reproduksibilitas dapat ditingkatkan dengan menyimpan snapshot dataset, tanggal pengambilan data, seed random, konfigurasi perangkat keras, log setiap running, dan bobot model. Skripsi telah menyebutkan Google Colaboratory, GPU NVIDIA T4, Python, TensorFlow/Keras, yfinance, NumPy, Pandas, scikit-learn, dan Matplotlib sebagai lingkungan pengembangan. Penelitian lanjutan sebaiknya melaporkan versi pustaka, seed, serta seluruh hasil per-running sehingga rerata, simpangan baku, dan uji statistik dapat dihitung secara transparan.

5. KESIMPULAN

Penelitian ini berhasil mengimplementasikan dan membandingkan LSTM serta GRU untuk prediksi harga penutupan XAUUSD menggunakan data harian GC=F periode 2 Januari 2020–28 April 2026. Dengan preprocessing Close, MinMaxScaler, sliding window 60 hari, dan split temporal 80:20, kedua model dapat mengikuti pola umum harga pada periode pengujian.

Pada run detail yang memiliki tabel lengkap, GRU merupakan model yang lebih unggul dalam akurasi dengan RMSE 82,2814, MAE 52,9155, dan MAPE 1,3290%, sedangkan LSTM menghasilkan RMSE 102,4626, MAE 65,0265, dan MAPE 1,5705%. LSTM tetap lebih efisien dalam waktu training, yaitu 91,90 detik berbanding 156,43 detik. Nilai MAPE keduanya berada di bawah 10%, tetapi interpretasi tersebut terbatas pada akurasi prediksi, bukan kinerja finansial.

Pemetaan perubahan prediksi menggunakan threshold ±0,5% berhasil menghasilkan sinyal Buy, Sell, dan Hold sebagai keluaran SPK. GRU menghasilkan proporsi Hold 49,7%, lebih tinggi dibandingkan LSTM 39,1%, sehingga lebih konservatif dalam merekomendasikan entry. Sistem ini sebaiknya digunakan sebagai alat bantu analisis dan tetap memerlukan validasi teknikal, fundamental, serta manajemen risiko oleh trader. Penelitian selanjutnya perlu menguji fitur multivariat, threshold adaptif, walk-forward validation, dan backtesting finansial.

6. UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Institut Sains & Teknologi TD Pardede Medan, serta para dosen pembimbing dan pihak yang mendukung penyediaan data dan penyelesaian penelitian ini.

DAFTAR PUSTAKA

Althelaya, K. A., El-Alfy, E. S. M., & Mohammed, S. (2021). LSTM-based deep learning model for stock prediction and predictive optimization model. International Journal of Cognitive Computing in Engineering, 2, 1–12. https://doi.org/10.1016/j.ijcce.2021.01.001

Ansari, Y., Yasmin, S., Naz, S., Zaffar, H., Ali, Z., Moon, J., & Rho, S. (2022). A deep reinforcement learning-based decision support system for automated stock market trading. IEEE Access, 10, 93564–93581. https://doi.org/10.1109/ACCESS.2022.3203940

Ayitey Junior, M., Appiahene, P., Appiah, O., & Bombie, C. N. (2023). Forex market forecasting using machine learning: Systematic literature review and meta-analysis. Journal of Big Data, 10(1), 9. https://doi.org/10.1186/s40537-022-00652-w

Bank for International Settlements. (2022). Triennial Central Bank Survey: Foreign exchange turnover in April 2022. https://www.bis.org/statistics/rpfx22_fx.htm

Baranochnikov, I., & Ślepaczuk, R. (2022). A comparison of LSTM and GRU architectures with novel walk-forward approach to algorithmic investment strategy. Working Papers of Faculty of Economic Sciences, University of Warsaw, 21/2022(397).

Hamayel, M. J., & Owda, A. Y. (2021). A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms. AI, 2(4), 477–496. https://doi.org/10.3390/ai2040035

Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. Soft Computing Letters, 3, 100009. https://doi.org/10.1016/j.socl.2021.100009

Kalami, Y. (2024). Comparative analysis of machine learning algorithms in pair currency price prediction in Forex market, particularly in EURUSD and XAUUSD (Gold).

Kobiela, D., Krefta, D., Krol, W., & Weichbroth, P. (2022). A comparison of LSTM and GRU architectures with novel walk-forward approach to algorithmic investment strategy. Working Papers—Faculty of Economic Sciences, University of Warsaw, 2022–21. https://ideas.repec.org/p/war/wpaper/2022-21.html

Liang, Y., Lin, Y., & Lu, Q. (2022). Forecasting gold price using a novel hybrid model with ICEEMDAN and LSTM-CNN-CBAM. Expert Systems with Applications, 206, 117847. https://doi.org/10.1016/j.eswa.2022.117847

Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. Neural Computing and Applications, 32(23), 17351–17360. https://doi.org/10.1007/s00521-020-04867-x

Pahlevi, M. R. (2023). Prediksi harga Forex menggunakan algoritma Long Short-Term Memory. Jnanaloka, 3(2), 69–76. https://doi.org/10.36802/jnanaloka.2022.v3-no2-69-76

Pahlevi, M. R., Kusrini, K., & Hidayat, T. (2023). Comparison of LSTM and GRU models for Forex prediction. Sinkron: Jurnal dan Penelitian Teknik Informatika, 7(4), 2254–2263. https://doi.org/10.33395/sinkron.v8i4.12709

Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: A deep learning approach. Fractal and Fractional, 7(2), 203. https://doi.org/10.3390/fractalfract7020035

Sudiatmika, I. P. G. A., Putra, I. M. A. W., & Artana, W. W. (2024). The implementation of gated recurrent unit (GRU) for gold price prediction using Yahoo Finance data: A case study and analysis.

Yurtesver, S. (2021). Gold price forecasting using LSTM, Bi-LSTM and GRU. European Journal of Science and Technology, 28, 901–908. https://doi.org/10.31590/ejosat.1010777