

**INTEGRASI MACHINE LEARNING DAN OPTIMASI
PORTOFOLIO: TRADE-OFF ANTARA AKURASI PREDIKSI
DAN KINERJA INVESTASI PADA PASAR SAHAM INDONESIA**

Antoni Reynara¹, Rasyad Nauval WardanZ, Intan Naila

Auliana³ Program Studi Manajemen, Fakultas Ekonomi Bisnis,

Universitas Pakuan antonizr45@gmail.com

Abstract

The surge of retail investors in the Indonesian stock market highlights a critical gap between market accessibility and financial literacy, leading to irrational decision-making. While machine learning (ML) models are increasingly adopted to navigate market volatility, high predictive accuracy is often misconstrued as a guarantee of optimal investment returns. This research investigates the empirical trade-off between predictive accuracy and economic performance by comparing a hybrid ML framework (LSTM, XGBoost, and Random Forest) with conventional methods (Markowitz Mean-Variance Optimization and Equal-Weight) in the Indonesian stock market. Using data from highly liquid stocks (LQ45 and IDX80) from 2019 to 2025, the results show that the single XGBoost model achieved the highest economic performance (Sharpe Ratio 0.96; CAGR 29.59%). Conversely, the hybrid framework yielded the lowest prediction error (RMSE 0.0418) but lower nominal returns, confirming a fundamental trade-off between predictive superiority and optimal asset allocation. Robustness analysis proves the integrated hybrid framework maintains positive risk-adjusted returns during highly volatile market crises. This study concludes that ML integration significantly improves investment decisions for novice investors, provided that predictive outputs are systematically synchronized with precise risk management strategies.

Keywords: Machine Learning, Portfolio Optimization, Trade-off, Risk-Adjusted Return, Indonesian Stock Market.

Pendahuluan

Pasar modal Indonesia belakangan ini mencatatkan lonjakan partisipasi investor ritel yang sangat masif. Berdasarkan data Kustodian Sentral Efek Indonesia (KSEI, 2025), jumlah investor meroket melampaui 20 juta jiwa, tumbuh lebih dari 35% hanya dalam kurun waktu satu tahun. Sayangnya, euforia ini tidak berjalan beriringan dengan pemahaman investasi yang matang. Laporan Otoritas Jasa Keuangan (OJK, 2024) mengindikasikan bahwa indeks literasi keuangan nasional masih tertahan di level 49–50%. Kesenjangan tajam antara kemudahan akses pasar dan minimnya literasi ini melahirkan risiko sistemik, di mana investor, terutama

kalangan pemula sangat rentan terjebak dalam pengambilan keputusan yang irasional dan berujung pada kerugian fatal (Lusardi & Mitchell, 2014).

Tantangan ini semakin berat di tengah kondisi pasar saham yang kian volatil dan sulit ditebak. Indikator ketidakpastian global seperti *CBOE Volatility Index* (VIX) kerap menunjukkan fluktuasi tajam yang merepresentasikan dinamika pasar modern yang non-linear. Menghadapi situasi ini, pendekatan investasi tradisional seperti *Mean-Variance Optimization* (Markowitz, 1952) dan Hipotesis Pasar Efisien (Fama, 1970) terbukti semakin lambat dan kurang responsif dalam memitigasi risiko (Malkiel, 2003; Lo, 2004). Oleh sebab itu, inovasi teknologi komputasi berbasis *machine learning*, seperti *Long Short-Term Memory* (LSTM), XGBoost, dan *Random Forest*, mulai diadopsi secara luas karena keunggulannya dalam memetakan pola pergerakan harga yang kompleks dan dinamis.

Meski begitu, tingginya akurasi prediksi sebuah algoritma sering kali disalahartikan sebagai jaminan pasti atas tingginya keuntungan investasi. Padahal, eksekusi portofolio di dunia nyata sangat bergantung pada kualitas sinkronisasi antara proyeksi *return* dan manajemen risiko alokasi aset (Kolm *et al.*, 2021). Hal ini memunculkan sebuah celah penelitian yang krusial: sebagian besar literatur berasumsi bahwa minimasi *error* prediksi otomatis akan mendongkrak profitabilitas secara linear, tanpa membuktikannya secara empiris pada ekosistem pasar berkembang seperti Indonesia.

Penelitian ini hadir untuk membedah kesenjangan tersebut melalui studi komparatif mendalam. Alih-alih hanya berfokus pada angka akurasi model, penelitian ini merancang kerangka kerja terintegrasi yang menggabungkan kapabilitas prediktif *framework hybrid* (LSTM, XGBoost, dan *Random Forest*) langsung dengan proses optimasi portofolio. Pendekatan holistik ini bertujuan untuk membuktikan apakah superioritas algoritma AI benar-benar mampu menciptakan nilai tambah ekonomis yang nyata, atau justru menciptakan fenomena *trade-off* antara ketepatan proyeksi dan efisiensi kinerja portofolio investasi akhir.

Berdasarkan latar belakang tersebut, penelitian ini difokuskan untuk menjawab pertanyaan berikut:

1. Apakah implementasi *framework machine learning* mampu menghasilkan kinerja ekonomi portofolio yang lebih superior dibandingkan metode optimasi konvensional di pasar saham Indonesia?
2. Apakah tingkat akurasi prediksi model berbanding lurus dengan pencapaian metrik *risk-adjusted return*, atau justru memunculkan fenomena *trade-off* tanpa implikasi investasi yang nyata?
3. Sejauh mana integrasi antara model prediktif adaptif dan strategi optimasi portofolio mampu menjaga stabilitas (*robustness*) investasi di tengah volatilitas pasar?

Selaras dengan permasalahan yang dirumuskan, penelitian ini bertujuan untuk:

1. Mengkomparasikan secara empiris efektivitas kinerja portofolio antara sistem *machine learning* terintegrasi dan pendekatan MVO konvensional pada saham berlikuiditas tinggi di Indonesia.
2. Membedah fenomena *trade-off* antara tingginya akurasi prediksi algoritma dengan realisasi kinerja keuangan portofolio guna memvalidasi asumsi literatur terdahulu.
3. Membangun arsitektur *decision support system* yang mengawinkan proses prediksi *hybrid machine learning* dan alokasi aset untuk rekomendasi investasi yang lebih stabil bagi investor pemula.

Penelitian ini membawa sejumlah kontribusi kebaruan (*novelty*) yang membedakannya dari studi-studi terdahulu, yakni:

1. Pergeseran Paradigma Evaluasi: Menggeser tolok ukur kesuksesan model AI dari sekadar metrik kesalahan statistik (RMSE/MAE) menuju pembuktian nilai ekonomis riil (*Sharpe Ratio*, CAGR, MDD).
2. Arsitektur Terintegrasi: Menyatukan deteksi pola temporal (LSTM) dan pola non-linear (*ensemble tree*) yang dihubungkan langsung ke dalam algoritma optimasi bobot Markowitz, dilengkapi sistem *signal filtering* berbasis persentil.

3. Pembuktian Empiris Fenomena *Trade-off*: Menyajikan analisis faktual di pasar modal Indonesia mengenai jurang pemisah antara kualitas prediktif sebuah mesin dengan kualitas pengelolaan risiko ekonomisnya.

Tinjauan Pustaka dan Penelitian Terdahulu

Teori Portofolio dan Keterbatasan Pendekatan Konvensional

Keputusan investasi sejatinya bermuara pada keseimbangan antara risiko dan imbal hasil. Teori portofolio modern dari Markowitz (1952) menggarisbawahi peran diversifikasi melalui *Mean-Variance Optimization* (MVO) dengan asumsi investor rasional. Sementara itu, *Efficient Market Hypothesis* (EMH) oleh Fama (1970) beranggapan bahwa harga aset memuat semua informasi pasar. Namun, Malkiel (2003) dan Lo (2004) melalui *Adaptive Market Hypothesis* (AMH) membuktikan bahwa pasar tidak pernah sepenuhnya efisien dan terus beradaptasi, sehingga metode konvensional kerap lambat dan kurang responsif terhadap dinamika *non-linear*.

Machine Learning dalam Prediksi Keuangan dan *Trade-off*

Kinerja Pemanfaatan *machine learning* menawarkan solusi adaptif untuk memproyeksikan pergerakan harga saham melalui pemetaan pola *non-linear*. LSTM (Hochreiter & Schmidhuber, 1997) sangat piawai memproses dependensi jangka panjang pada data *time series*, sedangkan XGBoost (Chen & Guestrin, 2016) dan *Random Forest* (Breiman, 2001) efektif membedah interaksi kompleks antar variabel. Fischer dan Krauss (2018) serta Gu, Kelly, dan Xiu (2020) menegaskan bahwa model *machine learning* secara konsisten melampaui akurasi metode tradisional. Namun, Kolm *et al.* (2021) menyoroti adanya jurang nyata antara kehebatan prediktif model dengan efektivitas aplikasinya di pasar: algoritma dengan RMSE sangat rendah sekalipun bisa gagal mencetak keuntungan optimal jika tidak dirangkai ke dalam strategi alokasi aset yang presisi. Kinerja integrasi ini wajib dievaluasi menggunakan metrik *risk-adjusted return* seperti *Sharpe Ratio* (Sharpe, 1994), *Sortino Ratio* (Sortino & Price, 1994), MDD, dan CAGR.

Konteks Investor Pemula dan Kesenjangan Penelitian

Investor individu, khususnya pemula, kerap rentan terhadap bias pengambilan keputusan akibat literasi keuangan terbatas (Lusardi & Mitchell, 2014). Kondisi ini semakin menuntut hadirnya kerangka keputusan berbasis data.

Letak kesenjangan penelitian utama: sebagian besar studi terdahulu hanya berfokus pada minimalisasi *error* tanpa menguji implikasi ekonomisnya secara langsung. Penelitian ini hadir menjembatani celah tersebut dengan mengevaluasi secara empiris apakah integrasi model *hybrid* benar-benar menghasilkan *trade-off* keputusan investasi yang lebih tangguh (*robust*) di tengah volatilitas pasar saham Indonesia.

Pengembangan Hipotesis

Machine Learning Tunggal vs Metode Konvensional

Metode konvensional seperti MVO klasik dan *equal-weight portfolio* (DeMiguel, Garlappi, & Uppal, 2009) sangat bergantung pada data historis tanpa kemampuan prediksi adaptif, sehingga kurang optimal merespons dinamika *non-linear* pasar modern. Sebaliknya, model *machine learning* tunggal seperti XGBoost memiliki keunggulan dalam memetakan interaksi kompleks antar fitur teknis dan makroekonomi, menghasilkan estimasi *expected return* yang lebih presisi untuk keputusan alokasi aset yang lebih tangguh.

H1: Model *machine learning* tunggal (XGBoost) mampu menghasilkan kinerja portofolio investasi yang secara signifikan lebih tinggi dibandingkan metode konvensional (MVO Klasik dan *Equal-Weight Portfolio*), yang diukur melalui *Sharpe Ratio*, *Sortino Ratio*, *Maximum Drawdown*, dan CAGR.

Framework Hybrid vs *Machine Learning* Tunggal

Model *machine learning* tunggal memiliki keterbatasan dalam merekam dependensi temporal jangka panjang dan menjaga stabilitas prediksi. *Framework hybrid* yang mengintegrasikan LSTM untuk menangkap pola temporal sekuensial, dikombinasikan dengan XGBoost dan *Random Forest* melalui skema *weighted ensemble* serta mekanisme *signal filtering* berbasis persentil, dirancang untuk meminimalkan bias prediksi secara lebih komprehensif.

H2: *Framework hybrid machine learning* (LSTM, XGBoost, dan *Random Forest*) menghasilkan tingkat akurasi prediksi yang lebih tinggi (RMSE dan MAE lebih rendah) serta kinerja portofolio investasi yang lebih baik secara signifikan dibandingkan model *machine learning* tunggal.

Stabilitas dan *Robustness Framework Hybrid*

Keunggulan suatu pemodelan investasi tidak dapat hanya dinilai pada kondisi

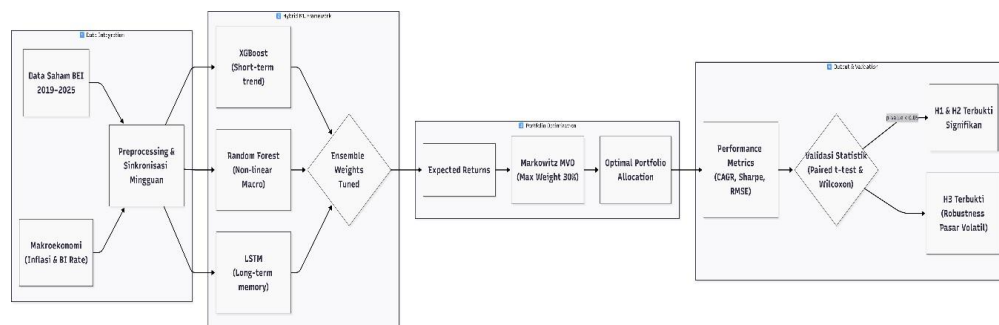
pasar normal. Pasar saham Indonesia, sebagai representasi *emerging market*, memiliki karakteristik volatilitas sangat tinggi dan sensitivitas kuat terhadap gejolak makroekonomi. Pengujian stabilitas (*robustness*) pada berbagai skenario pasar sangat esensial untuk memvalidasi konsistensi keandalan *framework hybrid*.

H3: *Framework hybrid machine learning* menunjukkan kinerja yang stabil dan *robust* pada berbagai kondisi pasar (volatil maupun stabil) di pasar saham Indonesia, yang dibuktikan dengan tidak adanya penurunan signifikan pada metrik *Sharpe Ratio*, *Sortino Ratio*, dan *Maximum Drawdown*.

Metode Penelitian

Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif komparatif yang membandingkan kinerja portofolio saham antara pendekatan berbasis *machine learning* dan metode konvensional. Fokus penelitian tidak hanya pada akurasi prediksi, melainkan pada kinerja portofolio secara ekonomis melalui pengukuran *risk-adjusted return*. Penelitian dilaksanakan pada pasar saham Indonesia sebagai representasi *emerging market* yang dicirikan oleh volatilitas tinggi dan sensitivitas terhadap faktor makroekonomi domestik, sehingga menjadi konteks yang relevan untuk menguji efektivitas kedua pendekatan bagi investor pemula. Alur rancangan penelitian dari integrasi data hingga validasi statistik dapat dilihat pada Gambar 1 berikut.



Gambar 1. Rancangan Arsitektur Hybrid Portfolio Optimization.

Populasi dan Sampel

Populasi penelitian adalah seluruh saham yang tercatat di Bursa Efek Indonesia (BEI) pada periode Januari 2019 hingga Desember 2025. Pemilihan sampel dilakukan secara *purposive sampling* dengan tiga kriteria: (1) terdaftar secara konsisten di BEI tanpa *delisting* selama periode pengamatan; (2) masuk

dalam indeks LQ45 atau IDX80 minimal empat periode penilaian; dan (3) memiliki data harga dan volume perdagangan yang lengkap. Kriteria ini menjamin likuiditas instrumen sekaligus relevansinya bagi profil risiko investor pemula.

Sumber dan Jenis Data

Data yang digunakan bersifat sekunder, bersumber dari Yahoo Finance dan situs resmi BEI untuk data harga saham harian (*Open, High, Low, Close, Volume*), serta dari Bank Indonesia (BI) dan Badan Pusat Statistik (BPS) untuk data makroekonomi mencakup *BI Rate*, inflasi, dan nilai tukar USD/IDR. Data diolah dalam format *time series* harian dan diagregasi menjadi data mingguan untuk mereduksi *noise* tanpa kehilangan informasi tren jangka menengah.

Teknik Pengolahan Data

Data mentah diproses melalui empat tahap secara kronologis. Tahap pertama adalah pembersihan data, meliputi penanganan nilai kosong menggunakan *forward filling* dan penanganan *outlier* melalui *winsorizing*. Tahap kedua adalah transformasi data, yakni perhitungan *log return* untuk memenuhi asumsi normalitas.

$$R_t = \ln(P_t / P_{t-1})$$

Tahap ketiga adalah normalisasi fitur menggunakan *Min-Max Scaling* khusus untuk input model *machine learning*. Tahap keempat adalah rekayasa fitur (*feature engineering*), mencakup indikator teknikal (MA, RSI, MACD, *historical volatility*), fitur berbasis pasar (*return IHSG*, perubahan volume), fitur makroekonomi, serta fitur temporal berupa *lag return* (t-1, t-5, t-10). Seluruh proses menggunakan Python dengan pustaka *pandas*, *NumPy*, dan *scikit-learn*.

Pengembangan Model

Penelitian mengembangkan *framework hybrid machine learning* dengan arsitektur berurutan. LSTM digunakan untuk menangkap dependensi temporal jangka panjang dan menghasilkan *temporal embedding* yang menjadi fitur tambahan bagi model tabular. XGBoost dan *Random Forest* kemudian digunakan untuk memodelkan hubungan *non-linear* antar fitur dan memprediksi *expected return* saham. Prediksi dari kedua model digabungkan melalui metode *weighted ensemble* dengan bobot optimal ditentukan melalui *grid search* pada data validasi.

Selanjutnya diterapkan mekanisme *signal filtering* berbasis *threshold* untuk mengeliminasi saham dengan prediksi *return* di bawah nilai ambang, menggunakan persentil tertentu (*top 30% return* prediksi) agar hanya saham berpotensi tinggi yang dipilih.

$$\hat{R}D = w_1 R_XGB + w_2 R_RF, \quad w_1 + w_2 = 1$$

Optimasi Portofolio

Optimasi portofolio dilakukan menggunakan pendekatan *Mean-Variance Optimization* (MVO) dalam kerangka *Modern Portfolio Theory* Markowitz, dengan memaksimalkan rasio Sharpe sebagai fungsi tujuan. Input optimasi meliputi prediksi *expected return* dari model dan matriks kovarians antar aset yang diestimasi menggunakan *shrinkage estimator* untuk meningkatkan kestabilan numerik. Kendala yang diberlakukan adalah larangan *short selling* dan batas maksimum bobot per aset guna mencerminkan kondisi investasi yang realistis bagi investor pemula. Simulasi *Monte Carlo* dengan 10.000 iterasi digunakan untuk memetakan *efficient frontier* dan mengidentifikasi portofolio dengan rasio Sharpe maksimum sebagai solusi optimal.

$$Sharpe = (E(R_p) - R^i) / \sigma_p$$

Validasi dan Evaluasi Model

Validasi model dilakukan melalui tiga pendekatan. Pertama, pembagian data *train-test* dengan proporsi 70:30 (2019–2023 sebagai data latih; 2024–2025 sebagai data uji). Kedua, *walk-forward validation* untuk mensimulasikan kondisi *real-time* pengambilan keputusan. Ketiga, *backtesting* yang memperhitungkan biaya transaksi, *slippage*, dan *rebalancing* adaptif. Evaluasi kinerja portofolio menggunakan empat metrik: *Sharpe Ratio*, *Sortino Ratio*, *Maximum Drawdown* (MDD), dan CAGR relatif terhadap IHSG sebagai *benchmark*. Pengujian statistik menggunakan *paired t-test* dan uji Wilcoxon *signed-rank* untuk menguji signifikansi perbedaan kinerja antar pendekatan.

$$Sortino = (E(R_p) - R^i) / \sigma_a$$

$$MDD = \max[(Peak_t - Trough_t) / Peak_t] \quad CAGR = (V_akhir / V_awal)^{(1/n)} - 1$$

Evaluasi Akurasi Prediksi

Akurasi prediksi model dievaluasi menggunakan dua metrik utama.

Pertama, *Root Mean Square Error* (RMSE) yang sensitif terhadap kesalahan ekstrem dalam prediksi *return*. Kedua, *Mean Absolute Error* (MAE) yang memberikan gambaran umum kesalahan model tanpa penalti tambahan. Kedua metrik digunakan untuk membandingkan akurasi prediksi antara *framework hybrid* dan metode konvensional, serta menguji hubungan antara akurasi prediksi dan kinerja portofolio yang dihasilkan.

$$RMSE = \sqrt{1/4 \sum (\hat{y}_i - y_i)^2} \quad MAE = 1/4 \sum |\hat{y}_i - y_i|$$

Model Pemandangan (*Benchmark*)

Untuk mengevaluasi efektivitas *framework hybrid*, kinerja dibandingkan dengan tiga metode *benchmark*: (1) Markowitz MVO klasik menggunakan *return* historis tanpa model prediktif; (2) *equal-weight portfolio* dengan alokasi merata tanpa pertimbangan *return* atau risiko; dan (3) model tunggal XGBoost tanpa integrasi LSTM dan *Random Forest*. Seluruh metode dievaluasi menggunakan metrik yang sama (*Sharpe Ratio*, *Sortino Ratio*, MDD, CAGR) pada periode pengujian yang identik.

Out-of-Sample Testing dan *Robustness Analysis*

Out-of-sample testing menggunakan data 2024–2025 yang sepenuhnya dipisahkan dari proses pelatihan dan validasi. *Robustness analysis* menguji kestabilan model pada tiga skenario: (1) kondisi pasar volatil—periode pandemi COVID-19 (2020–2022) dengan fluktuasi tinggi; (2) kondisi pasar stabil (2023–2025); dan (3) variasi *hyperparameter model*. Pengujian ini menjadi pembeda penelitian ini dibandingkan studi *machine learning* konvensional, sekaligus memperkuat validitas temuan pada konteks pasar berkembang.

Hasil dan Pembahasan

Hasil Pengolahan Data

Pada bagian ini disajikan hasil simulasi *backtesting* dan pengujian *out-of-sample* pada periode 2024 hingga akhir 2025. Evaluasi dilakukan pada tiga aspek utama: akurasi prediksi, kinerja portofolio investasi, serta stabilitas model.

Evaluasi Akurasi Prediksi Model

Evaluasi kesalahan prediksi diukur menggunakan RMSE dan MAE. *Framework hybrid* yang menggabungkan LSTM, XGBoost, dan *Random Forest* mencatatkan tingkat kesalahan lebih rendah, yaitu RMSE 0,0418 dan MAE 0,0303. Hasil ini lebih baik dibandingkan model *machine learning* tunggal

(XGBoost) dengan RMSE 0,0427 dan MAE 0,0310, membuktikan keunggulan arsitektur *ensemble* dalam mereduksi *error* prediksi.

Kinerja Akhir Portofolio dan Simulasi Investasi

Kinerja ekonomi portofolio diukur melalui CAGR, Maximum Drawdown, dan Sharpe Ratio. Hasil pengujian menunjukkan bahwa pendekatan machine learning secara umum mengungguli metode konvensional:

1. MVO_XGBoost (Model Tunggal): Kinerja tertinggi dengan CAGR 29,59%, Maximum Drawdown -26,11%, dan Sharpe Ratio 0,96.
2. MVO_Hybrid (Framework Hybrid): CAGR 23,08%, Maximum Drawdown -27,46%, dan Sharpe Ratio 0,74.
3. Equal_Weight (Konvensional): CAGR 4,98%, Maximum Drawdown -25,60%, dan Sharpe Ratio 0,09.
4. MVO_Klasik (Konvensional): Kinerja terburuk dengan CAGR -6,05%, Maximum Drawdown -26,64%, dan Sharpe Ratio -0,42.



Proses optimasi MVO pada framework hybrid merekomendasikan alokasi bobot final pada saham-saham unggulan guna memaksimalkan rasio Sharpe. Alokasi terbesar diberikan pada TLKM.JK sebesar 30,0%, disusul BBCA.JK (23,21%), UNTR.JK (17,41%), ICBP.JK (10,67%), KLBF.JK (7,9%), SMGR.JK (7,46%), BBRI.JK (1,96%), dan PTBA.JK (1,39%). Saham lainnya dialokasikan bobot 0,0%.

Tabel 1. Bobot Portofolio Alokasi Optimal (Framework Hybrid).

Kode Saham	Bobot Alokasi (%)
TLKM.JK	30,00
BBCA.JK	23,21
UNTR.JK	17,41
ICBP.JK	10,67
KLBF.JK	7,90

SMGR.JK	7,46
BBRI.JK	1,96
PTBA.JK	1,39
INDF.JK	0,00
BMRI.JK	0,00
ASII.JK	0,00
BBNI.JK	0,00
ADRO.JK	0,00
INTP.JK	0,00
PGAS.JK	0,00
UNVR.JK	0,00

Analisis Stabilitas (Robustness)

Untuk menguji keandalan model pada kondisi pasar fluktuatif, dilakukan robustness analysis terhadap framework hybrid. Periode krisis pandemi COVID-19 (2020–2022) ditetapkan sebagai representasi kondisi pasar volatil, sedangkan periode pemulihan (2023–2025) sebagai kondisi pasar stabil. Hasilnya menunjukkan bahwa pada kondisi pasar stabil, portofolio mampu mencetak Sharpe Ratio 1,39 dan Sortino Ratio 2,15. Saat menghadapi kondisi volatil, performa menurun namun tetap berada pada nilai positif, dengan Sharpe Ratio 0,47 dan Sortino Ratio 0,68.

Pembahasan

3.1.1 Pengujian Hipotesis 1: Keunggulan Machine Learning Tunggal vs Konvensional

Hasil penelitian secara meyakinkan menerima Hipotesis 1. Model XGBoost terbukti menghasilkan kinerja portofolio signifikan lebih tinggi dibandingkan metode konvensional, dibuktikan oleh lompatan Sharpe Ratio dari -0,42 (MVO Klasik) menjadi 0,96 (XGBoost). Keunggulan ini divalidasi melalui paired t-test ($p\text{-value} = 0,02132$) dan uji Wilcoxon ($p\text{-value} = 0,02589$), keduanya di bawah batas signifikansi $p < 0,05$. Temuan ini sejalan dengan argumentasi bahwa pendekatan konvensional yang bergantung pada stabilitas data historis memiliki keterbatasan dalam menghadapi dinamika pasar non-linear. Algoritma XGBoost mampu menangkap hubungan kompleks antar variabel secara lebih efektif, menghasilkan keputusan alokasi yang lebih adaptif.

Pengujian Hipotesis 2: Akurasi Prediksi vs Risk-Adjusted Return

Pengujian Hipotesis 2 memberikan temuan yang sangat menarik. Meskipun framework hybrid terbukti meningkatkan akurasi prediksi (RMSE 0,0418; MAE

0,0303), tingkat akurasi tersebut tidak selaras dengan peningkatan kinerja akhir portofolio secara nominal. Sharpe Ratio dan CAGR pada Hybrid (0,74 dan 23,08%) tercatat lebih rendah dibandingkan XGBoost tunggal (0,96 dan 29,59%). Namun demikian, peningkatan akurasi prediksi ini menunjukkan bahwa framework hybrid mampu menghasilkan trade-off yang lebih optimal antara return dan risiko melalui integrasi pola temporal dan non-linear yang lebih komprehensif. Meskipun kinerjanya secara nominal di bawah model tunggal, kinerja framework hybrid tetap terbukti secara statistik jauh lebih unggul dibandingkan MVO Klasik (paired t-test $p = 0,03611$; Wilcoxon $p = 0,03534$), mengonfirmasi pernyataan Kolm et al. (2021) bahwa superioritas prediktif harus diimbangi sinkronisasi manajemen risiko yang presisi.

Pengujian Hipotesis 3: Konsistensi pada Kondisi Pasar Berkembang

Melalui uji robustness, penelitian ini membuktikan bahwa framework hybrid mampu menjaga Sharpe Ratio dan Sortino Ratio tetap positif (0,47 dan 0,68) meskipun diterpa kondisi pasar sangat volatil. Temuan ini menerima Hipotesis 3, menyatakan bahwa sistem machine learning terintegrasi tidak hanya memberikan keunggulan di masa pasar stabil, namun memiliki kapabilitas manajemen risiko downside yang cukup solid (robust) saat terjadi gejolak pasar.

Simpulan

Penelitian ini bertujuan untuk menguji efektivitas pendekatan machine learning dalam meningkatkan kinerja portofolio investasi dibandingkan metode konvensional, sekaligus mengevaluasi hubungan antara akurasi prediksi dan kinerja investasi di pasar saham Indonesia. Hasil analisis menunjukkan bahwa pendekatan berbasis machine learning mampu menghasilkan kinerja portofolio yang lebih optimal. Model *XGBoost* sebagai representasi machine learning tunggal menghasilkan *Sharpe Ratio* dan *CAGR* tertinggi dibandingkan MVO Klasik maupun *equal-weight portfolio*, menegaskan keterbatasan pendekatan konvensional dalam dinamika *non-linear* pasar yang dibahas dalam teori *Adaptive Market Hypothesis*.

Penelitian ini juga menemukan bahwa peningkatan akurasi prediksi tidak secara langsung berbanding lurus dengan peningkatan kinerja portofolio. Walaupun *framework hybrid* menghasilkan RMSE dan MAE lebih rendah, kinerja portofolio nominalnya tidak melampaui model *machine learning* tunggal. Hal ini menunjukkan adanya perbedaan antara kemampuan prediktif model dengan implementasi keputusan investasi, sehingga mengonfirmasi bahwa akurasi prediksi bukan satu-satunya faktor penentu keberhasilan strategi investasi.

Integrasi antara model prediktif dan optimasi portofolio dalam *framework hybrid* terbukti menghasilkan kinerja yang lebih stabil dan robust pada kondisi pasar volatil. Hasil *robustness analysis* menunjukkan bahwa model mampu mempertahankan *Sharpe Ratio* dan *Sortino Ratio* pada nilai positif, menunjukkan kemampuan adaptasi terhadap perubahan kondisi pasar yang menjadi karakteristik utama *emerging market* seperti Indonesia. Efektivitas *machine learning* bergantung pada bagaimana hasil prediksi diintegrasikan ke dalam proses optimasi portofolio dan manajemen risiko.

Implikasi Penelitian

Implikasi Teoretis

Penelitian ini memberikan kontribusi penting dalam pengembangan literatur keuangan, khususnya terkait hubungan antara akurasi prediksi dan kinerja portofolio. Hasil bahwa peningkatan akurasi tidak selalu menghasilkan peningkatan kinerja investasi mematahkan asumsi implisit dalam banyak penelitian sebelumnya yang menyamakan superioritas prediktif dengan superioritas ekonomis. Penelitian ini juga memperkuat relevansi *Adaptive Market Hypothesis* dan memberikan kontribusi konseptual melalui pengembangan

framework terintegrasi yang mengurangi fragmentasi antara tahap analisis dan implementasi investasi.

Implikasi Praktis

Bagi investor pemula di pasar saham Indonesia, penggunaan model machine learning dapat membantu meningkatkan kualitas pengambilan keputusan investasi dengan menyediakan estimasi return yang lebih adaptif. Hal ini sangat relevan mengingat rendahnya tingkat literasi keuangan yang masih menjadi tantangan utama. Penelitian ini juga menekankan bahwa investor tidak seharusnya hanya berfokus pada akurasi prediksi, melainkan perlu memberikan perhatian lebih besar pada cara hasil prediksi diterjemahkan ke dalam strategi alokasi aset dan manajemen risiko. Framework hybrid yang dikembangkan dapat dijadikan dasar pengembangan sistem decision support atau robo-advisor yang sistematis dan berbasis data, membantu investor mengurangi bias emosional dan meningkatkan konsistensi pengambilan keputusan investasi.

Implikasi Kebijakan

Dalam perspektif kebijakan, hasil penelitian ini memberikan masukan bagi regulator bahwa peningkatan akses investasi yang tidak diiringi literasi keuangan berpotensi meningkatkan risiko kerugian bagi investor individu. Diperlukan kebijakan yang tidak hanya mendorong inklusi keuangan, tetapi juga meningkatkan kualitas edukasi investasi berbasis data. Regulator dapat mempertimbangkan pengembangan ekosistem teknologi keuangan yang mendukung penggunaan artificial intelligence dan machine learning secara bertanggung jawab, termasuk pengawasan robo-advisor. Transparansi dalam penggunaan model prediktif sangat penting agar investor memahami bahwa akurasi tinggi tidak selalu menjamin hasil investasi yang optimal.

Keterbatasan Penelitian

Meskipun telah dirancang secara sistematis, terdapat beberapa keterbatasan yang perlu diperhatikan:

1. Penelitian hanya menggunakan sampel saham likuiditas tinggi (LQ45 dan IDX80), sehingga hasil tidak sepenuhnya merepresentasikan seluruh kondisi pasar saham Indonesia, khususnya saham dengan kapitalisasi kecil.
2. Model terbatas pada kombinasi LSTM, XGBoost, dan Random Forest. Masih terdapat berbagai algoritma lain yang berpotensi memberikan hasil berbeda, seperti Transformer atau Deep Reinforcement Learning.
3. Asumsi biaya transaksi, slippage, dan rebalancing dalam backtesting masih

menggunakan pendekatan yang disederhanakan; dalam praktik nyata, faktor-faktor tersebut dapat berdampak lebih besar.

4. Periode penelitian, meskipun mencakup kondisi pasar volatil dan stabil, masih terbatas sehingga belum sepenuhnya mencerminkan siklus pasar jangka panjang.

4.1 Rekomendasi Penelitian Selanjutnya

Sebagai tindak lanjut dari keterbatasan yang ada, penelitian selanjutnya disarankan untuk:

1. Memperluas cakupan sampel dengan memasukkan saham berkapitalisasi kecil dan sektor yang lebih beragam.
2. Mengembangkan model yang lebih kompleks seperti deep learning berbasis Transformer atau pendekatan reinforcement learning dalam optimasi portofolio.
3. Mengintegrasikan metode optimasi portofolio alternatif seperti Black-Litterman atau Conditional Value at Risk (CVaR).
4. Menggunakan data frekuensi lebih tinggi (intraday) untuk menangkap dinamika pasar yang lebih detail.
5. Mengembangkan sistem implementasi real-time yang dapat diuji langsung dalam kondisi pasar aktual (live trading simulation).

Daftar Pustaka

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. Dalam *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (hlm. 785-794). Association for Computing Machinery.
- DeMiguel, V., Garlappi, L., & Uppal, R. (2009). Optimal Versus Naive Diversification: How Inefficient is the 1/N Portfolio Strategy? *The Review of Financial Studies*, 22(5), 1915-1953.
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- Kolm, P. N., Ritter, G., & Simonian, J. (2021). Black Litterman and beyond: The Bayesian paradigm in investment management. *The Journal of Portfolio Management*, 47(5), 97-113.
- Kustodian Sentral Efek Indonesia (KSEI). (2025). *Statistik Pasar Modal Indonesia: Desember 2025*. PT Kustodian Sentral Efek Indonesia.

- Lo, A. W. (2004). The Adaptive Markets Hypothesis: Market Efficiency from an Evolutionary Perspective. *Journal of Portfolio Management*, 30(5), 15-29.
- Lusardi, A., & Mitchell, O. S. (2014). The Economic Importance of Financial Literacy: Theory and Evidence. *Journal of Economic Literature*, 52(1), 5-44.
- Malkiel, B. G. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic Perspectives*, 17(1), 59-82.
- Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91.
- Otoritas Jasa Keuangan (OJK). (2024). *Survei Nasional Literasi dan Inklusi Keuangan (SNLIK) Tahun 2024*. Otoritas Jasa Keuangan Republik Indonesia.
- Sharpe, W. F. (1994). The Sharpe Ratio. *The Journal of Portfolio Management*, 21(1), 49-58.
- Sortino, F. A., & Price, L. N. (1994). Performance Measurement in a Downside Risk Framework. *The Journal of Investing*, 3(3), 59-64.