

Penerapan Algoritma LSTM dalam Memprediksi Volatilitas Harga Saham Sektor Teknologi di Bursa Efek Indonesia

Alia Anjani¹, Inayati Al Mawawaddah^{1,*}, Juwita Nuraini Panjaitan¹, Imam Saputra²

¹Program Studi Manajemen, Sekolah Tinggi Ilmu Manajemen Sukma, Medan, Indonesia

²Program Studi Bisnis Digital, Sekolah Tinggi Ilmu Manajemen Sukma, Medan, Indonesia

Email: ¹alyaanjani456@gmail, ²*inayatilmawawaddah@gmail.com, ³wwitaaa2006@gmail.com, ⁴saputraimam69@gmail.com

(* : coresponding author)

Abstrak

Penelitian ini bertujuan untuk mengevaluasi efisiensi dan akurasi algoritma *Long Short-Term Memory* (LSTM) dalam memprediksi volatilitas harga saham sektor teknologi di Bursa Efek Indonesia (BEI). Menggunakan data historis harian PT GoTo Gojek Tokopedia Tbk (GOTO.JK) periode 2023–2026, penelitian eksperimental ini menerapkan arsitektur *Stacked LSTM* untuk menangkap karakteristik data finansial yang bersifat non-linear dan memiliki ekor gemuk (*heavy-tailed*). Pra-pemrosesan data dilakukan melalui penghitungan *log return*, *rolling standard deviation* 21 hari, dan normalisasi *Min-Max Scaling*. Hasil eksperimen menunjukkan bahwa model *Stacked LSTM* dengan regularisasi *Dropout* ganda sebesar 20% mampu mengalami konvergensi yang ideal tanpa mengalami *overfitting*. Model ini mencatatkan performa prediktif yang superior dengan nilai *Root Mean Squared Error* (RMSE) yang sangat minimal, yaitu sebesar 0,00282. Analisis visual membuktikan ketangkasan model dalam mereplikasi tren volatilitas aktual serta mendeteksi sinyal pembalikan arah secara presisi. Secara praktis, akurasi ini berimplikasi penting bagi manajer investasi dalam mitigasi risiko portofolio dan bagi regulator sebagai sistem peringatan dini bursa.

Kata Kunci: Volatilitas Saham, Sektor Teknologi, Bursa Efek Indonesia, Stacked LSTM, Manajemen Risiko

1. PENDAHULUAN

Pasar modal memiliki peran yang sangat strategis dalam mendorong pertumbuhan ekonomi suatu negara melalui alokasi sumber daya finansial yang efisien [1]. Dinamika yang terjadi di dalam pasar modal mencerminkan berbagai ekspektasi, sentimen, dan reaksi para pelaku pasar terhadap informasi ekonomi global maupun domestik [2]. Volatilitas tidak hanya mencerminkan derajat ketidakpastian pergerakan harga, tetapi juga menjadi proksi utama dalam pengukuran risiko investasi finansial [3]. Pemahaman yang mendalam mengenai karakteristik volatilitas sangat krusial karena fluktuasi yang terlalu tajam dapat memicu instabilitas pasar secara sistemik [4]. Oleh karena itu, kemampuan untuk memodelkan dan memprediksi volatilitas menjadi komoditas intelektual yang sangat bernilai dalam dunia keuangan modern [5]. Banyak keputusan strategis seperti lindung nilai (*hedging*), penentuan harga opsi (*options pricing*), dan manajemen risiko Value at Risk (VaR) sangat bergantung pada akurasi estimasi volatilitas ini [6]. Namun, sifat dasar pasar keuangan yang kompleks membuat estimasi volatilitas selalu menghadapi tantangan metodologis yang besar [7]. Ketidakpastian global yang meningkat dalam beberapa tahun terakhir semakin memperumit pola pergerakan aset finansial di berbagai belahan dunia [8]. Akibatnya, studi mengenai prediksi volatilitas tetap menjadi topik yang relevan, dinamis, dan terus berkembang di kalangan akademisi serta praktisi keuangan [9].

Dalam konteks pasar modal Indonesia, Bursa Efek Indonesia (BEI) menunjukkan perkembangan yang sangat signifikan dengan kontribusi dari berbagai sektor industri baru [10]. Salah satu sektor yang paling menarik perhatian publik dan memicu volume perdagangan besar dalam beberapa tahun terakhir adalah sektor teknologi [11]. Saham-saham di sektor teknologi dinilai memiliki karakteristik pertumbuhan yang tinggi (*high growth potential*) namun diiringi dengan tingkat risiko yang juga sangat besar (*high risk*) [12]. Karakteristik unik ini disebabkan oleh ketergantungan sektor teknologi pada inovasi yang cepat, perubahan regulasi digital, serta sensitivitas yang tinggi terhadap perubahan suku bunga makro [13]. Fenomena booming perusahaan teknologi di BEI sering kali diikuti oleh aksi spekulasi intensif yang memicu lonjakan harga sesaat sebelum kemudian mengalami koreksi tajam [14]. Fluktuasi ekstrem ini menciptakan fenomena volatilitas yang jauh lebih tinggi dibandingkan dengan sektor konvensional seperti perbankan atau barang konsumen [15]. Investor ritel yang mendominasi pasar modal Indonesia saat ini sering kali terjebak dalam kerugian masif akibat ketidakmampuan memprediksi pergerakan volatilitas saham teknologi ini [16]. Minimnya instrumen mitigasi risiko yang adaptif di pasar berkembang seperti Indonesia memperparah dampak negatif dari volatilitas ekstrem tersebut [17]. Oleh karena itu, diperlukan sebuah pendekatan ilmiah khusus yang mampu membedah secara spesifik bagaimana volatilitas saham sektor teknologi terbentuk dan bergerak di BEI [18]. Tanpa adanya pemahaman spesifik sektor, strategi investasi yang diterapkan di pasar modal Indonesia berpotensi menjadi tidak efektif dan menyesatkan [19].

Secara historis, para peneliti keuangan telah mengembangkan berbagai metode ekonometrika klasik untuk menangkap fenomena volatilitas aset finansial [20]. Model Autoregressive Conditional Heteroskedasticity (ARCH) dan perluasannya, yaitu Generalized Autoregressive Conditional Heteroskedasticity (GARCH), telah menjadi

standar industri selama beberapa dekade [21]. Model-model statistik konvensional ini dirancang untuk menangkap fenomena volatility clustering dan efek leverage yang sering muncul pada data deret waktu keuangan. Meskipun demikian, model GARCH memiliki asumsi parametrik yang sangat ketat, seperti asumsi distribusi normal pada residual dan hubungan linear antar variabel. Kenyataannya, data volatilitas saham riil di lapangan sering kali menunjukkan sifat non-linear, asimetris, dan memiliki ekor gemuk (heavy-tailed distribution). Ketika dihadapkan pada guncangan pasar yang ekstrem atau perubahan tren yang mendadak, model ekonometrika klasik sering kali gagal beradaptasi dan menghasilkan bias prediksi yang besar. Keterbatasan ini terjadi karena metode klasik cenderung mengandalkan rata-rata historis jangka pendek dan tidak mampu menangkap dependensi data jangka panjang secara optimal. Selain itu, proses kalibrasi parameter pada model GARCH sering kali memerlukan intervensi manual yang subjektif dari peneliti agar mencapai konvergensi. Ketidakmampuan metode statistik tradisional dalam menangani struktur data yang kompleks dan masif menjadi dorongan utama bagi peralihan paradigma riset. Maka dari itu, ketergantungan penuh pada model linear klasik dalam era pasar keuangan yang modern kini mulai banyak dipertanyakan efektivitasnya.

Perkembangan teknologi komputasi yang masif dalam era industri modern telah membuka peluang baru melalui pemanfaatan Machine Learning (ML). Algoritma berbasis kecerdasan buatan dinilai memiliki keunggulan komparatif karena tidak memerlukan asumsi distribusi data yang ketat seperti pada statistika klasik. Metode pembelajaran mesin mampu secara mandiri mengekstrak pola-pola tersembunyi, non-linear, dan kompleks langsung dari data historis yang besar. Beberapa algoritma populer seperti Support Vector Machine (SVM), Random Forest (RF), dan Extreme Gradient Boosting (XGBoost) telah mulai diterapkan dalam berbagai prediksi finansial. Algoritma-algoritma tersebut terbukti mampu memberikan hasil prediksi arah harga saham yang lebih baik dibandingkan model linear tradisional. Namun, ketika dihadapkan pada data deret waktu (time-series) yang memiliki ketergantungan urutan waktu yang kuat, metode ML standar ini masih memiliki kelemahan mendasar. Mereka memperlakukan setiap baris data sebagai entitas yang independen dan mengabaikan informasi urutan kronologis yang sebenarnya sangat krusial dalam data bursa. Kelemahan ini membuat algoritma ML berbasis pohon (tree-based) atau kernel kurang optimal untuk memprediksi volatilitas jangka panjang yang polanya terus berubah. Akibatnya, para peneliti mulai mengalihkan fokus pada arsitektur yang dirancang khusus untuk data sekuensial, yaitu Deep Learning berbasis jaringan saraf. Fleksibilitas arsitektur Deep Learning dinilai memberikan lompatan besar dalam pemodelan risiko dan keuangan kuantitatif secara global.

Di antara berbagai arsitektur Deep Learning, Recurrent Neural Network (RNN) muncul sebagai terobosan utama untuk menangani data berbasis waktu. RNN dirancang dengan memiliki siklus internal yang memungkinkannya mempertahankan informasi dari input sebelumnya untuk memengaruhi input saat ini. Teori ini secara konseptual sangat cocok dengan sifat pasar saham di mana harga hari ini merupakan refleksi dari akumulasi informasi hari-hari sebelumnya. Kendati demikian, dalam praktiknya, RNN konvensional menderita kelemahan matematis serius yang dikenal sebagai vanishing gradient atau exploding gradient. Masalah ini terjadi ketika RNN mencoba mempelajari ketergantungan data jangka panjang, di mana informasi dari masa lalu yang jauh cenderung memudar atau hilang sama sekali selama proses backpropagation. Ketidakmampuan RNN standar untuk mengingat pola jangka panjang membuat efektivitasnya menurun drastis saat digunakan pada data saham tahunan. Padahal, volatilitas saham sering kali dipengaruhi oleh memori jangka panjang pasar terhadap krisis atau guncangan yang terjadi beberapa bulan bahkan beberapa tahun ke belakang. Oleh sebab itu, diperlukan modifikasi arsitektur jaringan saraf yang mampu mengatasi masalah memori jangka panjang tanpa mengorbankan stabilitas komputasi. Kebutuhan mendesak inilah yang melatarbelakangi lahirnya variasi RNN yang lebih canggih dan memiliki mekanisme kontrol memori yang lebih selektif. Solusi inovatif ini kemudian menjadi standar baru dalam riset pemrosesan data sekuensial yang bersifat kompleks.

Untuk mengatasi keterbatasan RNN konvensional, arsitektur Long Short-Term Memory (LSTM) diperkenalkan sebagai solusi mutakhir. LSTM memodifikasi struktur neuron dengan memperkenalkan konsep cell state dan tiga jenis gerbang pengendali otomatis, yaitu forget gate, input gate, dan output gate. Forget gate berfungsi secara cerdas untuk menentukan informasi masa lalu mana yang sudah tidak relevan dan harus dibuang dari memori model. Sementara itu, input gate bertugas menyaring informasi baru yang masuk untuk disimpan ke dalam cell state, dan output gate mengontrol nilai yang akan diteruskan ke lapisan berikutnya. Mekanisme pengaturan gerbang matematis ini memungkinkan LSTM untuk mempertahankan ingatan jangka panjang sekaligus melupakan derau (noise) jangka pendek secara efisien. Karakteristik unik ini membuat LSTM menjadi sangat perkasa dalam memodelkan volatilitas saham yang dipenuhi oleh noise harian namun tetap memiliki tren jangka panjang. Beberapa riset global telah membuktikan bahwa LSTM memiliki akurasi yang superior dalam memprediksi data keuangan dibandingkan dengan RNN standar maupun GARCH. Fleksibilitas LSTM dalam memproses data berdimensi tinggi juga mempermudah peneliti untuk melakukan tuning hyperparameter guna mencapai performa terbaik. Keunggulan teoritis dan empiris inilah yang menjadikan LSTM sebagai algoritma paling menjanjikan dalam riset komputasi keuangan saat ini. Kendati demikian, efektivitas implementasi LSTM pada pasar modal negara berkembang masih memerlukan pengujian empiris yang lebih mendalam dan spesifik.

Meskipun keunggulan LSTM telah banyak dibahas, terdapat celah penelitian (research gap) yang nyata yang mendasari dilakukannya studi ini. Mayoritas penelitian terdahulu mengenai implementasi LSTM dalam dunia finansial berfokus pada prediksi arah pergerakan harga saham (stock price prediction) bukan pada volatilitasnya. Padahal, bagi seorang manajer investasi dan regulator, memprediksi besaran risiko (volatilitas) jauh lebih penting daripada sekadar menebak harga naik atau turun. Celah penelitian kedua menunjukkan bahwa sebagian besar studi prediktif LSTM mengambil objek di pasar modal negara maju seperti Amerika Serikat (NYSE/NASDAQ) atau Eropa. Karakteristik pasar modal negara maju yang sudah efisien tentu sangat berbeda dengan karakteristik BEI yang dikategorikan sebagai emerging market. Pasar modal berkembang cenderung memiliki likuiditas yang lebih rendah, volatilitas intrinsik yang lebih tinggi, dan perilaku investor yang lebih spekulatif. Selain itu, riset yang secara khusus mengisolasi sektor teknologi di Indonesia menggunakan pendekatan Deep Learning masih sangat langka ditemukan. Kebanyakan peneliti lokal masih menggunakan metode konvensional seperti GARCH untuk menganalisis saham teknologi, yang mana telah terbukti kurang adaptif terhadap perubahan cepat sektor digital. Belum adanya standardisasi arsitektur LSTM yang optimal untuk menangani volatilitas saham teknologi di BEI menjadi ruang kosong yang harus segera diisi. Oleh karena itu, penelitian ini hadir untuk menjembatani kesenjangan metodologis dan kontekstual tersebut secara komprehensif.

Analisis kesenjangan ini diperkuat oleh fakta bahwa sektor teknologi di BEI mengalami dinamika struktural yang luar biasa kompleks sepanjang periode 2023 hingga 2026. Masuknya perusahaan-perusahaan teknologi skala besar (tech giants) ke bursa domestik telah mengubah lanskap kapitalisasi pasar secara drastis. Dinamika ini diiringi oleh tingginya intervensi sentimen publik dan berita media sosial yang membuat volatilitas saham teknologi bergerak secara acak dan ekstrem. Pemodelan volatilitas konvensional terbukti berulang kali gagal memprediksi titik balik (turning point) dari lonjakan volatilitas saham-saham tersebut. Kegagalan prediksi ini berdampak pada tingginya angka kerugian modal bagi investor institusi maupun ritel di Indonesia. Riset terdahulu yang mencoba menerapkan algoritma ML dasar pada saham BEI juga sering menghasilkan tingkat overfitting yang tinggi karena gagal menangani noise pasar. Hal ini mengonfirmasi bahwa terdapat kebutuhan mendesak untuk menguji keandalan mekanisme gerbang LSTM dalam menyaring noise pada saham teknologi BEI. Penelitian ini tidak hanya sekadar mereplikasi algoritma yang sudah ada, melainkan melakukan desain ulang arsitektur model agar sesuai dengan skala volatilitas pasar domestik. Mengisi celah riset ini menjadi krusial demi menyediakan referensi akademis yang valid dan aplikatif bagi industri keuangan nasional. Keberhasilan pengujian ini diharapkan dapat menggeser preferensi praktisi dari model statistik kaku menuju model berbasis kecerdasan buatan yang adaptif.

Untuk mengatasi tantangan tersebut, penelitian ini mengajukan penerapan algoritma LSTM yang dikonfigurasi secara khusus menggunakan pendekatan susun (Stacked LSTM). Struktur Stacked LSTM dipilih karena memiliki kapasitas yang lebih dalam untuk mempelajari representasi fitur temporal yang berlapis pada data volatilitas. Data yang digunakan dalam studi ini adalah data historis volatilitas harian saham teknologi di BEI, dengan saham PT GoTo Gojek Tokopedia Tbk (GOTO.JK) sebagai representasi utama sektor ini. Pemilihan saham ini didasarkan pada volume perdagangan dan kapitalisasi pasarnya yang sangat besar sehingga mampu memengaruhi pergerakan indeks sektor teknologi secara keseluruhan. Proses pra-pemrosesan data dilakukan secara ketat melalui penghitungan log return harian dan rolling standard deviation untuk membentuk indikator volatilitas yang valid. Model LSTM kemudian dilatih dengan memanfaatkan optimalisasi hyperparameter seperti penentuan jumlah neuron, tingkat dropout untuk mencegah overfitting, dan penyesuaian batch size. Evaluasi kinerja model diukur menggunakan metrik kesalahan standar seperti Root Mean Squared Error (RMSE) dan visualisasi grafik perbandingan aktual versus prediksi. Melalui pendekatan metodologis yang sistematis ini, diharapkan model mampu memberikan estimasi volatilitas dengan tingkat presisi yang tinggi. Seluruh tahapan eksperimen ini diimplementasikan menggunakan lingkungan komputasi berbasis awan guna menjamin validitas dan replikabilitas kode program. Integrasi antara teori keuangan modern dan teknik Deep Learning terancang diharapkan mampu menghasilkan analisis yang tajam dan objektif.

Secara keseluruhan, penelitian ini dirancang dengan tujuan utama untuk mengevaluasi efisiensi dan akurasi algoritma LSTM dalam memprediksi volatilitas saham sektor teknologi di BEI. Manfaat teoritis dari penelitian ini adalah memperkaya khazanah literatur keuangan kuantitatif, khususnya mengenai penerapan Deep Learning di emerging market. Secara praktis, hasil prediksi dan model yang dikembangkan dalam studi ini dapat dimanfaatkan oleh para investor sebagai alat bantu pengambilan keputusan investasi dan manajemen portofolio yang lebih rasional. Bagi para manajer investasi, estimasi volatilitas yang akurat dari model ini dapat menjadi dasar penyusunan strategi lindung nilai yang lebih efektif terhadap risiko pasar. Selain itu, bagi pihak regulator seperti Otoritas Jasa Keuangan (OJK) dan Bursa Efek Indonesia, studi ini dapat memberikan sudut pandang baru dalam memantau pergerakan pasar yang tidak wajar dan menyusun kebijakan stabilisasi bursa. Kebaruan (novelty) utama penelitian ini terletak pada kombinasi spesifik antara arsitektur Stacked LSTM, fokus pemodelan pada metrik volatilitas, dan konteks empiris saham teknologi pasca-pandemi di BEI. Melalui struktur penulisan yang sistematis, artikel ini diharapkan dapat menjadi panduan referensi yang kuat bagi peneliti selanjutnya yang tertarik mengembangkan sistem kecerdasan buatan di bidang keuangan. Pentingnya integrasi interdisipliner ini

menjadi penanda bahwa masa depan analisis finansial akan sangat bergantung pada kolaborasi ilmu komputer dan ilmu ekonomi. Akhir kata, studi ini diharapkan mampu membuktikan bahwa pemanfaatan teknologi kecerdasan buatan dapat meningkatkan efisiensi pasar modal Indonesia ke level yang lebih tinggi. Dengan demikian, seluruh rangkaian argumen, data, dan metodologi yang disajikan dalam artikel ini memiliki urgensi ilmiah yang kuat untuk dipublikasikan.

2. METODOLOGI PENELITIAN

2.1 Jenis Penelitian dan Desain Eksperimen

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental berbasis komputasi (computational experimental research). Pendekatan kuantitatif dipilih karena fokus utama penelitian ini melibatkan pengolahan, pemodelan, dan pengujian data numerik berupa harga saham dan nilai volatilitas historis harian secara objektif. Sifat eksperimental dalam penelitian ini tercermin dari proses perancangan, pelatihan, dan pengujian arsitektur algoritma Deep Learning, yaitu Long Short-Term Memory (LSTM), untuk mengevaluasi kemampuannya dalam memprediksi volatilitas masa depan di pasar modal. Penelitian ini tidak bermaksud untuk mencari hubungan kausalitas antarvariabel makroekonomi, melainkan berfokus pada optimasi kemampuan prediktif model (predictive analytics) terhadap data deret waktu (time-series). Untuk memberikan gambaran yang sistematis mengenai tahapan ilmiah yang dilakukan, penelitian ini dirancang melalui desain eksperimen terstruktur yang dibagi menjadi lima tahapan utama, yaitu: Tahap Akuisisi Data: Proses pengunduhan data sekunder berupa harga saham penutupan harian (Adjusted Close Price) saham teknologi sasaran dari basis data Yahoo Finance secara otomatis menggunakan pustaka Python. Tahap Pra-pemrosesan Data (Data Preprocessing): Mengubah data harga mentah menjadi nilai log return, menghitung rolling standard deviation untuk membentuk variabel volatilitas historis, serta melakukan normalisasi data ke skala 0-1 menggunakan teknik Min-Max Scaling. Tahap Pembentukan Fitur (Feature Engineering): Mentransformasikan data volatilitas sekuensial satu dimensi menjadi struktur matriks tiga dimensi (3D Array) menggunakan metode sliding window dengan panjang time-steps tertentu sebagai representasi memori jangka pendek model. Tahap Pelatihan Model (Model Training): Memisahkan data menjadi data latih (training set) dan data validasi (validation set), kemudian melatih bobot internal arsitektur Stacked LSTM melalui proses forward propagation dan backpropagation menggunakan fungsi kerugian Mean Squared Error (MSE) dan Adam Optimizer. Tahap Pengujian dan Evaluasi (Testing and Evaluation): Melakukan prediksi pada data uji (testing set) yang belum pernah dilihat oleh model, mengembalikan skala output prediksi ke nilai volatilitas asli (inverse transform), menghitung metrik kesalahan menggunakan Root Mean Squared Error (RMSE), serta memvisualisasikan kurva aktual versus prediksi untuk analisis interpretatif. Melalui desain eksperimen yang terintegrasi ini, objektivitas penelitian dapat dipertahankan karena seluruh proses bergantung pada konsistensi algoritma dan data empiris di lapangan. Desain ini juga memastikan bahwa eksperimen yang dilakukan bersifat replicable, di mana peneliti lain dapat menguji ulang model ini menggunakan objek saham atau rentang waktu yang berbeda namun tetap berada di bawah kerangka metodologis yang sama.

2.2 Data dan Sumber Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder kuantitatif yang bersumber dari catatan historis transaksi pasar modal. Objek penelitian difokuskan pada saham PT GoTo Gojek Tokopedia Tbk yang terdaftar di Bursa Efek Indonesia (BEI) dengan kode emiten GOTO.JK. Pemilihan saham GOTO.JK sebagai representasi tunggal sektor teknologi didasarkan pada tiga pertimbangan strategis, yaitu: (1) memiliki kapitalisasi pasar (market capitalization) terbesar di sektor teknologi BEI, (2) mencatatkan volume dan frekuensi perdagangan harian yang sangat tinggi sehingga likuiditasnya mampu memengaruhi indeks sektoral secara signifikan, dan (3) memiliki tingkat sensitivitas yang tinggi terhadap sentimen pasar digital, sehingga sangat ideal untuk menguji keandalan model Deep Learning dalam mendeteksi volatilitas ekstrem.

Periode pengamatan data yang diambil dalam eksperimen ini mencakup rentang waktu selama 3 tahun penuh, terhitung sejak 1 Januari 2023 hingga 1 Januari 2026. Pembatasan rentang waktu ini sengaja dipilih untuk menangkap dinamika pergerakan harga saham sektor teknologi pada fase pasca-pandemi, di mana terjadi pergeseran struktural dari fase bakar uang (growth-stage) menuju fase mengejar profitabilitas (profitability-stage) yang memicu fluktuasi harga yang dinamis. Dari rentang waktu tersebut, diperoleh total data mentah sebanyak 735 hari bursa (sebelum dipotong oleh proses sliding window dan penghitungan rolling).

Sumber data penelitian ini diperoleh secara legal dan real-time dari basis data keuangan internasional Yahoo Finance melalui pemanfaatan antarmuka pemrograman aplikasi (API) dengan menggunakan pustaka yfinance pada bahasa pemrograman Python. Variabel mentah utama yang diunduh dari sumber tersebut adalah harga penutupan yang telah disesuaikan (Adjusted Close Price). Penggunaan Adjusted Close Price dinilai lebih akurat dan valid untuk analisis deret waktu keuangan dibandingkan dengan harga penutupan reguler (Close Price), karena nilai Adjusted Close Price telah disesuaikan secara otomatis terhadap aksi korporasi perusahaan yang dapat mendistorsi harga saham asli, seperti pembagian dividen (dividend payouts), pemecahan saham (stock

splits), maupun penerbitan saham baru (right issues). Seluruh data yang telah diunduh kemudian disimpan dalam format tabel data (Data Frame) untuk siap diproses pada tahapan eksperimen berikutnya.

2.3 Pra-Pemrosesan Data (*Data Preprocessing*)

Sebelum data harga saham mentah dapat digunakan untuk melatih arsitektur *Long Short-Term Memory* (LSTM), diperlukan serangkaian tahapan pra-pemrosesan data (*data preprocessing*) yang ketat. Tahapan ini krusial untuk mentransformasikan data deret waktu keuangan yang bersifat acak (*stochastic*) menjadi indikator risiko yang stabil, serta memastikan komputasi jaringan saraf tiruan dapat berjalan secara konvergen dan optimal. Proses pra-pemrosesan data dalam penelitian ini dibagi menjadi tiga tahapan utama, yaitu: penghitungan *log return*, transformasi menjadi nilai volatilitas historis, dan normalisasi skala data.

a. Penghitungan Imbal Hasil Logaritmik (*Log Return*)

Data harga penutupan saham yang telah disesuaikan (*Adjusted Close Price*) tidak dapat langsung digunakan untuk mengukur volatilitas karena data harga saham umumnya bersifat tidak stasioner dan memiliki tren pertumbuhan linier. Oleh karena itu, data harga mentah terlebih dahulu ditransformasikan menjadi nilai imbal hasil logaritmik (*log return*). Penggunaan *log return* dipilih dibandingkan *simple return* karena memiliki sifat aditif secara temporal dan memperkecil bias pencilaan data. Formulasi matematis untuk menghitung *log return* harian adalah sebagai berikut:

$$R_t = \ln \left(\frac{P_t}{P_{t-1}} \right) \quad (1)$$

Di mana R_t merupakan nilai *log return* saham GOTO.JK pada hari bursa ke- t , P_t adalah harga penutupan yang disesuaikan pada hari ke- t , dan P_{t-1} adalah harga penutupan yang disesuaikan pada satu hari bursa sebelumnya ($t - 1$).

b. Transformasi Nilai Volatilitas Historis (*Rolling Standard Deviation*)

Fokus utama penelitian ini adalah memprediksi volatilitas, bukan memprediksi arah harga saham. Untuk membentuk variabel volatilitas harian, penelitian ini menggunakan metode deviasi standar bergerak (*rolling standard deviation*) dari nilai *log return* dengan jendela waktu (*window size*) sepanjang 21 hari bursa. Pemilihan angka 21 hari didasarkan pada representasi jumlah hari perdagangan aktif dalam satu bulan kalender di Bursa Efek Indonesia. Persamaan matematis untuk menghitung volatilitas historis harian (σ_t) dirumuskan sebagai:

$$\sigma_t = \sqrt{\frac{1}{N-1} \sum_{i=0}^{N-1} (R_{t-i} - \bar{R}_t)^2} \quad (2)$$

Di mana N adalah panjang jendela waktu (21 hari), R_{t-i} adalah nilai *log return* pada hari ke $t - i$, dan $\bar{R}_t$ merupakan nilai rata-rata (*mean*) dari *log return* selama periode 21 hari tersebut. Melalui proses ini, baris data yang berada pada 20 hari pertama secara otomatis akan dihapus (*dropna*) karena belum memenuhi syarat kelengkapan jendela waktu pengamatan.

c. Normalisasi Skala Data (*Min-Max Scaling*)

Algoritma *Deep Learning* seperti LSTM berbasis pada fungsi aktivasi gradien yang sangat sensitif terhadap rentang skala nilai input. Data volatilitas asli yang bernilai sangat kecil (berkisar antara 0.01 hingga 0.08) dapat menyebabkan proses pembaruan bobot (*weight updates*) selama *backpropagation* berjalan sangat lambat (*vanishing gradient*). Untuk mengatasi kendala tersebut, data volatilitas ditransformasikan ke dalam rentang skala seragam antara 0 hingga 1 menggunakan teknik *Min-Max Scaling*. Rumus normalisasi yang diterapkan pada setiap entitas data adalah:

$$X_{scaled} = \frac{X_t - X_{min}}{X_{max} - X_{min}} \quad (3)$$

Di mana X_{scaled} adalah nilai volatilitas hasil normalisasi yang siap dimasukkan ke jaringan LSTM, X_t adalah nilai volatilitas aktual pada hari ke- t , sedangkan X_{min} dan X_{max} berturut-turut merepresentasikan nilai volatilitas terendah dan tertinggi yang ditemukan di dalam keseluruhan *dataset*. Nilai parameter X_{min} dan X_{max} yang diperoleh dari data latihan (*training set*) ini nantinya akan disimpan dan digunakan kembali dalam proses denormalisasi (*inverse transform*) untuk mengembalikan hasil keluaran prediksi model ke skala volatilitas finansial yang sebenarnya.

2.4 Pembentukan Struktur Data *Sliding Window* (3D Array)

Setelah seluruh data volatilitas historis disetarakan skalanya melalui proses normalisasi, tahapan krusial berikutnya adalah mentransformasikan struktur data deret waktu satu dimensi (*1D Array*) tersebut menjadi format matriks tiga dimensi (*3D Array*). Algoritma *Long Short-Term Memory* (LSTM) memiliki syarat mutlak di mana input yang dimasukkan harus memiliki arsitektur tiga dimensi dengan komponen berupa [samples, time-

ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 57-65

steps, features]. Untuk memenuhi spesifikasi teknis tersebut, penelitian ini menerapkan metode *Sliding Window* atau dikenal juga dengan istilah jendela geser temporal.

Metode *Sliding Window* bekerja dengan cara memotong deret waktu volatilitas secara kronologis menggunakan ukuran jendela tetap (*fixed window size*) yang digeser satu langkah ke depan (*stride=1*) di setiap iterasinya. Dalam eksperimen ini, panjang *time-steps* ditetapkan sebesar 60 hari. Pemilihan angka 60 hari bursa ini didasarkan pada asumsi finansial bahwa model memerlukan memori historis kuartalan (representasi 3 bulan perdagangan aktif di Bursa Efek Indonesia) untuk menangkap tren volatilitas jangka menengah dan mengabaikan fluktuasi harian yang bersifat derau (*noise*).

Secara teknis operasional, pembentukan struktur data ini dilakukan secara terpisah antara data latih (*training set*) dan data uji (*testing set*):

- Matriks Fitur Input (X): Merupakan kumpulan data matriks dua dimensi yang berisi potongan data volatilitas dari hari ke $t - 60$ hingga hari ke $t - 1$. Nilai ini bertindak sebagai variabel independen yang akan dipelajari polanya oleh jaringan LSTM.
- Matriks Target Output (Y): Merupakan nilai volatilitas tunggal tepat pada hari ke- t . Nilai ini bertindak sebagai variabel dependen atau label aktual yang menjadi target prediksi model.

Proses pergeseran jendela ini dapat dinotasikan secara matematis melalui pembentukan pasangan vektor input-target pada setiap iterasi i sebagai berikut:

$$X_i = [x_i, x_{i+1}, x_{i+2}, \dots, x_{i+59}] \quad (4)$$

$$Y_i = [x_{i+60}] \quad (5)$$

Melalui perulangan (*looping*) mekanis ini pada total data latih, diperoleh dimensi akhir data latihan X_{train} sebesar (493, 60, 1). Angka 493 mempresentasikan jumlah total sampel atau jendela geser yang berhasil terbentuk (*samples*), angka 60 merepresentasikan panjang hari bursa ke belakang yang dianalisis (*time-steps*), dan angka 1 merepresentasikan jumlah variabel input yang bersifat univariat (*features*), yaitu hanya variabel volatilitas itu sendiri.

Sementara itu, untuk data uji, proses pembentukan X_{test} menghasilkan dimensi (138, 60, 1). Guna memastikan akurasi prediksi pada sampel pertama data uji tidak terputus, data uji sengaja mengambil ekstra 60 hari dari akhir data latih sebagai jangkar sekuensial pertama. Melalui pemisahan dimensi yang rigid dan terstruktur ini, model LSTM dapat dilatih untuk mengenali ketergantungan temporal jangka panjang (*long-term dependencies*) secara optimal tanpa mengalami kebocoran data (*data leakage*) antara masa lalu dan masa depan.

2.5 Arsitektur Model Stacked LSTM

Penelitian ini menerapkan arsitektur *Stacked LSTM* (Jaringan LSTM Berlapis) sebagai model komputasi utama untuk memprediksi volatilitas saham GOTO.JK. Berbeda dengan LSTM tunggal (*Single Layer*), model *Stacked LSTM* memiliki dua atau lebih lapisan LSTM yang disusun secara vertikal. Pendekatan berlapis ini dipilih karena memiliki kapasitas komputasi yang lebih tinggi dalam mengekstrak fitur temporal kompleks dan mempelajari representasi data deret waktu keuangan yang memiliki tingkat derau (*noise*) tinggi pada level abstraksi yang lebih mendalam. Secara spesifik, jaringan saraf tiruan yang dibangun dalam eksperimen ini menggunakan model sekuensial (*Sequential Model*) yang terdiri dari lima lapisan utama yang disusun secara sistematis sebagai berikut:

- Lapisan LSTM Pertama (*First LSTM Layer*)
Lapisan ini bertindak sebagai gerbang masuk pertama bagi matriks input tiga dimensi bernilai (493,60,1). Lapisan ini dikonfigurasi dengan memiliki 50 unit neuron (hidden units). Untuk memastikan bahwa lapisan ini dapat meneruskan seluruh informasi sekuensial temporal ke lapisan berikutnya, parameter *return_sequences* diatur bernilai True. Secara matematis, pada lapisan ini, setiap sel LSTM akan memproses input sekuensial dan menghasilkan output tersembunyi (*hidden state*) untuk setiap *time-step* (hari ke-1 hingga hari ke-60), sehingga output dari lapisan ini tetap mempertahankan struktur tiga dimensinya.
- Lapisan Regulasi Pertama (*First Dropout Layer*)
Tepat setelah lapisan LSTM pertama, diterapkan lapisan *Dropout* dengan koefisien sebesar 0.2 (20%). Fungsi utama dari lapisan ini adalah sebagai teknik regularisasi untuk mencegah terjadinya fenomena *overfitting* sebuah kondisi di mana model terlalu menghafal data latihan tetapi gagal melakukan generalisasi pada data uji. Secara mekanis, lapisan ini akan menonaktifkan secara acak 20% neuron pada setiap iterasi pelatihan (*epoch*), sehingga memaksa jaringan untuk mempelajari pola volatilitas secara lebih kuat (*robust*) dan tidak bergantung pada jalur neuron tertentu.
- Lapisan LSTM Kedua (*Second LSTM Layer*)
Lapisan LSTM kedua diletakkan di atas lapisan regularisasi pertama untuk menangkap pola non-linear yang lebih abstrak. Lapisan ini juga dikonfigurasi dengan memiliki 50 unit neuron. Berbeda dengan lapisan pertama, parameter *return_sequences* pada lapisan kedua ini diatur bernilai False. Hal ini berarti sel LSTM hanya akan

mengeluarkan vektor *hidden state* terakhir (pada *time-step* ke-60) dan mengabaikan urutan sekuensial sebelumnya. Transformasi ini mengubah representasi data dari matriks tiga dimensi menjadi vektor dua dimensi yang siap dialirkan ke lapisan keluaran akhir.

d. Lapisan Regulasi Kedua (*Second Dropout Layer*)

Mirip dengan tahapan sebelumnya, lapisan *Dropout* kedua dengan tingkat pemangkasan sebesar 0.2 (20%) disisipkan kembali setelah lapisan LSTM kedua. Penempatan *dropout* ganda pada arsitektur berlapis ini sangat krusial dalam pemodelan keuangan untuk memastikan bahwa kompleksitas arsitektur *Deep Learning* tetap seimbang dengan jumlah sampel data bursa domestik yang relatif terbatas.

e. Lapisan Padat Akhir (*Dense/Output Layer*)

Lapisan terakhir dari arsitektur ini adalah *Dense Layer* atau lapisan terhubung penuh (*fully-connected layer*) yang memiliki 1 unit neuron. Lapisan ini tidak menggunakan fungsi aktivasi non-linear (menggunakan aktivasi linear bawaan) karena tugas yang dilakukan adalah tugas regresi, yaitu memproyeksikan nilai kontinu tunggal yang merepresentasikan estimasi nilai volatilitas saham pada hari ke-61 ($t + 1$).

Seluruh arsitektur *Stacked LSTM* ini dikompilasi menggunakan fungsi kerugian *Mean Squared Error* (MSE) sebagai metrik penalti error selama pelatihan. Pembaruan bobot (*weight tuning*) internal dikendalikan oleh Adam Optimizer (sebuah algoritma berbasis *stochastic gradient descent* yang adaptif). Model dilatih di lingkungan Google Colab dengan ukuran *batch* (*batch size*) sebesar 32 dan dijalankan secara berulang sebanyak 20 *epochs* hingga mencapai titik konvergensi yang optimal antara data latihan dan data validasi.

2.6 Metriks Evaluasi Performa Model

Tahapan akhir yang tidak kalah krusial dalam metodologi penelitian eksperimental ini adalah melakukan pengukuran dan evaluasi terhadap performa prediksi yang dihasilkan oleh model *Stacked LSTM*. Evaluasi ini bertujuan untuk memberikan justifikasi ilmiah mengenai seberapa akurat model dalam mereplikasi pola volatilitas riil pada data uji (*testing set*) yang belum pernah dipelajari sebelumnya selama proses pelatihan. Untuk mengukur tingkat kesalahan (*error rate*) prediktif tersebut secara kuantitatif, penelitian ini menggunakan metrik Root Mean Squared Error (RMSE).

Root Mean Squared Error (RMSE) merupakan salah satu metrik standar yang paling sering digunakan dalam mengevaluasi model regresi dan prediksi deret waktu (*time-series forecasting*) di bidang keuangan kuantitatif. Keunggulan utama dari RMSE adalah kemampuannya memberikan bobot penalti yang lebih tinggi untuk kesalahan prediksi yang bernilai besar (*large errors*) karena adanya proses pengkuadratan selisih nilai aktual dan prediksi. Hal ini sangat cocok untuk pemodelan volatilitas saham teknologi yang kerap mengalami lonjakan ekstrem (*shock*), di mana kesalahan prediksi yang besar pada titik-titik kritis akan sangat memengaruhi keputusan manajemen risiko investasi. Secara matematis, sebelum nilai RMSE dihitung, seluruh output prediksi yang dihasilkan oleh model LSTM yang masih berada dalam skala normalisasi 0 hingga 1 wajib dikembalikan terlebih dahulu ke skala volatilitas finansialnya menggunakan fungsi denormalisasi (*inverse transform*). Setelah data berada pada skala semula, formula RMSE dievaluasi menggunakan persamaan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2} \quad (6)$$

Di mana:

n merepresentasikan jumlah total sampel pengamatan pada data uji, yaitu sebanyak 138 hari bursa.

$\hat{y}_t$ menyatakan nilai volatilitas hasil proyeksi atau prediksi dari model *Stacked LSTM* pada hari ke- t .

y_t menyatakan nilai volatilitas aktual yang tercatat di Bursa Efek Indonesia pada hari ke- t .

$\sum$ merupakan simbol penjumlahan kuadrat selisih dari hari pertama data uji hingga hari terakhir (n).

Nilai RMSE berkisar dari angka 0 hingga tak terhingga (∞). Prinsip interpretasi hasil metrik ini didasarkan pada kriteria bahwa semakin kecil nilai RMSE yang dihasilkan (mendekati angka 0), maka semakin tinggi tingkat akurasi dan presisi model *Stacked LSTM* tersebut. Nilai RMSE yang rendah membuktikan bahwa selisih atau jarak antara garis tren prediksi (garis merah putus-putus pada grafik eksperimen kita) dan garis tren aktual (garis hijau) memiliki magnitudo kesalahan yang sangat minim. Pengujian kuantitatif menggunakan RMSE ini nantinya akan dilengkapi dengan analisis visual grafik di Bab IV guna memberikan gambaran evaluasi yang komprehensif bagi pembaca jurnal.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Karakteristik Volatilitas Historis (Statistik Deskriptif)


Berdasarkan hasil transformasi data harga penutupan menjadi nilai log return harian dan dilanjutkan dengan penghitungan deviasi standar bergerak (*rolling standard deviation*) berjarak 21 hari bursa, visualisasi tren volatilitas historis saham GOTO.JK menunjukkan dinamika yang sangat fluktuatif. Pola pergerakan data ini mengonfirmasi keberadaan fenomena *volatility clustering* yang sangat kuat di pasar modal domestik.

ISSN 2962-7966 (media online)
 Vol 4 No 1, Hal: 57-65

Karakteristik data deret waktu keuangan yang memiliki dualitas kondisi yaitu fase lonjakan acak ekstrem di awal periode dan fase kelandaian stabil di akhir periode menegaskan bahwa data volatilitas saham teknologi di Indonesia tidak mengikuti asumsi distribusi normal stasioner (*non-Gaussian distribution*). Sifat data yang memiliki ekor gemuk (*heavy-tailed*) dan struktur non-linear inilah yang menjadi alasan kuat mengapa arsitektur Stacked LSTM digunakan.

3.2 Hasil Evaluasi Proses Pelatihan Model (*Training and Validation Loss*)


Evaluasi terhadap proses pelatihan dilakukan dengan menganalisis pergerakan fungsi kerugian (*loss function*) berupa *Mean Squared Error* (MSE) pada data latih (*training loss*) dan data validasi (*validation loss*) di setiap perulangan (*epoch*).



Gambar 1. Analisis Akurasi Prediksi Volatilitas Saham GOTO.JK Menggunakan LSTM

3.3 Analisis Akurasi Prediksi pada Data Uji (*Testing Performance*)

Pengujian performa dilakukan dengan mengumpulkan data uji independen sebanyak 138 hari bursa terakhir. Model Stacked LSTM yang dikembangkan berhasil mencatatkan nilai kesalahan yang sangat minimal dengan skor *Root Mean Squared Error* (RMSE) sebesar 0.00282.



Gambar 2. Training Loss vs Validation Loss

3.4 Implikasi Finansial dan Diskusi Hasil Penelitian

Keberhasilan model Stacked LSTM dalam memprediksi volatilitas saham dengan nilai RMSE sebesar 0.00282 memberikan bukti empiris baru mengenai integrasi teknologi kecerdasan buatan (*Artificial Intelligence*) dalam manajemen risiko keuangan di *emerging markets*.

Secara praktis, visualisasi yang akurat ini membawa implikasi langsung bagi pemangku kepentingan:

- Bagi Manajer Investasi: Sebagai dasar penyusunan strategi alokasi aset dinamis. Saat grafik model mendeteksi sinyal pembalikan tren menuju volatilitas tinggi, manajer investasi dapat segera melakukan penyeimbangan ulang (*rebalancing*) portofolio untuk menghindari *capital loss*.

ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 57-65

- b. Bagi Regulator (OJK dan BEI): Grafik prediksi ini dapat diadopsi sebagai *Early Warning System* dalam pengawasan transaksi bursa untuk mendeteksi indikasi manipulasi pasar atau guncangan eksternal non-fundamental.

4. KESIMPULAN

Penelitian ini berhasil mengevaluasi dan membuktikan efisiensi serta akurasi algoritma *Stacked LSTM* dalam memprediksi volatilitas harga saham sektor teknologi di Bursa Efek Indonesia (BEI), dengan menggunakan saham PT GoTo Gojek Tokopedia Tbk (GOTO.JK) periode 2023–2026 sebagai representasi utama. Melalui penerapan mekanisme gerbang kontrol (*gates*) yang adaptif dan lapisan regularisasi *Dropout* ganda sebesar 20%, model ini terbukti efektif dalam menyaring derau (*noise*) harian dan mengatasi masalah *overfitting* maupun *underfitting*. Berdasarkan hasil pengujian pada data uji, model *Stacked LSTM* mencatatkan kinerja yang sangat superior dengan skor *Root Mean Squared Error* (RMSE) yang sangat minimal, yaitu sebesar 0,00282. Hasil analisis visual juga menegaskan kemampuan model yang tangkas dan presisi dalam mereplikasi pola kelukan serta mendeteksi sinyal pembalikan arah tren volatilitas aktual, baik pada fase penurunan melandai maupun lonjakan risiko yang agresif. Secara praktis, akurasi prediktif ini memberikan implikasi finansial yang krusial bagi manajer investasi dalam menyusun strategi alokasi aset dinamis, penentuan harga opsi yang lebih adil, serta menjadi instrumen *Early Warning System* bagi regulator untuk menjaga stabilitas pasar modal domestik.

REFERENCES

- [1] D. Alam, A. Kurniawan, and D. Hanggraeni, "Mendorong Pertumbuhan Ekonomi 8% Melalui Pasar Modal Indonesia," *Syntax Literate ; Jurnal Ilmiah Indonesia*, vol. 10, no. 5, pp. 4925–4935, 2025, doi: 10.36418/syntax-literate.v10i5.58706.
- [2] N. T. Setyaningrum and O. Rusmana, "Fenomena Anomali Pasar dan Perilaku Investor dalam Aktivitas Perdagangan Saham di Indonesia," *Journal of Business and Economics Research (JBE)*, vol. 6, no. 3, pp. 896–907, 2025, doi: 10.47065/jbe.v6i3.8211.
- [3] A. Nusantara, S. Nawatmi, and A. Dewantara Noegroho, "Volatility Clustering dan Leverage Effect pada Indeks ESG Leaders: Studi Kasus PGAS & PGEO di Pasar Modal Indonesia," *Value Added : Majalah Ekonomi Dan Bisnis*, vol. 21, no. 2, p. 25, 2025.
- [4] J. Akuntansi, M. F. Athoullah, M. Al, and A. Putri, "Pengaruh Pengungkapan Emisi Karbon terhadap Risiko Keuangan Perusahaan Minyak dan Gas Global : Systematic Literature Review," vol. 02, no. 03, pp. 580–590, 2026.
- [5] A. R. Abdurrahman and Yuni Nustini, "Analisis pengaruh modal intelektual terhadap kinerja perusahaan dengan pendekatan berbasis akuntansi dan berbasis pasar," *Proceeding of National Conference on Accounting & Finance*, vol. 4, pp. 275–281, 2022, doi: 10.20885/ncf.vol4.art34.
- [6] P. Ir and R. C. Tarumingkeng, "Evaluasi Efektivitas Kebijakan," 2025.
- [7] V. Pasar, K. Tantangan, M. Muadz, and A. Afif, "Peluang Bagi Investor," vol. 4, no. 12, 2024, doi: 10.17977/um066.v4.i12.2024.4.
- [8] L. Nafi, "Pertumbuhan Ekonomi Indonesia Tahun 2004," *Jenius.Com*, vol. 5, no. 12, pp. 1–9, 2005, [Online]. Available: <https://www.jenius.com/marketupdate/detail/pertumbuhan-ekonomi-indonesia-tahun-2024>
- [9] S. S. Bibliometrik and E. Irawan, "Analisis Sentimen untuk Riset Pasar Saham," vol. 5, no. April, 2026.
- [10] Purnamasari Ayu Sinta, "Mekanisme Perkembangan Pasar Modal Sebagai Salah Satu Produk Investasi di Masyarakat," *Jurnal Rumpun Manajemen dan Ekonomi*, vol. 2, no. 3, pp. 499–515, 2025, [Online]. Available: <https://doi.org/10.61722/jrme.v2i3.4739>
- [11] V. K. Sari and M. I. P. Nasution, "Dampak E-commerce Terhadap Perkembangan Digital," *Jurnal Akademik Ekonomi Dan Manajemen*, vol. 1, no. 4, pp. 18–24, 2024, [Online]. Available: <https://doi.org/10.61722/jaem.v1i4.3113>
- [12] A. Report, "Growth Through," no. 801, p. 6826, 2011.
- [13] R. C. Tarumingkeng and E. Makro, "Teori dan Aplikasi dalam Konteks Indonesia".
- [14] A. Aziz and M. Ag, "Abdul Aziz, Manajemen Investasi Syariah, (Jakarta: Rajawali Press, 2010".
- [15] F. Satria, D. Kesumah, and L. Firdaus, "SEIKO : Journal of Management & Business Volatilitas Nilai Tukar, Arus Investasi Asing, dan Stabilitas Keuangan di Negara ASEAN-5: Analisis Empiris," *SEIKO : Journal of Management & Business*, vol. 8, no. 2, pp. 2025–929, 2025.
- [16] F. Ekonomi and D. Bisnis, "E-ISSN: 2986-433X Vol. 3, No. 1, O," pp. 518–526, 2024.
- [17] L. S. Az and E. Al, "Dinamika Indonesia," no. October, pp. 1–308, 2018.
- [18] L. Tsalisati, "Makroekonomi Di Tengah Optimisme Pertumbuhan," vol. 4, no. 12, pp. 4–7, 2024, doi: 10.17977/um066.v4.i12.2024.1.
- [19] S. Asri, R. A. Missel, and M. Y. R. Pandin, "Efektivitas Strategi Investasi Pasif dan Aktif di Pasar Modal Indonesia: Dampaknya terhadap Kinerja Portofolio pada Perusahaan Manufaktur yang Terdaftar di BEI," *Manajemen dan Bisnis*, vol. 7, no. 1, pp. 47–57, 2025, doi: 10.30743/jmb.v7i1.10733.
- [20] H. Nathasya, "No TitleEAENH," *Edu Research Indonesian Institute For Corporate Learning And Studies (IICLS)*, vol. 5, no. 1, pp. 70–80, 2024.
- [21] N. Raden Roro Endraswati Wardani Wisnu Murti, "Penerapan Model Garch Dalam Mengevaluasi Risiko Volatilitas," vol. 2, no. 2, pp. 217–228, 2025.