

Prediksi Volatilitas Harga Minyak Mentah dan Emas Menggunakan Random Forest Regression Berdasarkan Data Yahoo Finance

Nuri Natasya^{1*}, Nur Amelia Syahputri¹, Rindi Agustia¹, Imam Saputra²

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

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

Email: ^{1*}nurinatasya52@gmail.com, ²syahputrinuramelia@gmail.com, ³rndagustia@gmail.com, ⁴saputraimam69@gmail.com

(* : coresponding author)

Abstrak

Ketidakpastian harga minyak mentah (*crude oil*) yang ekstrem mengharuskan tersedianya model estimasi volatilitas yang presisi untuk kebutuhan manajemen risiko keuangan. Meskipun algoritma *Random Forest Regressor* populer karena ketangguhannya terhadap data non-linear, penggunaannya pada deret waktu finansial non-stasioner sering kali memicu masalah ekstrapolasi yang berdampak pada nilai *Coefficient of Determination* (R^2) bernilai negatif pada data uji (*out-of-sample*). Penelitian ini bertujuan untuk merancang kerangka kerja rekayasa fitur berbasis stasioneritas dan restriksi kedalaman pohon (*tree depth constraint*) guna mengatasi kelemahan ekstrapolasi tersebut. Data historis harian *Crude Oil Futures* (CL=F) periode 2015–2024 ditarik dari Yahoo Finance. Fitur nominal mutlak ditransformasikan menjadi bentuk stasioner terstandarisasi, meliputi rasio pergerakan rata-rata (SMA_Ratio), persentase perubahan harga (Price_Pct_Change), lebar pita relatif (BB_Bandwidth), serta penyertaan *lagged target volatility* (V_{t-1}). Data dibagi secara sekuensial temporal dengan rasio 80:20. Hasil eksperimen menunjukkan bahwa model teroptimasi berhasil membalikkan nilai R^2 dari -1,1664 (pada Model Baseline) menjadi +0,9174 (pada Model Teroptimasi) pada data uji *out-of-sample*. Selain itu, nilai *Root Mean Squared Error* (RMSE) berhasil dipangkas sebesar 80,46% (menjadi 0,0312) dan *Mean Absolute Error* (MAE) berkurang sebesar 81,56% (menjadi 0,0205). Analisis *feature importance* mengonfirmasi dominasi V_{t-1} (62,4%) dan BB_Bandwidth (18,2%), yang membuktikan fenomena *volatility clustering*. Penelitian ini menyimpulkan bahwa kelemahan ekstrapolasi pada *Random Forest* dapat diatasi melalui rekayasa fitur stasioner tanpa perlu beralih ke arsitektur *Deep Learning* yang kompleks.

Kata Kunci: Random Forest; Volatilitas Minyak Mentah; Rekayasa Fitur; Stasioneritas; Out-of-Sample; R^2 Negatif

1. PENDAHULUAN

Pasar komoditas global, khususnya minyak mentah (*crude oil*), memegang peranan yang sangat vital dalam menjaga stabilitas makroekonomi dan rantai pasok industri dunia [1]. Pergerakan harga minyak mentah tidak hanya memengaruhi sektor energi secara langsung, tetapi juga berdampak signifikan terhadap nilai tukar mata uang, tingkat inflasi, serta dinamika pasar modal global [2]. Dalam beberapa tahun terakhir, fluktuasi harga komoditas energi menunjukkan tingkat ketidakpastian yang sangat ekstrem akibat keterkaitannya dengan isu geopolitik dan kondisi ekonomi makro. Risiko fluktuasi harga ini dikenal sebagai volatilitas, sebuah variabel krusial dalam dunia keuangan yang menggambarkan besarnya rentang perubahan harga aset dalam periode waktu tertentu [3]. Bagi para pelaku pasar, investor, dan pembuat kebijakan, ketidakmampuan dalam mengantisipasi derajat volatilitas dapat berujung pada kerugian finansial yang signifikan [4]. Oleh karena itu, estimasi dan prediksi volatilitas harga minyak mentah menjadi topik riset yang sangat strategis di bidang *computational finance*. Pengukuran volatilitas yang akurat berfungsi sebagai instrumen mitigasi risiko melalui strategi *hedging* serta optimalisasi alokasi portofolio investasi [2]. Kehadiran platform penyedia data keuangan terintegrasi seperti Yahoo Finance mempermudah akses terhadap data historis harga pasar secara *real-time* dan transparan. Kendati demikian, karakteristik data historis minyak mentah yang sangat bersifat *non-linear*, *high-frequency*, dan penuh dengan *noise* menghadirkan tantangan tersendiri dalam proses pemodelannya [5]. Dengan demikian, pemahaman mendalam mengenai perilaku dinamika volatilitas komoditas energi berbasis data historis menjadi kebutuhan primer dalam manajemen risiko keuangan modern [6].

Kehadiran teknik analisis teknikal telah lama menjadi basis utama bagi para praktisi pasar untuk memahami arah tren dan tingkat volatilitas harga aset [7]. Indikator teknikal seperti *Simple Moving Average* (SMA), *Relative Strength Index* (RSI), dan *Bollinger Bands* diekstrak dari data historis *Open, High, Low, Close, Volume* (OHLCV) guna menangkap sinyal momentum dan pergerakan harga. *Bollinger Bands*, misalnya, secara spesifik dirancang untuk mengukur tingkat lebar pita statistik yang mencerminkan tinggi tingginya volatilitas pasar [8]. Sementara itu, indikator RSI dimanfaatkan untuk mendeteksi kondisi *overbought* atau *oversold* yang sering kali menjadi preseden bagi perubahan arah volatilitas [14]. Penggabungan berbagai indikator teknikal ini membentuk fitur komputasi berdimensi tinggi yang diharapkan mampu memberikan informasi prediktif mengenai kondisi pasar [9]. Dalam kurun waktu satu dekade terakhir, pendekatan prediktif berbasis statistik konvensional seperti ARIMA dan GARCH kerap diandalkan untuk memodelkan *time-series* keuangan. Namun demikian, model statistik parametrik tersebut mengasumsikan bahwa data terdistribusi secara normal dan memiliki sifat stasioneritas yang konstan [10]. Asumsi linearitas pada model klasik sering kali gagal dalam merepresentasikan lonjakan (*spikes*) volatilitas yang bersifat mendadak akibat guncangan eksternal [18]. Fleksibilitas pemrosesan data linier yang terbatas mendorong perlunya pemanfaatan pendekatan komputasi cerdas yang lebih adaptif [11]. Oleh sebab itu, integrasi

antara indikator teknikal dan algoritma *Machine Learning* menjadi paradigma baru yang terus dikembangkan dalam analisis komoditas[12].

Perkembangan bidang *Machine Learning* telah membuka peluang besar dalam menyelesaikan permasalahan pemodelan *time-series* finansial yang kompleks dan non-linear [13]. Salah satu algoritma *supervised learning* yang populer dan memiliki rekam jejak yang solid adalah *Random Forest Regression*[14]. Sebagai metode *ensemble learning* berbasis *decision trees*, *Random Forest* bekerja dengan membangun banyak pohon keputusan selama proses pelatihan untuk menghasilkan prediksi akhir melalui rerata output [15]. Keunggulan utama dari *Random Forest* terletak pada kemampuannya dalam menangani keterkaitan non-linear antar variabel tanpa mengasumsikan distribusi data tertentu[16]. Selain itu, algoritma ini memiliki sifat yang relatif *robust* terhadap *overfitting* dibandingkan dengan *single decision tree* berkat penerapan teknik *bagging* (*bootstrap aggregating*)[17]. Karakteristik unik lain dari *Random Forest* adalah kemampuannya dalam menghitung nilai *feature importance*, yang memungkinkan peneliti untuk mengukur seberapa besar kontribusi relatif dari setiap indikator teknikal terhadap variabel target [18]. Dalam konteks prediksi volatilitas harga minyak mentah, *Random Forest* berpotensi mengekstrak interaksi antar indikator teknikal secara lebih komprehensif [19]. Pemanfaatan *Random Forest* juga tidak memerlukan asumsi ekonometrika yang ketat, sehingga memudahkan proses eksekusi komputasi pada dataset berskala besar. Eksplorasi performa algoritma ini pada data *out-of-sample* pasar komoditas menjadi krusial untuk menguji keandalan model di era volatilitas tinggi. Hasil evaluasi prediktif berbasis *Random Forest* diharapkan mampu memberikan estimasi numerik volatilitas yang akurat bagi para analis keuangan[20].

Meskipun algoritma *Random Forest* menawarkan berbagai keunggulan teoritis, penerapan praktisnya pada prediksi *time-series* finansial masih menghadapi peneliti pada sejumlah celah penelitian (*research gap*) yang signifikan. Sebagian besar studi terdahulu berfokus pada penerapan *Random Forest* menggunakan variabel input berupa nilai harga absolut mutlak seperti harga penutupan (*Close price*) dan nilai indikator teknikal tanpa transformasi [21]. Penggunaan data nilai absolut pada model berbasis pohon keputusan cenderung menciptakan bias regresi saat diuji pada data *out-of-sample* yang berada di luar rentang tren data latih (*regime shift*). Masalah keterbatasan ekstrapolasi ini menyebabkan model pohon gagal memprediksi nilai volatilitas ekstrem yang nilainya melampaui rentang data historis pada masa pelatihan. Fenomena ini tecermin dari munculnya evaluasi kinerja berupa nilai *Coefficient of Determination* (R^2) yang bernilai negatif pada data uji periode terkini [15]. R^2 yang negatif mengindikasikan bahwa kemampuan prediktif model bahkan lebih buruk dibandingkan dengan estimasi *baseline* menggunakan rata-rata sederhana [22]. Keterlambatan respons (*lagging*) model terhadap pergeseran volatilitas mendadak juga menjadi isu kritis yang belum terselesaikan secara optimal dalam literatur. Dominasi berlebihan dari salah satu indikator teknikal tertentu dalam pembentukan struktur pohon sering kali mengabaikan dinamika temporal jangka pendek. Oleh karena itu, dijumpai *gap* akademis yang nyata mengenai bagaimana menstrukturkan fitur input agar model *Random Forest* mampu beradaptasi terhadap perubahan rezim volatilitas. Mengatasi kelemahan ekstrapolasi ini menjadi fokus utama dalam pengembangan model prediksi finansial yang andal.

Analisis lebih mendalam terhadap *gap* penelitian menunjukkan bahwa faktor utama kegagalan R^2 pada pemodelan volatilitas adalah pengabaian sifat *non-stationarity* pada data harga komoditas. Ketika indikator teknikal dihitung berdasarkan nilai absolut harga, skala data input secara gradual mengalami pergeseran tren seiring berjalannya waktu. *Random Forest* tidak memiliki mekanisme bawaan untuk memproyeksikan tren di luar batas (*bound*) data sampel pelatihan. Akibatnya, sewaktu terjadi krisis atau gejolak harga baru, keputusan pembagian (*splitting*) pada *node* pohon menjadi tidak relevan dengan kondisi aktual pasar. Sebagian besar penelitian prediktif komoditas cenderung mengevaluasi performa model hanya menggunakan metrik error absolut seperti RMSE (*Root Mean Squared Error*) dan MAE (*Mean Absolute Error*). Penggunaan metrik error absolut secara tunggal kerap menyamarkan kegagalan korelasi tren, karena nilai error kecil tidak selalu menjamin kestabilan nilai R^2 . Terlebih lagi, ekstraksi indikator teknikal standar tanpa menyertakan fitur *lagged volatility* (volatilitas masa lalu) mengakibatkan kehilangan memori temporal (*temporal memory loss*) pada model. Volatilitas pasar keuangan terbukti secara empiris memiliki sifat *volatility clustering*, di mana periode volatilitas tinggi cenderung diikuti oleh volatilitas tinggi kembali. Ketiadaan fitur *lag* volatilitas historis sebagai variabel prediktor menyebabkan model *Random Forest* kehilangan pijakan historis yang paling berpengaruh [9]. Kelemahan metodologis inilah yang melatarbelakangi perlunya rekayasa fitur (*feature engineering*) yang lebih terstruktur dan berbasis stasioneritas.

2. METODOLOGI PENELITIAN


2.1 Kerangka Penelitian (*Research Framework / Workflow*)

Untuk menjamin keterulangan (*reproducibility*) serta keteraturan sistematika eksperimen, penelitian ini dirancang melalui kerangka kerja komputasi yang terstruktur secara berurutan. Kerangka penelitian ini memetakan seluruh tahapan eksekusi, mulai dari akuisisi data mentah hingga evaluasi performa prediktif *Random*

ISSN 2962-7966 (media online)
 Vol 4 No 1, Hal: 77-89

Forest Regressor. Pemisahan fungsional pada setiap tahapan bertujuan untuk memastikan bahwa manipulasi data tidak mengalami kebocoran informasi (*data leakage*) dari data latih ke data uji.

Secara visual, alur kerangka kerja penelitian ini disajikan dalam bentuk diagram alir (*flowchart*) pada Gambar 1.



Gambar 1. Kerangka Penelitian

Berdasarkan kerangka penelitian pada Gambar 1, tahapan eksperimen dibagi menjadi enam fase utama sebagai berikut:

- Fase Akuisisi Data (*Data Acquisition Phase*):**
 Proses diawali dengan penarikan data historis harian komoditas minyak mentah (*Crude Oil*) berformat *Open, High, Low, Close, Volume* (OHLCV) dari basis data Yahoo Finance secara otomatis menggunakan antarmuka pemrograman pustaka Python *yfinance*.
- Fase Pra-pemrosesan Data (*Data Preprocessing Phase*):**
 Data mentah yang diperoleh melalui verifikasi keutuhan nilai untuk memastikan ketiadaan data yang hilang (*missing values*). Pada fase ini, baris data yang mengandung *Null* akibat perhitungan nilai awal dieliminasi tanpa mengubah kesinambungan temporal *time-series*.
- Fase Rekayasa & Transformasi Fitur (*Feature Engineering & Transformation Phase*):**
 Pada tahap ini, fitur target berupa *Annualized Volatility 20-hari* dikalkulasi berdasarkan *log return* harian. Berbeda dengan pendekatan konvensional, seluruh fitur prediktor independen (SMA, RSI, Bollinger Bands) ditransformasi dari nilai nominal absolut menjadi bentuk rasio, perubahan persentase (*percentage change*), dan *lagged target volatility* (V_{t-1}) guna menjamin sifat stasioneritas data.

- d. Fase Pembagian Data Temporal (*Time-Series Data Splitting Phase*):
Dataset yang telah terstruktur dipisah secara sekuensial menjadi data latih (*training set*) sebesar 80% dan data uji (*testing set*) sebesar 20%. Pemisahan ini menerapkan skema *Time-Series Split* tanpa pengacakan (*non-random shuffle*) untuk merepresentasikan pengujian dunia nyata secara *out-of-sample*.
- e. Fase Pemodelan & Pelatihan (*Modeling & Training Phase*):
Algoritma *Random Forest Regressor* dilatih menggunakan data latih. Pada fase ini, diterapkan pembatasan eksplisit pada kedalaman maksimum pohon (*max_depth*) untuk mengontrol kompleksitas *node* dan mencegah timbulnya *overfitting*.
- f. Fase Evaluasi & Analisis Importansi (*Evaluation & Feature Importance Analysis Phase*):
Model yang telah dilatih dievaluasi terhadap data uji menggunakan metrik kuantitatif, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Coefficient of Determination* (R^2). Setelah model mencapai akurasi optimal dengan $R^2 > 0$, dilakukan ekstraksi nilai *feature importance* untuk menganalisis kontribusi relatif dari masing-masing indikator teknikal terhadap variabel target.

2.1 Pengumpulan Data (*Data Collection / Acquisition*)

Proses pengumpulan data pada penelitian ini dilakukan secara sekunder dengan memanfaatkan *Application Programming Interface* (API) dari platform penyedia data keuangan global Yahoo Finance melalui pustaka open-source Python *yfinance*. Komoditas yang menjadi objek kajian utama adalah minyak mentah jenis *West Texas Intermediate* (WTI) *Crude Oil Futures*, yang dipasahkan di bursa komoditas dan direpresentasikan oleh simbol kode *ticker* CL=F.

Data historis yang ditarik mencakup pergerakan harga harian dalam rentang waktu 9 tahun, terhitung mulai dari 1 Januari 2015 hingga 1 Januari 2024. Pemilihan rentang waktu ini didasarkan pada pertimbangan untuk menangkap berbagai variasi rezim pasar (*market regimes*), termasuk periode kondisi pasar stabil, krisis pandemi global COVID-19 pada tahun 2020, hingga gejolak ketegangan geopolitik dunia pada periode 2022–2023 yang memicu fluktuasi harga minyak secara signifikan.

Dataset mentah yang diperoleh terdiri dari atribut standar pasar modal berstruktur *time-series* harian dengan format OHLCV (*Open, High, Low, Close, Volume*). Rincian mengenai deskripsi variabel, tipe data, dan definisi operasional dari dataset mentah disajikan pada Tabel 1.

Tabel 1. Deskripsi Variabel Dataset Mentah *Crude Oil Futures* (CL=F)

Nama Variabel	Tipe Data	Satuan	Deskripsi Operasional
Date	Datetime (YYYY-MM-DD)	-	Tanggal transaksi harian perdagangan bursa.
Open	Float64	USD (\$)	Harga pembukaan perdagangan minyak mentah pada hari tersebut.
High	Float64	USD (\$)	Harga tertinggi yang dicapai selama jam perdagangan harian.
Low	Float64	USD (\$)	Harga terendah yang dicapai selama jam perdagangan harian.
Close	Float64	USD (\$)	Harga penutupan resmi transaksi minyak mentah di akhir hari perdagangan.
Adj Close	Float64	USD (\$)	Harga penutupan yang telah disesuaikan dengan dividen atau <i>split</i> .
Volume	Int64	Kontrak	Jumlah total kontrak futures minyak mentah yang diperdagangkan harian.

Total observasi data mentah yang berhasil diakuisisi dari API Yahoo Finance berjumlah 2.268 baris data harian (sesuai hari bursa aktif, tidak termasuk akhir minggu dan hari libur pasar modal). Data mentah ini kemudian disimpan dalam format struktur *DataFrame* berbasis Pandas untuk diproses lebih lanjut pada tahapan *preprocessing* dan rekayasa fitur (*feature engineering*).

Penggunaan instrumen data terintegrasi melalui *yfinance* ini menjamin aspek transparansi dan *reproducibility*, sehingga peneliti lain dapat mengunduh ulang dataset dengan parameter rentang waktu dan *ticker* yang sama secara presisi.

2.2 Pra-pemrosesan Data & Rekayasa Fitur (*Data Preprocessing & Feature Engineering*)

Tahap pra-pemrosesan data dan rekayasa fitur merupakan fase kritis untuk mentransformasikan data mentah OHLCV menjadi struktur dataset terstandarisasi yang stasioner. Langkah ini dirancang secara khusus untuk mengatasi kelemahan ekstrapolasi algoritma *Random Forest* terhadap data non-stasioner dan tren harga nominal mutlak.

2.2.1 Pembersihan Data (*Data Cleaning*)

Data historis bursa komoditas sering kali memiliki celah (*gaps*) akibat libur pasar modal. Langkah-langkah pembersihan data yang dilakukan meliputi:

- Pemeriksaan Nilai Hilang (*Missing Values*): Mengidentifikasi dan menghapus baris data yang mengandung nilai *Null* atau *NaN* yang muncul akibat jeda hari libur perdagangan.
- Eliminasi Windowing Lag: Perhitungan indikator teknikal berbasis jendela waktu (*rolling window*) menghasilkan *NaN* pada baris-baris awal dataset. Seluruh baris yang terdampak oleh proses pemotongan jendela (*windowing*) dieliminasi, sehingga menghasilkan dataset bersih yang kontinu tanpa merusak urutan temporal.

2.2.2 Formulasi Variabel Target Volatilitas (*Y*)

Variabel target yang akan diprediksi oleh model adalah volatilitas historis terannualisasi (*annualized historical volatility*) 20-hari (V_t). Pertama-tama, *log return* harian (R_t) dihitung dari harga penutupan (C_t) menggunakan Persamaan (1):

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

Selanjutnya, volatilitas 20-hari terannualisasi (V_t) dihitung berdasarkan standar deviasi dari *log return* harian dalam jendela bergerak (*rolling window*) 20 hari perdagangan, yang diskalakan dengan faktor $\sqrt{252}$ (asumsi 252 hari kerja bursa dalam satu tahun) sesuai Persamaan (2):

$$V_t = \sqrt{\frac{1}{N-1} \sum_{i=0}^{N-1} (R_{t-i} - \bar{R}_t)^2} \times \sqrt{252} \quad (2)$$

di mana $N = 20$ dan $\bar{R}_t$ adalah rata-rata *log return* selama periode 20 hari tersebut.

2.2.3 Rekayasa Fitur Stasioner (*X*)

Untuk mencegah kecenderungan model *Random Forest* menghafal skala harga absolut, seluruh indikator teknikal ditransformasikan ke dalam bentuk nilai relatif dan stasioner sebagai variabel independen prediktor:

- Persentase Perubahan Harga (*Price Percentage Change*): Mengukur return harian sederhana untuk menghilangkan tren nominal harga:

$$P_{\text{change},t} = \frac{C_t - C_{t-1}}{C_{t-1}} \quad (3)$$

- Rasio Pergerakan Rata-Rata (*Moving Average Ratio*): Menghitung perbandingan antara *Simple Moving Average* (SMA) jangka pendek (10 hari) dan jangka menengah (50 hari) untuk menangkap pergeseran tren secara independen dari skala harga:

$$\text{SMA}_{\text{Ratio},t} = \frac{\text{SMA}_{10,t}}{\text{SMA}_{50,t}} = \frac{\frac{1}{10} \sum_{i=0}^9 C_{t-i}}{\frac{1}{50} \sum_{i=0}^{49} C_{t-i}} \quad (4)$$

- Relative Strength Index terstandarisasi (RSI_{14}): Mengukur momentum perubahan harga dalam rentang terdistribusi $[0, 100]$ berdasarkan rata-rata kenaikan (U) dan penurunan (D) selama 14 hari:

$$\text{RSI}_{14,t} = 100 - \left(\frac{100}{1 + \frac{\text{EMA}_{14}(U_t)}{\text{EMA}_{14}(D_t)}} \right) \quad (4)$$

- Karakteristik Bollinger Bands Relatif: Alih-alih menggunakan nilai harga batas atas (*Upper Band*) dan batas bawah (*Lower Band*) secara mutlak, dihitung nilai lebar pita relatif (*Bandwidth*) yang merepresentasikan kompresi dan ekspansi volatilitas:

$$\text{BB}_{\text{Bandwidth},t} = \frac{\text{BB}_{\text{Upper},t} - \text{BB}_{\text{Lower},t}}{\text{BB}_{\text{Middle},t}} = \frac{4 \cdot \sigma_{20,t}}{\text{SMA}_{20,t}} \quad (5)$$

- Lagged Target Volatility (V_{t-1}): Untuk memberikan memori temporal (*temporal memory*) dan menangkap fenomena autokorelasi *volatility clustering*, nilai volatilitas satu hari sebelumnya (V_{t-1}) dimasukkan sebagai salah satu prediktor utama:

$$\text{Lag}_1(V_t) = V_{t-1}$$

Melalui serangkaian transformasi ini, matriks fitur input $X_t = \{P_{\text{change},t}, \text{SMA}_{\text{Ratio},t}, \text{RSI}_{14,t}, \text{BB}_{\text{Bandwidth},t}, V_{t-1}\}$ sepenuhnya bersifat stasioner dan terbebas dari bias nilai harga historis mutlak.

2.3 Pemodelan & Skema Pembagian Data (*Model Architecture & Data Splitting*)

Tahap pemodelan melibatkan konfigurasi arsitektur algoritma *Random Forest Regressor* serta skema pembagian dataset temporal yang dirancang khusus untuk menghindari kebocoran data (*data leakage*).

2.3.1 Skema Pembagian Data Temporal (*Time-Series Data Splitting*)

Dalam data deret waktu keuangan, penerapan metode *k-fold cross-validation* standar atau *random train-test split* tidak dapat digunakan karena akan merusak struktur dependensi waktu dan menyebabkan kebocoran informasi masa depan (*look-ahead bias*). Oleh karena itu, penelitian ini menerapkan skema Time-Series Split secara sekuensial berdasarkan urutan kronologis tanggal. Dataset stasioner hasil rekayasa fitur dibagi dengan rasio 80:20:

- Data Latih (*Training Set*): Mencakup 80% data awal secara kronologis (1.753 sampel harian) yang digunakan untuk melatih model dan membangun pohon-pohon keputusan.
- Data Uji (*Testing Set*): Mencakup 20% data akhir secara kronologis (439 sampel harian) yang difungsikan sebagai data *out-of-sample* untuk menguji keandalan dan daya generalisasi model secara riil.

2.3.2 Arsitektur Algoritma Random Forest Regressor

Random Forest Regressor adalah algoritma *ensemble learning* berbasis *bagging* (*bootstrap aggregating*) yang menggabungkan B buah pohon keputusan (*decision trees*) independen. Prediksi akhir diperoleh melalui rata-rata agregat dari prediksi seluruh pohon individual. Mekanisme matematis pembentukan model dijelaskan sebagai berikut:

- Bootstrap Sampling: Dari data latih $\mathcal{D}$ berukuran N , diambil sampel acak dengan pengembalian $\mathcal{D}_b$ sebanyak B kali ($b = 1, 2, \dots, B$).
- Pembangunan Pohon (*Decision Tree Construction*): Untuk setiap sampel bootstrap $\mathcal{D}_b$, sebuah pohon regresi $T_b(x)$ dibangun. Pada setiap simpul (*node*), dilakukan pencarian pemisahan terbaik (*best split*) berdasarkan kriteria penurunan *Mean Squared Error* (MSE) terkecil:

$$MSE_{\text{node}} = \frac{1}{N_m} \sum_{i \in \mathcal{D}_m} (y_i - \bar{y}_m)^2 \quad (6)$$

di mana N_m adalah jumlah sampel pada simpul m , y_i adalah nilai volatilitas aktual, dan $\bar{y}_m$ adalah rata-rata nilai target pada simpul tersebut.

- Prediksi Agregat (*Ensemble Prediction*): Untuk sebuah vektor masukan fitur stasioner x , nilai prediksi volatilitas akhir $\hat{y}$ dihitung melalui Persamaan:

$$\hat{y}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (7)$$

2.3.3 Konfigurasi dan Restriksi Hyperparameter

Guna membatasi kompleksitas pohon serta mencegah *overfitting* yang memicu nilai R^2 negatif pada data uji, diterapkan pengaturan *hyperparameter constraint* sebagai berikut:

- `n_estimators = 100`: Membangun 100 pohon keputusan untuk memastikan kestabilan estimasi rata-rata ensemble.
- `max_depth = 5`: Membatasi kedalaman maksimum setiap pohon keputusan hingga 5 tingkat. Pembatasan ini sangat krusial untuk mencegah pohon menghafal *noise* pada data latih serta menjaga daya ekstrapolasi model.
- `min_samples_split = 10`: Menetapkan batas minimal 10 sampel pada sebuah simpul internal agar simpul tersebut dapat dipisah lebih lanjut.
- `random_state = 42`: Mengunci benih acak (*random seed*) untuk menjamin konsistensi dan keterulangan (*reproducibility*) hasil eksperimen.

2.4 Metrik Evaluasi Performa (*Performance Evaluation Metrics*)

Guna mengukur keakuratan, kestabilan, dan daya generalisasi model *Random Forest Regressor* dalam memprediksi volatilitas harga minyak mentah pada data *out-of-sample*, digunakan tiga metrik evaluasi kuantitatif standar dalam pemodelan prediktif deret waktu: Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Coefficient of Determination (R^2 Score).

Metrik-metrik ini dihitung dengan membandingkan nilai volatilitas aktual (y_i) terhadap nilai volatilitas hasil prediksi model ($\hat{y}_i$) pada *testing set* sejumlah n observasi.

2.4.1 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) mengukur akar kuadrat dari rata-rata selisih kuadrat antara nilai volatilitas prediksi dan nilai aktual. Metrik ini memberikan bobot hukuman (*penalty*) yang lebih tinggi terhadap kesalahan prediksi (*error*) berukuran besar atau deviasi ekstrem. Persamaan matematis RMSE didefinisikan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Nilai RMSE yang semakin mendekati nol mengindikasikan bahwa deviasi prediksi terhadap data aktual semakin kecil dan akurasi model semakin tinggi.

2.4.2 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata besaran kesalahan magnitudo absolute antara hasil prediksi dan data aktual tanpa memperhatikan arah deviasi (positif atau negatif). Berbeda dengan RMSE, MAE memberikan pembobotan linier sehingga tidak terlalu sensitif terhadap data pencilan (*outliers*). Persamaan matematis MAE dirumuskan sebagai berikut:

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

Metrik MAE memberikan gambaran rata-rata tingkat kesalahan riil yang dapat diekspektasikan oleh analis atau manajer risiko secara langsung.

2.4.3 Coefficient of Determination (R^2 Score)

Coefficient of Determination (R^2) mengukur proporsi varians variabel target (volatilitas) yang mampu dijelaskan oleh variabel-variabel independen (fitur stasioner dan indikator teknikal) di dalam model. Persamaan matematis R^2 didefinisikan sebagai:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

di mana SS_{res} adalah *Sum of Squared Residuals*, SS_{tot} adalah *Total Sum of Squares*, dan $\bar{y}$ adalah rata-rata dari nilai volatilitas aktual pada data uji. Interpretasi nilai R^2 pada pengujian *out-of-sample* adalah sebagai berikut:

- $R^2 = 1.0$: Model sempurna (*perfect fit*).
- $0 < R^2 < 1.0$: Model memiliki daya prediktif yang valid dan mampu menjelaskan variasi tren data.
- $R^2 \leq 0$: Model gagal memprediksi pola *out-of-sample* dan kinerjanya lebih buruk dibandingkan dengan estimasi *baseline* menggunakan nilai rata-rata sederhana ($\bar{y}$). Perbaikan rekayasa fitur stasioner pada penelitian ini berfokus utama untuk mentransformasi nilai R^2 dari negatif menjadi positif ($R^2 > 0$).

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi & Eksplorasi Dataset (*Data Exploration & Visual Inspection*)

Tahap awal analisis dilakukan melalui eksplorasi data secara visual dan kalkulasi statistik deskriptif terhadap data historis minyak mentah jenis WTI (*Crude Oil Futures*, CL=F) hasil akuisisi rentang waktu 2015 hingga 2024. Eksplorasi ini bertujuan untuk memahami dinamika pergerakan harga nominal, karakteristik distribusi volatilitas target (V_t), serta sifat fitur-fitur stasioner yang telah ditransformasi.

3.1.1 Statistik Deskriptif Variabel Penelitian

Tabel 2 menyajikan ringkasan statistik deskriptif untuk variabel target volatilitas terannualisasi 20-hari (V_t) serta fitur-fitur prediktor stasioner hasil rekayasa fitur (*feature engineering*).

Tabel 2. Statistik Deskriptif Variabel Target dan Fitur Stasioner ($N = 2.218$)

Nama Variabel	Mean	Std. Dev	Min	Median	Max	Skewness
Target Volatilitas (V_t)	0,3842	0,2156	0,1120	0,3315	2,8451	3,124
Price_Pct_Change	0,0005	0,0312	-0,5597	0,0011	0,3766	-1,842
SMA_Ratio	1,0032	0,0584	0,6120	1,0081	1,2890	-0,412
RSI_14	52,142	11,284	12,410	52,810	85,920	-0,128
BB_Bandwidth	0,1894	0,1105	0,0512	0,1610	1,4821	2,891
Volatilitas_Lag1 (V_{t-1})	0,3841	0,2155	0,1120	0,3314	2,8451	3,126

Berdasarkan Tabel 2, variabel target volatilitas (V_t) memiliki rata-rata (*mean*) sebesar 0,3842 (38,42%) dengan nilai maksimum mencapai 2,8451 (284,51%). Nilai volatilitas ekstrem tersebut terjadi pada periode April 2020 akibat penurunan permintaan global yang memicu harga futures minyak sempat menyentuh area negatif. Tingginya nilai *skewness* positif (3,124) pada V_t menandakan bahwa distribusi volatilitas cenderung miring ke kanan (*right-skewed*) dengan keberadaan nilai pencilan (*outliers*) ekstrem akibat guncangan pasar (*market shocks*).

Sebaliknya, fitur-fitur prediktor stasioner seperti SMA_Ratio dan RSI_14 menunjukkan distribusi yang relatif seimbang di sekitar nilai tengahnya. SMA_Ratio berada pada rata-rata 1,0032 dengan deviasi standar yang


ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 77-89

terlampau kecil (0,0584), mengonfirmasi bahwa transformasi rasio berhasil menghilangkan tren nominal harga dan menjaga variabel dalam rentang batas (*bounded*) yang konsisten.

3.1.2 Inspeksi Visual Tren Pergerakan Harga vs Volatilitas Historis

Gambar 2 menampilkan perbandingan visual antara kurva harga penutupan nominal harian minyak mentah (*Close Price*) dan kurva volatilitas terannualisasi 20-hari (V_t) sepanjang periode penelitian (2015–2024).



Gambar 2. Perbandingan Kurva Harga Penutupan Harian

Melalui Gambar 2, dapat diidentifikasi tiga rezim volatilitas utama (*volatility regimes*) dalam dataset:

- Periode Stabil (2015–2019): Fluktuasi harga bergerak dalam kisaran USD 40–70 dengan volatilitas relatif tenang pada rentang 0,20–0,40.
- Rezim Anomali Pandemi COVID-19 (Awal 2020): Terjadi kejatuhan harga secara drastis yang diikuti oleh lonjakan (*spike*) volatilitas tertinggi dalam sejarah komoditas energi (mencapai > 2,80).
- Rezim Geopolitik & Inflasi (2022–2023): Konflik geopolitik Rusia-Ukraina mendorong harga minyak melonjak melebihi USD 110/barel, yang kemudian memicu periode volatilitas tinggi berkepanjangan pada rentang 0,40–0,85.

Inspeksi visual ini membuktikan keberadaan fenomena *volatility clustering* secara empiris, di mana periode volatilitas tinggi selalu berkelompok dalam satu durasi waktu tertentu. Sifat autokorelasi temporal ini memperkuat landasan metodologis pengikutsertaan variabel *lagged volatility* (V_{t-1}) dalam skema rekayasa fitur

3.2 Hasil Evaluasi Performa Model (*Performance Evaluation Results*)

Evaluasi kuantitatif dilakukan untuk menguji efektivitas rekayasa fitur berbasis stasioneritas dan penerapan *hyperparameter constraint* ($\text{max_depth} = 5$) pada algoritma *Random Forest Regressor*. Pengujian dilakukan dengan membandingkan dua skenario eksperimen pada dataset *out-of-sample* (data uji sekuensial periode 2022–2024, $N = 439$):

- Model Baseline (Model Awal): Dilatih menggunakan fitur-fitur harga nominal mutlak (Close, SMA_10, SMA_50, RSI_14, BB_Upper, BB_Lower) tanpa pembatasan kedalaman pohon ($\text{max_depth} = \text{None}$).
- Model Teroptimasi (Model Usulan): Dilatih menggunakan fitur-fitur stasioner terstandarisasi (Price_Pct_Change, SMA_Ratio, RSI_14, BB_Bandwidth) ditambah variabel *lagged volatility* (V_{t-1}) dengan pembatasan kedalaman pohon ($\text{max_depth} = 5$).

3.2.1 Perbandingan Performa Kuantitatif

Tabel 3 menyajikan hasil evaluasi metrik kinerja kuantitatif (RMSE, MAE, dan R^2 Score) untuk kedua skenario pemodelan pada *training set* dan *testing set*.

Tabel 3. Perbandingan Kinerja Prediktif Model Baseline vs Model Teroptimasi

Skenario Pemodelan	Dataset	RMSE	MAE	R2 Score	Evaluasi Kinerja
Model Baseline (<i>Nominal Fitur</i>)	Training Set	0,0214	0,0122	0,9892	<i>Overfitting</i> Ekstrem
	Testing Set	0,1597	0,1112	-1,1664	Gagal Ekstrapolasi
Model Teroptimasi (<i>Fitur Stasioner + Lag-1</i>)	Training Set	0,0285	0,0184	0,9811	Optimal & General
	Testing Set	0,0312	0,0205	0,9174	Valid ($R^2 > 0$)

3.2.2 Analisis Komparatif dan Identifikasi *Overfitting*

Berdasarkan hasil eksperimen pada Tabel 3, diperoleh beberapa temuan akademis utama sebagai berikut:

- Kegagalan Ekstrapolasi pada Model Baseline:

Model *baseline* mencatatkan kinerja luar biasa pada data latih dengan $R^2 = 0,9892$, namun kinerjanya merosot drastis saat diuji pada data uji *out-of-sample* dengan nilai $R^2 = -1,1664$. Nilai R^2 yang bernilai negatif secara matematis mengonfirmasi bahwa model *baseline* gagal menangkap pola tren baru pada periode 2022–2024. Pohon keputusan yang tumbuh tanpa batas ($\text{max_depth} = \text{None}$) menghafal skala harga nominal masa lalu,

sehingga ketika harga pasar bergeser ke rezim baru (*regime shift*), pemisahan simpul (*node splitting*) menghasilkan bias prediksi yang masif.

b. Perbaikan Kinerja pada Model Teroptimasi:

Penerapan fitur stasioner dan pembatasan kedalaman pohon ($\text{max_depth} = 5$) berhasil menyelesaikan permasalahan ekstrapolasi secara signifikan. Pada *testing set*, nilai R^2 berhasil melompat dari -1,1664 menjadi +0,9174. Hal ini membuktikan bahwa 91,74% varians volatilitas minyak mentah pada data *out-of-sample* mampu dijelaskan secara presisi oleh model teroptimasi.

c. Penurunan Tingkat Kesalahan (*Error Metrics*):

Model teroptimasi berhasil memangkas nilai kesalahan prediksi secara substansial. Nilai RMSE berkurang sebesar 80,46% (dari 0,1597 menjadi 0,0312), sedangkan MAE berkurang sebesar 81,56% (dari 0,1112 menjadi 0,0205). Penurunan drastis pada RMSE mengindikasikan bahwa model usulan sangat efektif dalam meminimalisasi deviasi ekstrem (*large residuals*) saat terjadi fluktuasi pasar mendadak.


Rangkaian hasil evaluasi kuantitatif ini membuktikan hipotesis penelitian bahwa masalah R^2 negatif pada regresi deret waktu berbasis *Random Forest* bukan disebabkan oleh keterbatasan bawaan algoritma, melainkan akibat ketidaksesuaian struktur fitur input yang tidak stasioner.

3.3 Visualisasi Prediksi vs Data Aktual (*Actual vs Predicted Volatility Visualization*)

Guna memberikan pemahaman kualitatif dan intuisi visual mengenai performa model, dilakukan pemetaan kurva volatilitas aktual (y) terhadap kurva volatilitas hasil prediksi ($\hat{y}$) pada *testing set* (April 2022–Januari 2024, $N = 439$). Evaluasi visual ini difokuskan pada dua aspek utama: kemampuan model dalam merespons fenomena keterlambatan (*lagging effect*) dan ketepatan model dalam mengestimasi puncak lonjakan (*spikes*) volatilitas.

3.3.1 Perbandingan Visual Tren Terintegrasi

Gambar 3 menyajikan perbandingan visual lintasan kurva volatilitas aktual dengan hasil prediksi dari Model *Baseline* (tanpa rekayasa fitur) dan Model Teroptimasi (fitur stasioner + V_{t-1}).



Gambar 3. Perbandingan Visual Lintasan Kurva Volatilitas Aktual Dengan Hasil Prediksi

3.3.2 Analisis Karakteristik Kurva Prediksi

Berdasarkan inspeksi visual pada Gambar 3, dapat ditarik tiga poin analisis utama mengenai perilaku kedua model:

a. Eliminasi Masalah *Overshooting* dan *Lagging*:

Pada Model *Baseline* (garis merah terputus-putus pada grafik awal download.png), prediksi volatilitas mengalami deviasi ekstrem (*overshoot*) hingga menyentuh angka 0,90 pada pertengahan tahun 2022, sementara nilai aktualnya hanya berada pada kisaran 0,50–0,60. Sebaliknya, Model Teroptimasi mampu menempel ketat (*closely track*) lintasan volatilitas aktual tanpa mengalami *overshoot*. Fenomena *lagging* (keterlambatan respons perubahan arah) yang sebelumnya mendominasi model *baseline* berhasil dihilangkan berkat masuknya variabel *lagged target volatility* (V_{t-1}).

b. Presisi Penangkapan Puncak Lonjakan (*Volatility Spikes*):

Selama periode uji, terdapat beberapa lonjakan volatilitas akibat dinamika pasar komoditas energi (seperti pada April 2022, Januari 2023, dan akhir 2023). Model Teroptimasi terbukti mampu mengestimasi besaran magnitudo puncak lonjakan tersebut secara akurat. Penyesuaian kurva prediksi pada area puncak dan lembah (*peaks and troughs*) menunjukkan bahwa model tidak hanya menghafal tren rata-rata, tetapi juga peka terhadap perubahan akselerasi volatilitas jangka pendek.

c. Stabilitas Prediksi pada Periode *Low Volatility*:

Pada rentang Juli hingga Oktober 2023, volatilitas minyak mentah mengalami penurunan bertahap menuju area relatif rendah (0,15–0,25). Model Teroptimasi tetap konsisten berada dalam garis trayektori yang sama dengan data aktual dan tidak menghasilkan fluktuasi *spurious* (sinyal palsu). Kestabilan ini mengonfirmasi bahwa pembatasan kedalaman pohon ($\text{max_depth} = 5$) berhasil mencegah model merekam *noise* acak pada data bursa harian.

ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 77-89

Rangkaian visualisasi ini memperkuat bukti kuantitatif sebelumnya ($R^2 = 0,9174$), yang menunjukkan bahwa rekonstruksi fitur stasioner membuat *Random Forest Regressor* sangat andal dalam memprediksi pola *time-series* finansial secara realitis.


3.4 Analisis Tingkat Pengaruh Fitur (*Feature Importance Analysis*)

Salah satu keunggulan utama dari algoritma *Random Forest Regressor* dibandingkan arsitektur *black-box* (seperti *Deep Learning*) adalah kemampuannya menyajikan interpretabilitas model melalui kalkulasi *feature importance*. Nilai *feature importance* dihitung berdasarkan kontribusi relatif setiap variabel independen dalam menurunkan *Mean Squared Error* (MSE) pada setiap pemisahan simpul (*node split*) di seluruh pohon keputusan.

3.4.1 Perbandingan Redistribusi Importansi Fitur

Eksperimen awal pada Model *Baseline* (menggunakan harga nominal mutlak) menghasilkan redistribusi bobot yang sangat timpang, di mana indikator BB_Lower mendominasi pembentukan keputusan dengan bobot lebih dari 0,70 (70%), sementara indikator teknikal lainnya (seperti RSI dan SMA) hampir diabaikan. Dominasi tunggal ini terjadi karena model memperlakukan batas bawah nominal sebagai ambang batas absolut, yang mengakibatkan model rentan gagal saat terjadi pergeseran tren (*regime shift*).

Pasca-penerapan rekayasa fitur stasioner dan penyertaan variabel *lagged target volatility* (V_{t-1}), distribusi nilai *feature importance* mengalami redistribusi yang jauh lebih proporsional dan rasional secara teoritis. Gambar 4 menyajikan peringkat dan besaran nilai importansi dari masing-masing fitur stasioner pada Model Teroptimasi.



Gambar 4. Fitur Prediktor

3.4.2 Interpretasi Ekonometrika dan Praktis Indikator

Berdasarkan hasil kalkulasi importansi fitur pada Gambar 4, dapat ditarik beberapa analisis teoritis dan praktis sebagai berikut:

- Peran Dominan *Lagged Target Volatilitas* ($V_{t-1} = 0,624$):
Variabel *lagged volatility* (V_{t-1}) memegang kontribusi terbesar yaitu 62,4%. Temuan ini secara empiris mengonfirmasi keberadaan sifat autokorelasi temporal dan fenomena *volatility clustering* pada pasar komoditas energi, di mana volatilitas hari kemarin merupakan prediktor paling tegar (*robust*) untuk menentukan tingkat volatilitas hari ini.
- Signifikansi Lebar Pita Bollinger relatif (BB_Bandwidth = 0,182):
BB_Bandwidth memberikan kontribusi sebesar 18,2%. Transformasi dari nilai nominal (BB_Lower/BB_Upper) menjadi rasio lebar pita relatif terbukti efektif. Variabel ini menjadi indikator teknikal terkuat dalam mengukur kompresi (periode tenang) dan ekspansi (periode gejolak) pasar tanpa terikat pada skala nominal harga minyak.
- Kontribusi Indikator Momentum & Tren (RSI_14, SMA_Ratio, Price_Pct_Change):
Indikator momentum RSI_14 menyumbang 9,5%, diikuti oleh SMA_Ratio sebesar 5,8%, dan Price_Pct_Change sebesar 4,1%. Penggabungan ketiga indikator ini memberikan informasi pelengkap (*complementary features*) mengenai kejenuhan pasar (*overbought/oversold*) serta akselerasi perubahan harga harian.

Redistribusi bobot yang seimbang ini membuktikan bahwa rekonstruksi fitur berbasis stasioneritas berhasil menghilangkan bias ketersediaan skala (*scale-availability bias*), sehingga *Random Forest Regressor* mampu memanfaatkan seluruh sinyal indikator teknikal secara terintegrasi untuk menghasilkan prediksi volatilitas yang akurat.

3.5 Pembahasan & Implikasi Riset (*Discussion & Practical Implications*)

Pada sub-bab ini, temuan kuantitatif dan visual dari eksperimen dibahas secara akademis untuk menguraikan kontribusi teoritis, perbandingan dengan studi terdahulu, implikasi praktis bagi manajemen risiko, serta keterbatasan model yang ditemukan.

3.5.1 Pembahasan Akademis dan Konfirmasi Novelty

Keberhasilan membalikkan nilai *Coefficient of Determination* (R^2) dari -1,1664 menjadi +0,9174 memberikan bukti empiris mengenai cara mengatasi kelemahan ekstrapolasi algoritma berbasis *decision tree* pada data *time-series* finansial. Algoritma *Random Forest* secara alami melakukan pemisahan ruang fitur (*space splitting*) berbentuk ortogonal yang bersifat konstan di luar rentang data pelatihan (*out-of-bound extrapolation*). Ketika fitur input disajikan dalam bentuk harga nominal mutlak (Close, SMA), pergeseran rezim harga pasar (*regime shift*) menyebabkan model mengeksekusi *node* keputusan yang tidak sesuai dengan kondisi aktual, sehingga memicu eror prediksi yang masif.

Transformasi fitur menjadi variabel stasioner terstandarisasi (Price_Pct_Change, SMA_Ratio, BB_Bandwidth) secara efektif menghapus bias skala (*scale bias*) tersebut. Ditambah dengan penyertaan variabel *lagged target volatility* (V_{t-1}), model diberi kemampuan memori temporal untuk menangkap fenomena *volatility clustering* sifat ekonometrika klasik di mana periode volatilitas tinggi cenderung persisten dan diikuti oleh volatilitas tinggi kembali. Integrasi antara rekayasa fitur stasioner dan restriksi kedalaman pohon ($\text{max_depth} = 5$) terbukti secara metodologis mampu menjaga kestabilan generalisasi model tanpa kehilangan daya prediktifnya.

3.5.2 Perbandingan dengan Penelitian Terkait

Temuan penelitian ini sejalan dan memperkuat beberapa literatur terdahulu di bidang *computational finance*:

- Perbandingan dengan Pemodelan Klasik: Hasil penelitian ini mendukung temuan Nguyen & Tran (2023) yang menyatakan bahwa pendekatan regresi non-parametrik *machine learning* mampu mengungguli model ekonometrika klasik (seperti GARCH atau ARIMA) dalam menangkap perilaku non-linear volatilitas minyak mentah, terutama saat terjadi guncangan pasar (*market shocks*).
- Atrikbasi Rekayasa Fitur: Penelitian ini mengonfirmasi argumen Zhao & Sun (2022) mengenai pentingnya *feature engineering* pada indikator teknikal. Penggunaan rasio relatif alih-alih nilai absolut terbukti mencegah timbulnya nilai R^2 negatif pada pengujian *out-of-sample*.
- Alternatif terhadap Deep Learning: Sebagian besar studi terkini (misal: Wang & Liu, 2023) cenderung beralih ke arsitektur *Deep Learning* seperti LSTM untuk menghindari masalah ekstrapolasi. Namun, hasil penelitian ini membuktikan bahwa *Random Forest* yang jauh lebih ringan secara komputasi dan memiliki tingkat interpretabilitas tinggi melalui *feature importance* dapat mencapai tingkat akurasi yang sepadan ($R^2 > 0,90$) apabila diintegrasikan dengan kerangka kerja rekayasa fitur yang tepat.

3.5.3 Implikasi Praktis (*Practical Implications*)

Secara praktis, model prediksi volatilitas teroptimasi ini memberikan kontribusi konkrit bagi para pelaku industri keuangan dan komoditas:

- Bagi Manajer Risiko & Trader Komoditas: Estimasi volatilitas harian yang akurat ($MAE = 0,0205$) memungkinkan penentuan nilai *Value at Risk* (VaR) yang lebih presisi. Informasi ini sangat krusial dalam merancang strategi lindung nilai (*hedging*) menggunakan instrumen derivatif seperti *options* dan *futures* minyak mentah WTI.
- Bagi Pengambil Kebijakan Energi: Model ini dapat dimanfaatkan oleh instrumen pemerintah atau BUMN sektor energi untuk mengantisipasi ketidakpastian harga impor minyak mentah, sehingga perencanaan subsidi BBM dan anggaran belanja negara dapat dirancang dengan tingkat margin risiko yang lebih terukur.
- Transparansi Keputusan (*Explainable AI*): Informasi *feature importance* yang menunjukkan dominasi V_{t-1} (62,4%) dan BB_Bandwidth (18,2%) memberikan panduan transparan bagi analis pasar untuk memprioritaskan indikator mana yang harus dipantau secara *real-time* saat mengevaluasi risiko pasar.

3.5.4 Keterbatasan Penelitian (*Research Limitations*)

Meskipun model teroptimasi mencatatkan performa prediktif yang sangat tinggi, terdapat beberapa keterbatasan yang perlu dicatat untuk penelitian selanjutnya:

- Kejutan Geopolitik Mendadak (*Unpredictable Black-Swan Events*): Model hanya mengandalkan indikator teknikal kuantitatif berbasis data historis harga. Oleh karena itu, model tetap memiliki keterbatasan dalam mengantisipasi guncangan mendadak yang disebabkan oleh faktor eksternal non-kuantitatif, seperti pengumuman kuota produksi OPEC+ yang tidak terduga atau eskalasi konflik militer secara tiba-tiba.
- Keterbatasan Variabel Makroekonomi: Penelitian ini belum memasukkan variabel fundamental makroekonomi (seperti nilai tukar USD, tingkat suku bunga FED, atau persediaan stok minyak AS / *EIA Crude Oil Inventories*) yang berpotensi meningkatkan daya jelas model pada horizon prediksi jangka panjang.

4. KESIMPULAN

Berdasarkan hasil eksperimen, evaluasi kuantitatif, dan pembahasan yang telah dipaparkan pada bab-bab sebelumnya, penelitian mengenai prediksi volatilitas harga minyak mentah (*Crude Oil Futures*, CL=F) berbasis

Random Forest Regressor ini menghasilkan beberapa kesimpulan utama sebagai berikut: Penerapan rekayasa fitur berbasis stasioneritas terbukti secara metodologis mampu menyelesaikan masalah kelemahan ekstrapolasi algoritma *Random Forest Regressor* pada data deret waktu finansial. Transformasi fitur dari nilai nominal mutlak menjadi variabel stasioner terstandarisasi (Price_Pct_Change, SMA_Ratio, BB_Bandwidth) yang dikombinasikan dengan *lagged target volatility* (V_{t-1}) serta pembatasan kedalaman pohon (max_depth = 5) berhasil melompati nilai *Coefficient of Determination* (R^2) pada pengujian *out-of-sample* dari -1,1664 (pada Model Baseline) menjadi +0,9174 (pada Model Teroptimasi). Model teroptimasi terbukti sangat presisi dan konsisten dalam memprediksi fluktuasi volatilitas minyak mentah pada periode krisis/gejolak pasar (2022–2024). Hal ini dibuktikan oleh penurunan tingkat kesalahan prediksi secara drastis, di mana nilai RMSE berkurang sebesar 80,46% (dari 0,1597 menjadi 0,0312) dan nilai MAE berkurang sebesar 81,56% (dari 0,1112 menjadi 0,0205). Penggunaan fitur stasioner berhasil menghilangkan bias dominasi tunggal indikator nominal (BB_Lower > 70%). Model teroptimasi menyajikan redistribusi bobot keputusan yang jauh lebih rasional dan terinterpretasi secara ekonometrika: Volatilitas_Lag1 (V_{t-1}) memegang peran paling dominan sebesar 62,4%, mengonfirmasi fenomena *volatility clustering* pada pasar energi. BB_Bandwidth berkontribusi sebesar 18,2% sebagai indikator ekspansi/kompresi risiko. Indikator momentum dan tren (RSI_14, SMA_Ratio, dan Price_Pct_Change) menyumbang total 19,4% sebagai informasi pelengkap. Penelitian ini memberikan bukti empiris bahwa algoritma berbasis *decision tree*/pohon keputusan (seperti *Random Forest*) yang sering dianggap tidak cocok untuk data deret waktu tren non-stasioner, dapat diubah menjadi model prediktif yang sangat andal ($R^2 > 0,90$) tanpa perlu beralih ke arsitektur *Deep Learning* yang rumit, selama input data ditransformasikan ke dalam bentuk stasioner yang terstruktur. Model yang dikembangkan dapat diterapkan secara langsung oleh manajer risiko, *trader* komoditas, dan lembaga keuangan untuk menghitung *Value at Risk* (VaR) serta merancang strategi lindung nilai (*hedging*) yang lebih presisi menggunakan instrumen derivatif minyak mentah. Guna menyempurnakan dan memperluas cakupan penelitian ini di masa mendatang, beberapa saran rute penelitian lanjutan yang direkomendasikan adalah menggabungkan indikator teknikal stasioner dengan data analisis sentimen berita keuangan (menggunakan NLP/IndoBERT) serta variabel makroekonomi (seperti nilai tukar USD dan tingkat suku bunga) untuk meningkatkan kepekaan model terhadap kejutan politik/geopolitik mendadak. Menerapkan kerangka kerja rekayasa fitur stasioner ini pada instrumen keuangan lain yang memiliki karakteristik volatilitas tinggi, seperti Emas (GC=F), Gas Alam (NG=F), atau aset kripto (Bitcoin/Ethereum). Membandingkan kinerja *Random Forest Teroptimasi* dengan algoritma *Gradient Boosting* terkini seperti XGBoost, LightGBM, atau CatBoost yang dikombinasikan dengan metode optimasi hyperparameter berbasis *Bayesian Optimization*.

REFERENCES

- [1] A. Rakhman, J. Dinamika, D. Harga, M. Mentah, P. Pertumbuhan, and E. Indonesia, "Dinamika Ekspor-Impor dan Harga Minyak Mentah sebagai Penggerak Pertumbuhan Ekonomi Indonesia The Dynamics of Exports-Imports and Crude Oil Prices as Drivers of Indonesia's Economic Growth."
- [2] E. Soesanto *et al.*, "Dampak Fluktuasi Harga Minyak Dunia Terhadap Ekonomi Di Indonesia," vol. 2, no. 1, pp. 231–242, 2025.
- [3] "4".
- [4] O. Tanaya, Rr. S. Kanti Wilujeng, and I. Putri Radjainan, "Foreign Direct Investment dan Risiko Politik di ASEAN," *Owner*, vol. 6, no. 2, pp. 1610–1620, Mar. 2022, doi: 10.33395/owner.v6i2.805.
- [5] E. S. Ramadhani, D. Devianto, and F. Yanuar, "Model Pergerakan Harga Minyak Mentah Brent Menggunakan Pendekatan Time Series Dengan Efek Long Memory," *Jurnal Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, vol. 5, no. 3, pp. 1673–1686, Dec. 2024, doi: 10.46306/lb.v5i3.746.
- [6] A. O. Madhani, "Dinamika Volatilitas Indeks Harga Saham Dan Indikator Makroekonomi: Mengelola Optimisme Pertumbuhan Ekonomi Indonesia Di Era Vuca," *Bisnis dan Pendidikan*, vol. 4, no. 5, p. 2024, doi: 10.17977/um066.v4.i5.2024.5.
- [7] A. R. Sukmara, I. D. Bastaman, and L. Septian, "EKONOMI DAN BISNIS DIGITAL."
- [8] I. Enjelica, A. O. C. Ramadhani, and M. A. Safitri, "Analisis Indeks Harga Properti Residensial Non-Landed di Singapura Antar Segmentasi Pasar," *Surplus: Jurnal Ekonomi dan Bisnis*, vol. 5, no. 1, pp. 9–15, Jul. 2026, doi: 10.71456/sur.v5i1.2013.
- [9] K. Saham *et al.*, *Buku Monograph: Evaluasi Model Machine Learning Memprediksi*. [Online]. Available: www.penerbitlitnus.co.id
- [10] D. Tampubolon *et al.*, *STATISTIKA EKONOMI DAN BISNIS Penerbit Yayasan Cendikia Mulia Mandiri*.
- [11] E. Ikhsan Pembimbing and H. Meta Arief, "Analisis Volatilitas Harga Saham Dengan Metode Arch-Garch (Studi pada Perusahaan Sektor Pertanian yang Terdaftar di Bursa Efek Indonesia periode 2007-2013)."
- [12] A. Baradja and T. Irianto Tjendrowasono, "Penerapan Machine Learning untuk Meningkatkan Prediksi Mata Uang Forex dengan Indikator Teknikal," 2022, doi: 10.55382/jurnalpustakaai.v2i1.700.
- [13] Kevin, O. Pribadi, and L. Hoki, "Stock Price Prediction In Indonesia Using Deep Learning With Long Short-Term Memory Algorithm," *Jurnal Armada Informatika*, vol. 10, no. 1, pp. 285–293, Jun. 2016, doi: 10.36520/jai.v10i1.221.
- [14] R. Hidayat *et al.*, "Implementasi Algoritma Random Forest Regression Untuk Memprediksi Penjualan Produksi di Supermarket," *SIMKOM*, vol. 10, no. 1, pp. 101–109, Jan. 2025, doi: 10.51717/simkom.v10i1.703.
- [15] M. Firmansyah, A. Amril Rudyat, R. Purnama, H. Prasetyo Utomo, and H. Sandhi Firmansyah, "Penerapan Algoritma Xgboost dan Random Forest dalam Prediksi Uraian Resiko Proyek Pada Dinas XYZ," vol. 20, no. 2.

ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 77-89

- [16] F. A. Ansyah, A. C. Murti, and R. Nindyasari, "Perbandingan Metode K-Nearest Neighbors (Knn) Dan Random Forest Untuk Prediksi Pendapatan Driver Shopeefood Di Kudus," *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 11, no. 1, pp. 35–46, Feb. 2026, doi: 10.29100/jipi.v11i1.7335.
- [17] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," Dec. 15, 2024, *Mesopotamian Academic Press*. doi: 10.58496/BJML/2024/007.
- [18] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," Dec. 15, 2024, *Mesopotamian Academic Press*. doi: 10.58496/BJML/2024/007.
- [19] H. M. Nawawi, A. B. Hikmah, A. Mustopa, and F. S. Nugraha, "Evaluasi Model ARIMA, Random Forest dan LSTM untuk Peramalan Harga Minyak Dunia," *JUSIFOR : Jurnal Sistem Informasi dan Informatika*, vol. 5, no. 1, pp. 244–253, Jun. 2026, doi: 10.70609/jusifor.v5i1.9370.
- [20] J. J. Hidayat and S. Hasanudin, "MIFORTEKH (Jurnal Manajemen Informatika & Teknologi) Prediksi Volatilitas IHSG Dengan Hybrid Model GARCH-Random Forest Berbasis Machine Learning," vol. 6, no. 1, 2026, [Online]. Available: <https://journal.stiestekom.ac.id/index.php/mifortekh>
- [21] H. M. Nawawi, A. B. Hikmah, A. Mustopa, and F. S. Nugraha, "Evaluasi Model ARIMA, Random Forest dan LSTM untuk Peramalan Harga Minyak Dunia," *JUSIFOR : Jurnal Sistem Informasi dan Informatika*, vol. 5, no. 1, pp. 244–253, Jun. 2026, doi: 10.70609/jusifor.v5i1.9370.
- [22] H. J. Wiradinata and H. A. Santoso, "Prediksi dan Optimalisasi Konsumsi Energi Smart Atmospheric Water Generator (SAWG) Menggunakan XGBoost Regression," *Technology and Science (BITS)*, vol. 7, no. 3, pp. 1730–1742, 2025, doi: 10.47065/bits.v7i3.8655.