

Sistem Prediksi Risiko Volatilitas Saham Menggunakan Hybrid LSTM dan Random Forest

Ragil Leon Putra, Ledy Elsera Asrianty

Program Studi Informatika, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Jl. Siliwangi, Sleman, Daerah Istimewa Yogyakarta, Indonesia, 55285.

Email : ragilleon7788@gmail.com

ABSTRAK

Fluktuasi harga merupakan salah satu sumber risiko di pasar saham. Bagi investor yang belum berpengalaman, perubahan harga tersebut tidak selalu mudah diterjemahkan menjadi gambaran tingkat risiko. Penelitian ini mengembangkan sistem untuk memperkirakan volatilitas dan mengelompokkannya sebagai risiko rendah, sedang, atau tinggi pada saham BUMI.JK melalui gabungan *Long Short-Term Memory* (LSTM) dan *Random Forest*. Data *Open*, *High*, *Low*, *Close*, *Adjusted Close*, serta *Volume* diambil secara otomatis dari *Yahoo Finance* API. Setelah data dibersihkan, *log return* dihitung dan volatilitas diukur menggunakan standar deviasi *log return* untuk jendela 7 dan 30 hari. LSTM memodelkan pola berurutan pada data dan menghasilkan estimasi volatilitas; estimasi tersebut beserta fitur temporal yang relevan kemudian menjadi masukan *Random Forest* untuk menentukan kelas risiko. Ambang risiko ditetapkan sebagai kriteria operasional penelitian, yakni volatilitas di bawah 2% tergolong rendah, 2% sampai 5% sedang, dan di atas 5% tinggi. Aplikasi dikembangkan dengan *Flask* dan menyajikan angka volatilitas, kategori risiko, grafik pergerakan historis, serta tanggal data terakhir pada *dashboard web*. Pada evaluasi regresi, LSTM menghasilkan MAE 0,01240401 dan RMSE 0,01665610 dalam satuan *log return*. Untuk klasifikasi, model gabungan mencapai *Accuracy* 86,45%, *Weighted Precision* 86,19%, *Weighted Recall* 86,45%, dan *Weighted F1-Score* 86,27%. Perhitungan pada data terkini menghasilkan volatilitas 7,7418% untuk jendela 7 hari dan 5,8185% untuk jendela 30 hari; keduanya masuk kelas risiko tinggi menurut batas yang diterapkan. Sistem yang dihasilkan menyatukan estimasi dan pengelompokan risiko dalam bentuk informasi yang dapat dipakai sebagai analisis awal.

Kata Kunci : Volatilitas Saham, BUMI.JK, LSTM, *Random Forest*, *Yahoo Finance* API.

ABSTRACT

Share-price variability provides useful information for assessing investment exposure, yet less-experienced investors may struggle to translate price movements into understandable risk levels. This research develops a web application that estimates volatility and assigns a risk class for BUMI.JK shares by combining Long Short-Term Memory (LSTM) with Random Forest. Open, High, Low, Close, Adjusted Close, and Volume records were collected from the Yahoo Finance API. Following data cleaning, log returns were calculated and their standard deviations were used to measure volatility over 7-day and 30-day windows. LSTM models sequential patterns and estimates volatility, whereas its output, together with the related temporal features, is passed to Random Forest, which assigns the low, medium, or high risk class. The application,

built with Flask, presents volatility estimates, risk labels, historical charts, and the latest data date in a web dashboard. Regression testing produced an MAE of 0.01240401 and an RMSE of 0.01665610 in log-return units for LSTM. The hybrid classifier recorded 86.45% accuracy, 86.19% weighted precision, 86.45% weighted recall, and an 86.27% weighted F1-score. Calculations for the latest available data returned volatility values of 7.7418% over 7 days and 5.8185% over 30 days. Risk classes follow the operational thresholds of this study, namely volatility below 2% as low, 2%–5% as medium, and above 5% as high; by these criteria, both readings were assigned to the high-risk class. The resulting application brings numerical volatility estimation and risk categorization together as an initial aid for stock-risk analysis.

Keywords: *Stock Volatility, BUMI.JK, LSTM, Random Forest, Yahoo Finance API.*

1. PENDAHULUAN

Akses yang semakin mudah ke perdagangan saham membuat investor membutuhkan cara yang lebih jelas untuk memahami kemungkinan perubahan nilai investasinya. Volatilitas menggambarkan besarnya variasi harga dalam suatu rentang waktu dan kerap digunakan sebagai salah satu petunjuk ketidakpastian pasar (Rosyida et al., 2020). Informasi mengenai volatilitas juga relevan untuk pertimbangan transaksi dan pengelolaan alokasi aset (Petrozziello et al., 2022). Kebutuhan akan penyajian yang mudah dimengerti menjadi penting, khususnya bagi investor pemula. Penelitian ini memilih saham PT Bumi Resources Tbk (BUMI.JK), yang nilainya dapat bergerak mengikuti sentimen pasar, perubahan komoditas, serta situasi ekonomi. Karena itu, analisis tidak cukup hanya menggambarkan riwayat harga; hasilnya juga perlu diterjemahkan menjadi informasi risiko yang lebih mudah digunakan.

Kajian tentang pasar saham telah memanfaatkan beragam metode pembelajaran mesin dan *deep learning*. Jiang (2021) serta Thakkar dan Chaudhari (2021) merangkum perkembangan arsitektur *deep learning* untuk prediksi pasar. Pada konteks saham Indonesia, Budiharto (2021) menggunakan LSTM, sementara Darnis et al. (2025) menguji pendekatan *Recurrent Neural Network*. LSTM untuk peramalan volatilitas turut dibahas oleh Lei et al. (2021) dan Petrozziello et al. (2022), sedangkan Vijh et al. (2020) menerapkan *Random Forest* pada prediksi saham. Model gabungan juga telah diteliti, antara lain *Hybrid-LSTM* oleh Yang et al. (2024) dan perpaduan *Random Forest* dengan LASSO oleh Zeng et al. (2024).

Masih ada peluang untuk mengubah keluaran prediksi menjadi petunjuk risiko yang dapat dimanfaatkan pengguna. Tinjauan Olorunnimbe dan Viktor (2023) mencatat bahwa penelitian *deep learning* di pasar saham banyak menitikberatkan peramalan harga, sementara pemanfaatannya untuk tujuan manajemen risiko belum sebanyak itu. Studi Abdi dan Yonhendri (2025) serta Gunawan dan Ikrimach (2024) menggunakan data dari *Yahoo Finance*, tetapi penggabungan estimasi volatilitas, penetapan kelas risiko, dan penyajian hasil dalam satu *dashboard web* tetap relevan untuk dikembangkan.

Menanggapi kebutuhan tersebut, penelitian ini merancang sistem yang menghubungkan model LSTM dengan *Random Forest*. LSTM menghasilkan estimasi volatilitas dari pola data berurutan, sementara *Random Forest* membantu memetakan keluaran model menjadi tiga tingkat risiko: rendah, sedang, dan tinggi. Sumbangan utama penelitian bersifat implementatif, yakni menggabungkan proses pengambilan data otomatis melalui *Yahoo Finance* API, estimasi volatilitas, klasifikasi risiko, serta visualisasi berbasis *web* yang dibangun dengan *Flask*.

Dashboard menyajikan analisis BUMI.JK untuk dua jendela, yakni 7 hari dan 30 hari, agar pengguna dapat melihat perbedaan gambaran volatilitas pada rentang pendek dan lebih panjang. Informasi yang tersedia mencakup grafik historis, label risiko, dan tanggal data yang dipakai. Data diambil melalui *Yahoo Finance* API dan hasil analisis disajikan lewat aplikasi *Flask*. Meski sistem memproses data terbaru yang tersedia, hal ini tidak berarti bahwa prediksi berlangsung tanpa jeda; waktu pembaruan tetap mengikuti ketersediaan data dari penyedia.

Fokus penelitian ini adalah membangun prototipe berbasis *web* yang memperkirakan volatilitas saham PT Bumi Resources Tbk (BUMI.JK) dan menyajikan klasifikasi risikonya melalui kombinasi LSTM–*Random Forest*. Sistem dirancang untuk menampilkan hasil pada jendela pengamatan 7 hari dan 30 hari. Dengan demikian, investor—terutama pengguna pemula—dapat mengakses ringkasan analisis risiko secara lebih sistematis sebagai salah satu bahan pertimbangan, bukan sebagai satu-satunya dasar keputusan investasi.

2. METODE

Data Penelitian dan Pra-pemrosesan

Studi ini menggunakan pendekatan kuantitatif dengan data sekunder berupa riwayat perdagangan saham PT Bumi Resources Tbk (BUMI.JK). Data diunduh dari *Yahoo Finance* melalui pustaka *Python yfinance*, meliputi 2 Januari 2020 hingga 30 Desember 2025. Enam kolom yang dianalisis adalah *Open*, *High*, *Low*, *Close*, *Adjusted Close*, dan *Volume*.

Sebelum pemodelan, data diperiksa dan disiapkan melalui penataan kolom, pengubahan indeks tanggal ke format waktu, pengurutan berdasarkan tanggal, pemeriksaan tanggal ganda, penanganan nilai yang tidak terisi, serta validasi nilai harga dan volume. Pemeriksaan akhir memperlihatkan bahwa *dataset* awal dan *dataset* yang telah dibersihkan masing-masing berisi 1.447 baris dengan enam variabel saham.

Return logaritmik dihitung dari rasio harga penutupan pada dua hari perdagangan berurutan. Persamaan yang digunakan untuk memperoleh *log return* dituliskan sebagai berikut:

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

Pada persamaan tersebut, r_t menyatakan *log return* saat t , P_t adalah harga penutupan pada waktu t , dan $P_{(t-1)}$ menunjukkan harga penutupan pada periode sebelumnya. Volatilitas selanjutnya diperoleh dari simpangan baku sampel *log return* di dalam jendela pengamatan yang ditentukan. Persamaannya ditampilkan berikut ini:

$$\sigma = \sqrt{\left((1)/(n-1) \sum_{i=1}^n (r_i - \bar{r})^2 \right)} \quad (2)$$

dengan (σ_t) merupakan volatilitas pada periode pengamatan, (n) merupakan jumlah observasi *return*, (r_i) merupakan *log return* ke- (i) , dan $(\bar{r})$ merupakan rata-rata *log return* pada jendela pengamatan. Nilai volatilitas dikonversi menjadi persentase menggunakan persamaan:

$$V_t = \sigma_t \times 100\% \quad (3)$$

Volatilitas dihitung pada jendela 7 dan 30 hari untuk membandingkan dua cakupan waktu. Data yang telah dibersihkan kemudian diubah menjadi sekuens deret waktu dengan panjang masukan yang sesuai untuk LSTM. Pembagian data latih dan data uji mengikuti urutan kronologis, sehingga urutan waktu dalam data saham tetap terjaga dan observasi tidak diacak.

Pemodelan *Hybrid LSTM* dan *Random Forest*

Kedua algoritma diberi peran berbeda dalam rancangan *hybrid* ini. LSTM bertugas sebagai model regresi untuk mempelajari hubungan antarwaktu pada riwayat saham dan memperkirakan nilai volatilitas. Masukan berupa sekuens data diproses untuk membentuk representasi pola temporal yang kemudian digunakan dalam menghasilkan estimasi.

Keluaran prediksi LSTM bersama fitur temporal yang relevan diteruskan ke *Random Forest* sebagai bahan penentuan kelas risiko. Batas operasional yang dipakai adalah volatilitas di bawah 2% untuk kelas rendah, 2% sampai 5% untuk kelas sedang (termasuk batasnya), dan di atas 5% untuk kelas tinggi. Dengan alur ini, sistem menghasilkan nilai estimasi sekaligus label risiko untuk ditampilkan pada *dashboard*.

Penilaian dilakukan menurut tujuan masing-masing model. Untuk keluaran regresi LSTM, digunakan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE); definisi kedua ukuran tersebut disajikan pada persamaan berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Dalam keterangan persamaan, N menunjukkan jumlah sampel uji, y_i adalah nilai observasi, dan $\hat{y}_i$ merupakan hasil estimasi. Karena variabel target dinyatakan dalam satuan *log return*, nilai MAE dan RMSE yang dihasilkan juga berada pada satuan tersebut; nilai yang lebih kecil menandakan selisih prediksi yang lebih rendah.


Kinerja pengelompokan kelas dinilai melalui *Accuracy*, *Weighted Precision*, *Weighted Recall*, dan *Weighted F1-Score*. *Accuracy* menyatakan proporsi prediksi yang tepat dari seluruh observasi, sedangkan tiga metrik berbobot memperhitungkan jumlah data yang termasuk dalam setiap kelas.

Arsitektur dan Integrasi *Dashboard Web*

Sistem menghubungkan pengambilan data, penyiapan *dataset*, penghitungan volatilitas, inferensi model *hybrid*, penentuan kelas risiko, dan penyajian hasil di *dashboard*. *Flask* pada sisi *backend* menjadi penghubung *Yahoo Finance*, modul pengolahan data, model LSTM serta *Random Forest* yang telah dilatih, dan antarmuka pengguna. Data BUMI.JK yang diperoleh melalui *yfinance* diperiksa kelengkapan dan


strukturnya sebelum digunakan untuk menghitung *log return* dan volatilitas sesuai periode pilihan.

Sesudah tahap pengolahan selesai, sistem meminta LSTM menghasilkan estimasi volatilitas dan fitur temporal. Informasi tersebut lalu digunakan *Random Forest* untuk menentukan kelas risiko berdasarkan model yang telah dilatih. *Backend* mengirim hasil ke *dashboard*, yang menyajikan angka volatilitas, label risiko, grafik historis, jendela analisis, dan tanggal data terakhir.



Gambar 1. Arsitektur Sistem Prediksi Risiko Volatilitas Saham BUMI.JK

Gambar 1 memperlihatkan hubungan antarbagian sistem. Data historis bersumber dari *Yahoo Finance*, lalu diperiksa melalui tahap prapemrosesan. LSTM mempelajari urutan data untuk menghasilkan estimasi, dan *Random Forest* menetapkan kelas risiko. *Flask* menghubungkan proses analitik tersebut dengan tampilan *web* agar hasilnya dapat diakses pengguna.



Gambar 2. Alur Proses Sistem Prediksi Risiko Volatilitas Saham BUMI.JK

Alur pada Gambar 2 merangkum proses dari permintaan pengguna sampai keluaran muncul di layar. Ketika data lolos pemeriksaan, sistem menghitung volatilitas, menjalankan model LSTM dan *Random Forest*, lalu menampilkan hasil sesuai rentang waktu yang dipilih.

Dashboard menampilkan kode saham, pilihan jendela pengamatan, kendali untuk mengambil data dan menjalankan analisis, angka volatilitas, kategori risiko, grafik historis, serta tanggal data terakhir. Permintaan dari pengguna, pemanggilan API, pengolahan data, dan inferensi ditangani *backend Flask*; hasil yang dikirimkan kemudian divisualisasikan pada antarmuka.

3. HASIL DAN PEMBAHASAN

Hasil Pra-pemrosesan Data dan Perhitungan Volatilitas

Riwayat perdagangan BUMI.JK untuk periode 2 Januari 2020–30 Desember 2025 diperoleh dari *Yahoo Finance* melalui *yfinance*. *Dataset* mencakup enam atribut: *Open*,

High, Low, Close, Adjusted Close, dan *Volume*. Pemeriksaan menunjukkan jumlah baris tetap 1.447 sebelum maupun setelah pembersihan. Tidak ditemukan nilai kosong pada keenam atribut maupun tanggal perdagangan yang berulang. *Dataset* hasil pembersihan digunakan untuk memperoleh *log return* dan menghitung volatilitas.

Tabel 1. Ringkasan Pengumpulan dan Pra-pemrosesan Data Saham BUMI.JK

Parameter	Hasil
Sumber data	<i>Yahoo Finance</i> melalui pustaka <i>Python yfinance</i>
Kode saham	BUMI.JK
Periode pengamatan	2 Januari 2020–30 Desember 2025
Variabel	<i>Open, High, Low, Close, Adjusted Close, Volume</i>
File data mentah	BUMI_JK_raw_2020_2025.csv
File data bersih	BUMI_JK_clean_2020_2025.csv
Jumlah baris sebelum pra-pemrosesan	1.447
Jumlah baris setelah pra-pemrosesan	1.447
<i>Missing values</i> setelah pembersihan	0 pada seluruh enam variabel
Duplikasi tanggal pada <i>dataset</i> bersih	0

Sumber: Hasil pengolahan data penelitian, 2026.

Log return diperoleh dari perubahan relatif harga penutupan antara dua hari perdagangan yang berurutan. Deret *return* tersebut menjadi masukan untuk penghitungan simpangan baku sampel pada jendela 7 hari serta 30 hari sebagai ukuran volatilitas.

Tabel 2. Sampel Data Saham BUMI.JK Setelah Pra-pemrosesan

Tanggal	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Adj Close</i>	<i>Volume</i>	<i>Log Return</i>
2020-01-02	66	67	66	66	66	46.639.800	—
2020-01-03	66	74	66	73	73	58.425.980	0,100811
2020-01-06	73	73	68	69	69	38.823.490	-0,056309
2020-01-07	69	70	68	69	69	10.657.650	0,000000
2020-01-08	69	69	66	68	68	17.396.370	-0,014599

Sumber: Hasil pengolahan *dataset* BUMI.JK, 2026.

Tabel 2 menampilkan sebagian data yang telah diurutkan berdasarkan tanggal transaksi. Nilai *return* logaritmik dari rangkaian harga tersebut selanjutnya dipakai dalam penghitungan volatilitas untuk kedua jendela analisis.

Tabel 3. Hasil Perhitungan Volatilitas Saham BUMI.JK

Periode pengamatan	Nilai volatilitas	Kategori risiko
7 hari	7,7418%	Tinggi
30 hari	5,8185%	Tinggi

Sumber: Hasil pengolahan data penelitian, 2026.

Angka pada Tabel 3 memperlihatkan bahwa ukuran volatilitas untuk jendela 7 hari melampaui hasil pada jendela 30 hari. Walaupun nilainya berbeda, keduanya melewati ambang 5% yang digunakan sistem sehingga diberi label risiko tinggi.

Hasil Evaluasi Model *Hybrid LSTM* dan *Random Forest*

Pengujian dilakukan untuk menilai dua keluaran: ketepatan estimasi numerik dari LSTM dan ketepatan klasifikasi risiko oleh model *hybrid*. Kinerja regresi diperiksa melalui MAE dan RMSE, sedangkan hasil klasifikasi diringkas dengan *Accuracy*, *Weighted Precision*, *Weighted Recall*, *Weighted F1-Score*, serta *Macro F1-Score*.

Pada data evaluasi, LSTM memperoleh MAE 0,01240401 dan RMSE 0,01665610 dalam satuan *log return*. MAE merangkum besarnya selisih absolut rata-rata antara nilai aktual dan estimasi, sedangkan RMSE lebih sensitif terhadap kesalahan yang besar.

Tabel 4. Hasil Evaluasi Model LSTM untuk Prediksi Volatilitas

Metrik	Nilai
<i>Mean Absolute Error</i> (MAE)	0,01240401
<i>Root Mean Square Error</i> (RMSE)	0,01665610

Sumber: Hasil pengolahan data penelitian, 2026.

Untuk tugas klasifikasi, keluaran *hybrid* ditempatkan ke dalam tiga kelas risiko. Hasil pengujian mencatat *Accuracy* 86,45%, *Weighted Precision* 86,19%, *Weighted Recall* 86,45%, *Weighted F1-Score* 86,27%, serta *Macro F1-Score* 82,51%.

Tabel 5. Hasil Evaluasi Klasifikasi Model *Hybrid LSTM* dan *Random Forest*

Metrik	Nilai
<i>Accuracy</i>	86,45%
<i>Weighted Precision</i>	86,19%
<i>Weighted Recall</i>	86,45%
<i>Weighted F1-Score</i>	86,27%
<i>Macro F1-Score</i>	82,51%

Sumber: Hasil pengolahan data penelitian, 2026.

Tabel 5 menyajikan ukuran kinerja secara keseluruhan. Rincian metrik untuk masing-masing kelas kemudian ditampilkan pada Tabel 6 agar perbedaan hasil antara kelas rendah, sedang, dan tinggi dapat diperiksa.

Tabel 6. *Classification Report* Model *Hybrid LSTM* dan *Random Forest*

Kelas risiko	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Rendah	0,79	0,73	0,76	26
Sedang	0,80	0,77	0,79	69
Tinggi	0,91	0,95	0,93	119
<i>Macro Average</i>	0,84	0,82	0,83	214
<i>Weighted Average</i>	0,86	0,86	0,86	214

Sumber: Hasil pengolahan data penelitian, 2026.

Mengacu pada Tabel 6, model paling baik mengenali kelas tinggi, dengan *precision* 0,91, *recall* 0,95, dan *F1-score* 0,93. Pada kelas sedang, nilainya masing-masing 0,80, 0,77, dan 0,79. Sementara itu, kelas rendah menghasilkan *precision* 0,79, *recall* 0,73, serta *F1-score* 0,76.

Data uji terdiri atas 119 observasi berlabel tinggi, 69 berlabel sedang, dan 26 berlabel rendah. Komposisi ini memperlihatkan bahwa jumlah sampel tiap kelas tidak merata. Oleh sebab itu, evaluasi sebaiknya tidak hanya bertumpu pada satu angka agregat, tetapi juga memperhatikan hasil per kelas dan rata-rata makro maupun berbobot.

Penetapan label risiko didasarkan pada batas volatilitas yang ditentukan untuk penelitian ini: kurang dari 2% masuk kelas rendah, rentang 2%–5% masuk kelas sedang, dan nilai yang melampaui 5% digolongkan tinggi.

Tabel 7. Kriteria Klasifikasi Risiko Berdasarkan Volatilitas

Nilai volatilitas	Kategori risiko	Interpretasi
Kurang dari 2%	Rendah	Fluktuasi relatif rendah berdasarkan kriteria sistem
2%–5%	Sedang	Fluktuasi berada pada tingkat menengah berdasarkan kriteria sistem
Lebih dari 5%	Tinggi	Fluktuasi relatif tinggi berdasarkan kriteria sistem

Sumber: Kriteria klasifikasi yang digunakan dalam penelitian, 2026.

Batas tersebut merupakan aturan kerja yang digunakan aplikasi untuk menerjemahkan angka volatilitas menjadi label risiko. Kategori pada *dashboard* karenanya mencerminkan kriteria penelitian ini dan tidak dimaksudkan sebagai standar universal yang berlaku bagi setiap saham atau situasi pasar.


Hasil Implementasi *Dashboard Web*

Komponen aplikasi disatukan dalam *dashboard web* yang menghubungkan pengambilan data, pembersihan, prediksi, klasifikasi, dan visualisasi. *Flask* mengatur komunikasi antara *Yahoo Finance* yang diakses lewat *yfinance*, modul prapemrosesan, model LSTM dan *Random Forest*, serta tampilan untuk pengguna.

Ketika pengguna memilih periode, aplikasi mengambil data BUMI.JK yang tersedia dan memeriksa kelengkapannya. Data yang lolos pemeriksaan diolah, kemudian diproses oleh model untuk memperoleh estimasi volatilitas dan label risiko.


Dashboard menampilkan hasil tersebut bersama grafik historis serta tanggal data yang digunakan.

Dari data terbaru yang diuji, volatilitas tercatat 7,7418% untuk jendela 7 hari dan 5,8185% untuk jendela 30 hari. Karena kedua nilai berada di atas ambang 5%, sistem menandainya sebagai risiko tinggi.



Gambar 3. Tampilan *Dashboard* Prediksi Risiko Volatilitas Saham BUMI.JK Periode 7 Hari

Sumber: Dokumentasi aplikasi hasil pengembangan, 2026.



Gambar 4. Tampilan *Dashboard* Prediksi Risiko Volatilitas Saham BUMI.JK Periode 30 Hari

Sumber: Dokumentasi aplikasi hasil pengembangan, 2026.

Gambar 3 dan Gambar 4 memperlihatkan hasil aplikasi untuk masing-masing periode pengamatan. *Dashboard* menyertakan angka volatilitas dan label risiko, disertai grafik riwayat agar perubahan nilainya dapat ditinjau pengguna.

Grafik historis memberi konteks terhadap angka volatilitas yang ditampilkan, sementara tanggal data terakhir menunjukkan kebaruan data yang dipakai. Penyatuan hasil perhitungan, kategori risiko, dan grafik dalam satu antarmuka mengurangi kebutuhan pengguna untuk menghitung secara manual. Bukti implementasi tetap perlu didukung dokumentasi aplikasi dan pemeriksaan fungsi sistem.

Pembahasan

Hasil evaluasi memperlihatkan bahwa LSTM dapat digunakan untuk mengestimasi volatilitas dari rangkaian historis BUMI.JK pada data uji. Temuan ini beririsan dengan Budiharto (2021), yang memodelkan saham Indonesia menggunakan LSTM dan data *Yahoo Finance*, serta studi Kusuma et al. (2024), Sahroni et al. (2024), dan Ananda dan Sutopo (2025). Secara khusus, Lei et al. (2021) dan Petrozziello et al. (2022) membahas pemodelan volatilitas dengan LSTM. Dalam rancangan penelitian ini, LSTM menangkap pola sekuens dan menghasilkan estimasi, sedangkan *Random Forest* mengolah keluaran serta fitur relevan untuk menentukan kelas rendah, sedang, atau tinggi. Hasil evaluasi menunjukkan bahwa susunan kerja tersebut dapat diterapkan pada data uji yang digunakan. Pendekatan ini berkaitan dengan pengembangan model *hybrid* oleh Yang et al. (2024) dan kombinasi *Random Forest*–LASSO oleh Zeng et al. (2024). Perbedaan utama penelitian ini adalah penyatuan estimasi volatilitas, klasifikasi risiko, dan tampilan hasil dalam *dashboard web*.

Berbeda dari studi Budiharto (2021) yang memprediksi saham Indonesia secara umum, penelitian ini memusatkan analisis pada estimasi volatilitas BUMI.JK dan pemberian label risikonya. Vijh et al. (2020) serta Rasyid et al. (2025) membahas penggunaan *Random Forest* dalam prediksi saham; pada sistem ini, algoritma tersebut berfungsi setelah LSTM mempelajari pola temporal, yaitu untuk klasifikasi risiko. Dengan demikian, kontribusi yang ditonjolkan ialah penerapan alur terintegrasi pada satu saham, dari prediksi volatilitas sampai penyajian kelas risiko secara visual.

Nilai volatilitas hasil pengujian mencapai 7,7418% untuk periode 7 hari dan 5,8185% untuk periode 30 hari; menurut batas yang diterapkan, keduanya masuk kelas tinggi. Informasi tersebut dapat menjadi salah satu masukan saat pengguna menelaah

perubahan harga, sejalan dengan pembahasan manajemen risiko pada Petrozziello et al. (2022) dan Liu et al. (2024). *Dashboard* memberi kegunaan praktis karena hasil model disajikan sebagai informasi yang dapat dibaca, bukan sekadar skor evaluasi. Hal ini sejalan dalam aspek implementasi dengan Abdi dan Yonhendri (2025), tetapi sistem yang dikembangkan di sini menekankan volatilitas dan kategori risikonya. Secara keseluruhan, integrasi LSTM dan *Random Forest* dapat diimplementasikan untuk menghasilkan informasi risiko volatilitas BUMI.JK dalam *dashboard*.

4. SIMPULAN

Penelitian ini menghasilkan prototipe *web* untuk menganalisis risiko volatilitas saham PT Bumi Resources Tbk (BUMI.JK) melalui gabungan LSTM dan *Random Forest*. LSTM digunakan untuk memperkirakan nilai volatilitas dengan MAE 0,01240401 dan RMSE 0,01665610, sementara *Random Forest* menetapkan kelas rendah, sedang, atau tinggi dengan *Accuracy* 86,45% dan *Weighted F1-Score* 86,27%. Aplikasi *Flask* mengambil data yang tersedia dari *Yahoo Finance* API dan menyajikan hasilnya melalui *dashboard*. Pada pengujian data terbaru, volatilitas untuk jendela 7 hari mencapai 7,7418% dan untuk jendela 30 hari sebesar 5,8185%; keduanya dikategorikan tinggi berdasarkan batas penelitian. Hasil tersebut perlu dipahami dengan mempertimbangkan ketidakseimbangan data uji, yang terdiri atas 119 sampel kelas tinggi, 69 kelas sedang, dan 26 kelas rendah, serta perbedaan *F1-score* antara kelas tinggi (0,93) dan rendah (0,76). Penelitian berikutnya dapat menguji pembobotan kelas atau SMOTE dengan mencegah kebocoran data, menambahkan indikator teknikal seperti RSI, MACD, dan *Bollinger Bands*, memperluas saham dan rentang waktu yang diuji, serta membandingkan model *hybrid* dengan LSTM dan *Random Forest* secara terpisah.

5. DAFTAR PUSTAKA

- Abdi, M. F. & Yonhendri. (2025). Implementasi sistem prediksi saham real-time dengan integrasi Yahoo Finance API dan machine learning di Google Colab: Analisis dan evaluasi performa model. *Teknomatika*, 15(1), 25–31. <https://doi.org/10.61423/teknomatika.v15i01.692>
- Ananda, M. R., & Sutopo, J. (2025). Komparasi model deep learning dalam prediksi harga saham pada sektor pertambangan Indonesia. *JINTEKS: Jurnal Informatika*

- Teknologi Dan Sains*, 7(4), 2174–2183.
<https://doi.org/10.51401/jinteks.v7i4.6965>
- Budiharto, W. (2021). Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM). *Journal of Big Data*, 8(1), 47. <https://doi.org/10.1186/s40537-021-00430-0>
- Darnis, F., Rahman, A., & Ansori, Y. (2025). Akurasi model algoritma Recurrent Neural Network untuk prediksi saham syariah. *Teknomatika*, 15(1), 17–24. <https://doi.org/10.61423/teknomatika.v15i01.690>
- Gunawan, K. & Ikrimach. (2024). Implementation of Python-based TOPSIS method for best stock selection analysis using Yahoo Finance. *Jurnal Teknologi Dan Open Source*, 7(2), 125–137.
- Irmayani, W., & Jayanti, W. E. (2025). Visualisasi prediksi harga saham menggunakan model Long Short-Term Memory (LSTM). *JUSTIAN: Jurnal Sistem Informasi Akuntansi*, 6(1), 1–8. <https://doi.org/10.31294/justian.v6i1.8107>
- Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184, 115537. <https://doi.org/10.1016/j.eswa.2021.115537>
- Kusuma, N. P. N., Artani, K. T. B., & Dewi, D. P. N. (2024). Prediksi harga saham blue chip menggunakan algoritma Long Short-Term Memory (LSTM). *Jurnal Riset Akuntansi Dan Keuangan*, 20(1), 73–84. <https://doi.org/10.21460/jrak.v20i1.6>
- Lei, B., Liu, Z., & Song, Y. (2021). On stock volatility forecasting based on text mining and deep learning under high-frequency data. *Journal of Forecasting*, 40(8), 1596–1610. <https://doi.org/10.1002/for.2794>
- Liu, G., Zhuang, Z., & Wang, M. (2024). Forecasting the high-frequency volatility based on the LSTM-HIT model. *Journal of Forecasting*, 43(5), 1356–1373. <https://doi.org/10.1002/for.3078>
- Nabipour, M., Nayyeri, P., Jabani, H., Mosavi, A., Salwana, E., & S., S. (2020). Deep Learning for Stock Market Prediction. *Entropy*, 22(8), 840. <https://doi.org/10.3390/e22080840>
- Olorunnimbe, K., & Viktor, H. (2023). Deep learning in the stock market—A systematic survey of practice, backtesting, and applications. *Artificial Intelligence Review*, 56(3), 2057–2109. <https://doi.org/10.1007/s10462-022-10226-0>
- Petrozziello, A., Troiano, L., Serra, A., Jordanov, I., Storti, G., Tagliaferri, R., & La Rocca, M. (2022). Deep learning for volatility forecasting in asset management. *Soft Computing*, 26(17), 8553–8574. <https://doi.org/10.1007/s00500-022-07161-1>
- Pranoto, S., Sutiono, S., Sarifudin, & Nasution, D. (2024). Penerapan UML dalam perancangan sistem informasi pelaporan dan evaluasi pembangunan pada bagian administrasi pembangunan Sekretariat Daerah Kota Tebing Tinggi. *Surplus: Jurnal Ekonomi Dan Bisnis*, 2(2), 384–401.

- Rasyid, A., Muharam, A. B., & Solichin, A. (2025). Prediksi harga saham syariah Indonesia berdasarkan analisis fundamental, teknikal dan bandarmology menggunakan metode Random Forest. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(2), 1663–1677. <https://doi.org/10.29100/jipi.v10i2.7855>
- Rosyida, H., Firmansyah, A., & Wicaksono, S. B. (2020). Volatilitas harga saham: Leverage, ukuran perusahaan, pertumbuhan aset. *JAS (Jurnal Akuntansi Syariah)*, 4(2), 196–208. <https://doi.org/10.46367/jas.v4i2.256>
- Saberironaghi, M., Ren, J., & Saberironaghi, A. (2025). Stock Market Prediction Using Machine Learning and Deep Learning Techniques: A Review. *AppliedMath*, 5(3), 76. <https://doi.org/10.3390/appliedmath5030076>
- Sahroni, M., Arif, M. F., & Misdram, M. (2024). Stock price prediction using the Long Short-Term Memory method. *Jurnal Teknik Informatika (JUTIF)*, 5(6), 1769–1777. <https://doi.org/10.52436/1.jutif.2024.5.6.2615>
- Thakkar, A., & Chaudhari, K. (2021). A comprehensive survey on deep neural networks for stock market: The need, challenges, and future directions. *Expert Systems with Applications*, 177, 114800. <https://doi.org/10.1016/j.eswa.2021.114800>
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599–606. <https://doi.org/10.1016/j.procs.2020.03.326>
- Yang, A., Ye, Q., & Zhai, J. (2024). Volatility forecasting with HYBRID-LONG SHORT-TERM MEMORY models: Evidence from the COVID -19 period. *International Journal of Finance & Economics*, 29(3), 2766–2786. <https://doi.org/10.1002/ijfe.2805>
- Zeng, Q., Lu, X., Xu, J., & Lin, Y. (2024). Macro-Driven Stock Market Volatility Prediction: Insights from a New Hybrid Machine Learning Approach. *International Review of Financial Analysis*, 96, 103711. <https://doi.org/10.1016/j.irfa.2024.103711>