

Penilaian Harga Opsi *Put* Saham NVIDIA Menggunakan Model Black–Scholes dan LSTM

Pricing of NVIDIA Put Options Using the Black-Scholes Model and LSTM

Rifky Miftaqul Ilmi¹, Ramdhan Fazrianto Suwarman^{*2}, Lita Wulandari Aeli³

Program Studi Matematika, Universitas Negeri Malang

rifky.miftaqul.2203126@students.um.ac.id¹, ramdhan.fazrianto.fmipa@um.ac.id^{*2}

lita.wulandariaeli.fmipa@um.ac.id³

**Corresponding author*

Received 1 May 2026; Revised 13 May 2026; Accepted 15 May 2026

Abstrak - Saham NVIDIA dalam beberapa tahun terakhir mengalami pertumbuhan laba dan volatilitas harga yang cukup tinggi. Volatilitas ini dapat menimbulkan risiko kerugian akibat penurunan harga saham. Oleh karena itu, diperlukan instrumen lindung nilai, salah satunya adalah opsi *put*. Opsi *put* merupakan instrumen derivatif yang memberikan hak kepada pemegangnya untuk menjual aset yang mendasarinya pada harga tertentu dalam periode tertentu. Tujuan penelitian ini adalah menganalisis penilaian harga opsi *put* saham NVIDIA menggunakan model Black–Scholes dan LSTM. Data yang digunakan berupa histori kuotasi opsi harian pada periode 2022–2023. Hasil penelitian menunjukkan bahwa model LSTM memiliki akurasi yang lebih unggul dengan RMSE sebesar 5.100 dan MAE sebesar 3.079, dibanding dengan model Black–Scholes yang menghasilkan RMSE sebesar 7.303 dan MAE sebesar 3.656. Berdasarkan waktu jatuh tempo, model Black–Scholes lebih unggul pada opsi dengan jatuh tempo kurang dari tiga bulan, sedangkan model LSTM lebih unggul pada opsi dengan jatuh tempo lebih dari tiga bulan. Perbedaan tersebut dipengaruhi oleh penyimpangan asumsi normalitas *log return* pada model Black–Scholes dan pendekatan bergulir yang mampu menjaga kestabilan akurasi penilaian pada model LSTM. Penelitian ini diharapkan dapat menjadi referensi dalam pemilihan model penentuan harga opsi *put* untuk mendukung strategi lindung nilai.

Kata Kunci - Opsi Put, Black–Scholes, LSTM, pengelolaan risiko, NVIDIA

Abstract - In recent years, NVIDIA stock has experienced significant earnings growth and high price volatility. This volatility may increase the risk of losses due to declines in stock prices. Therefore, a hedging instrument is required, one of which is a put option. A put option is a derivative instrument that gives its holder the right to sell the underlying asset at a predetermined price within a specified period. This study aims to analyze the pricing of NVIDIA put options using the Black–Scholes and Long Short-Term Memory (LSTM) models. The data used consist of historical daily option quotation data from 2022 to 2023. The results indicate that the LSTM model achieved higher pricing accuracy, with an RMSE of 5.100 and an MAE of 3.079, compared to the Black–Scholes model, which produced an RMSE of 7.303 and an MAE of 3.656. Based on time to maturity, the Black–Scholes model performed better for options with maturities of less than three months, whereas the LSTM model outperformed for options with maturities exceeding three months. These differences were influenced by deviations from the log-return normality assumption in the Black–Scholes model, while the rolling approach in the LSTM model helped maintain the stability of pricing accuracy. This study is expected to serve as a reference for selecting put option pricing models to support hedging strategies.

Keywords - Option Price, Black–Scholes, LSTM, Put Options, NVIDIA Stock

1. PENDAHULUAN

Saham hingga saat ini tetap menjadi salah satu instrumen investasi yang banyak diminati oleh investor. Hal ini terlihat dari tingginya nilai perdagangan saham di pasar global dalam beberapa tahun terakhir. Pada tahun 2025, nilai perdagangan saham global tercatat meningkat sebesar 36.8% [1]. Peningkatan ini turut didorong oleh kinerja saham berkapitalisasi besar yang memberikan dampak ekonomi yang sangat besar terhadap pasar. Salah satu perusahaan tersebut adalah NVIDIA Corporation [2]. NVIDIA merupakan perusahaan teknologi yang berfokus pada pengembangan unit pemrosesan grafis (GPU). Pada akhir tahun 2023, laba per saham NVIDIA tercatat meningkat lebih dari 12 kali lipat dibandingkan tahun sebelumnya [3]. Meskipun kinerja keuangan perusahaan menunjukkan peningkatan yang signifikan, harga saham NVIDIA selama periode 2022–2023 mengalami volatilitas yang cukup tinggi. Pada awal tahun 2022, harga saham berada pada kisaran 301.22 USD, kemudian menurun hingga sekitar 146.13 USD pada akhir tahun 2022, sebelum kembali meningkat hingga mencapai kisaran 497.05 USD pada akhir tahun 2023 [4]. Kondisi tersebut menjadikan saham NVIDIA menarik bagi investor karena potensi keuntungan yang tinggi, tetapi pada saat yang sama juga meningkatkan risiko kerugian akibat fluktuasi dan potensi penurunan harga saham. Oleh karena itu, diperlukan instrumen lindung nilai untuk mengurangi risiko investasi. Salah satu instrumen yang dapat digunakan adalah opsi *put* [5]. Opsi *put* adalah instrumen derivatif yang memberikan hak kepada pemegangnya untuk menjual aset yang mendasarinya pada harga tertentu dalam waktu tertentu [6].

Pada tahun 2025, jumlah kontrak opsi yang diperdagangkan di bursa mencapai 63.51 miliar kontrak, jauh lebih besar dibandingkan kontrak berjangka yang hanya sekitar 30.24 miliar kontrak [1]. Tingginya volume perdagangan ini menunjukkan bahwa opsi banyak dimanfaatkan sebagai instrumen dalam strategi lindung nilai. Namun demikian, efektivitas penggunaan opsi sangat bergantung pada ketepatan dalam penilaian harga opsi. Bagi para *trader*, investor, dan lembaga keuangan, penilaian harga opsi merupakan hal penting untuk membuat keputusan yang tepat dalam melakukan lindung nilai terhadap risiko yang terkait dengan aset yang mendasarinya [7]. Kesalahan dalam penilaian harga opsi dapat menyebabkan ketidaktepatan dalam mencerminkan risiko, sehingga strategi manajemen risiko yang diterapkan menjadi kurang optimal.

Penelitian [8] menunjukkan adanya fenomena *underpricing* dan *overpricing* pada penilaian harga opsi. Kondisi *underpricing* mencerminkan adanya ketidakakuratan dalam estimasi risiko atau keterbatasan likuiditas pasar, sehingga harga opsi tidak sepenuhnya merefleksikan risiko yang mendasarinya. Sebaliknya, kondisi *overpricing* menyebabkan investor membayar premi yang melebihi nilai wajarnya, yang pada akhirnya meningkatkan biaya lindung nilai dan menurunkan efisiensi strateginya. Oleh karena itu, diperlukan metode penilaian harga wajar opsi yang akurat dalam mendukung strategi lindung nilai. Salah satu model yang umum digunakan dalam penilaian harga opsi adalah model Black–Scholes. Penelitian [9] menunjukkan bahwa model Black–Scholes memiliki kinerja yang cukup baik untuk penilaian harga wajar opsi dengan waktu jatuh tempo kurang dari tiga bulan. Namun demikian, model Black–Scholes didasarkan pada sejumlah asumsi pasar yang ideal, seperti distribusi *lognormal* dari *return* saham. Asumsi tersebut tidak selalu sesuai dengan kondisi pasar yang sebenarnya. Ketidaksesuaian antara asumsi model dan kondisi pasar tersebut dapat menyebabkan terjadinya *mispricing* pada harga opsi.

Berdasarkan keterbatasan asumsi pada model Black–Scholes, diperlukan pendekatan alternatif yang lebih fleksibel. Menurut [10] pendekatan *deep learning* merupakan salah satu pendekatan yang sangat fleksibel. Pendekatan ini bekerja dengan mempelajari pola dari data historis. Salah satu model berbasis *deep learning* yang banyak digunakan dalam peramalan deret waktu keuangan adalah Long Short–Term Memory (LSTM) [11]. Dengan demikian, model LSTM diusulkan sebagai pendekatan alternatif terhadap model Black–Scholes. Berbagai penelitian terdahulu menunjukkan keunggulan kinerja model LSTM, diantaranya penelitian oleh

[12], [13], [14], dan [9]. Hasil penelitian tersebut menunjukkan bahwa model LSTM memiliki kemampuan yang lebih baik dibandingkan model Black–Scholes dalam penilaian harga opsi, yang ditunjukkan oleh tingkat kesalahan yang lebih rendah. Temuan tersebut mengindikasikan bahwa model LSTM memiliki potensi yang lebih unggul dalam memodelkan harga opsi dibandingkan model Black–Scholes. Namun, berdasarkan telaah literatur terhadap berbagai penelitian sebelumnya, belum ditemukan penelitian yang secara khusus membahas penilaian harga opsi *put* saham NVIDIA menggunakan model Black–Scholes dan LSTM. Oleh karena itu, penelitian ini dilakukan untuk menganalisis dan membandingkan kinerja kedua model tersebut dalam penilaian harga opsi *put* saham NVIDIA.

2. METODE PENELITIAN

Metode yang digunakan dalam penelitian ini meliputi model matematis Black–Scholes dan model berbasis *deep learning*, yaitu LSTM. Kedua model tersebut digunakan dalam penilaian harga teoritis opsi *put* saham NVIDIA menggunakan variabel independen yang terdiri atas harga saham, harga pelaksanaan, volatilitas, tingkat suku bunga bebas risiko, waktu hingga jatuh tempo, dan variabel dependen berupa harga opsi *put*. Tahapan penelitian ini meliputi pengumpulan data, pengujian asumsi teoritis, pembagian data, implementasi model, serta evaluasi dan perbandingan kinerja model.

2.1. Pengumpulan Data

Penelitian ini menggunakan tiga data sekunder yang terdiri dari data kuotasi opsi harian untuk opsi saham NVIDIA, data harga penutupan harian saham NVIDIA, dan data tingkat suku bunga *Treasury*. Data kuotasi opsi harian diperoleh dari OptionsDX, yaitu platform berbasis web yang menyediakan data dan kutipan historis opsi serta mata uang kripto yang diperdagangkan di bursa pasar Amerika Serikat. Data kuotasi opsi harian dikumpulkan selama periode April 2022 hingga Desember 2023 dengan total 697,267 observasi. Sementara itu, data harga penutupan harian saham diperoleh dari data kuotasi opsi harian dengan periode waktu yang lebih panjang, yaitu dari bulan November 2021 hingga Desember 2023. Data ini terdiri dari 532 hari perdagangan. Selanjutnya, data tingkat suku bunga diperoleh dari *U.S. Treasury Constant Maturity Yield* yang bersumber dari Federal Reserve Economic Data (FRED) dengan periode waktu dari bulan April 2022 hingga Desember 2023. Data yang dikumpulkan terdiri dari lima tenor, yaitu 1 bulan, 3 bulan, 6 bulan, 1 tahun, dan 2 tahun.

2.2. Pengujian Asumsi Teoritis

Pengujian asumsi teoritis bertujuan untuk melihat tingkat kesesuaian asumsi normalitas *log return* dan kestabilan volatilitas terhadap kondisi data empiris. Prosedur pengujian asumsi ini dijelaskan pada bagian berikut.

1. Normalitas *Log Return*

Pengujian normalitas *log return* dilakukan dengan menggunakan uji Shapiro–Wilk terhadap seluruh data *log return*. Data *log return* dihitung berdasarkan data harga penutupan harian saham menggunakan persamaan yang dijelaskan oleh [15] pada halaman 5. Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut:

H_0 : *Log return* saham berdistribusi normal,

H_1 : *Log return* saham tidak berdistribusi normal.

Kriteria pengujian didasarkan pada nilai *p – value* dengan tingkat signifikansi $\alpha = 0.05$, di mana H_0 ditolak apabila nilai *p – value* $< \alpha$. Sebaliknya, H_0 gagal ditolak apabila *p – value* $> \alpha$ [16]. Selain itu, pengujian *excess kurtosis* dilakukan untuk menganalisis ketebalan ekor distribusi *log return*. Nilai yang mendekati nol menunjukkan distribusi normal, sedangkan nilai kurang dari nol menunjukkan distribusi lebih datar dengan ekor tipis, dan nilai lebih dari nol

menunjukkan puncak lebih runcing dengan ekor tebal [17]. Dua kondisi terakhir mengindikasikan *log return* tidak berdistribusi normal.

2. Volatilitas Konstan

Pengujian volatilitas konstan dilakukan dengan menggunakan uji ARCH-LM untuk mendeteksi adanya perubahan variansi yang tidak konstan dari waktu ke waktu yang diindikasikan dengan adanya heteroskedastisitas. Prosedur pengujian dilakukan menggunakan data *log return*. Hipotesis yang digunakan dalam uji ini adalah sebagai berikut [15]:

H_0 : Tidak terdapat efek heteroskedastisitas,

H_1 : Terdapat efek heteroskedastisitas.

Kriteria pengujian didasarkan pada nilai *p – value* dengan tingkat signifikansi $\alpha = 0.05$, di mana H_0 ditolak apabila *p – value* < α . Sebaliknya, H_0 gagal ditolak apabila *p – value* > α .

2.3. Pembagian Data

Pembagian data dalam penilaian harga opsi *put* hanya dilakukan pada model berbasis *deep learning*, yaitu LSTM. Hal ini karena model LSTM memerlukan pembagian data menjadi data pelatihan dan pengujian. Dalam penelitian ini, pembagian data mengikuti pendekatan yang digunakan oleh [9], yaitu membagi data menjadi tiga bagian terdiri dari data pelatihan, data validasi, dan data pengujian. Data pelatihan mencakup periode delapan bulan, sedangkan data validasi dan data pengujian masing-masing mencakup periode satu bulan. Periode data tersebut susunan berdasarkan waktu yang berurutan. Selanjutnya, pembagian data diterapkan menggunakan pendekatan bergulir, di mana data pengujian bergerak satu bulan ke depan dari bulan Januari hingga Desember.

2.4. Model Black–Scholes

Model Black–Scholes merupakan model matematis penilaian harga opsi yang dikembangkan oleh Fischer Black dan Myron Scholes (1973). Model ini didasarkan pada prinsip tidak adanya peluang arbitrase dan mengasumsikan kondisi pasar yang ideal. Dalam konteks opsi saham, penerapan model ini didasarkan pada asumsi-asumsi sebagai berikut [18]:

1. Selama sisa umur kontrak, tingkat suku bunga bebas risiko tidak mengalami perubahan.
2. Varians dari *return* saham bersifat tetap dengan pergerakan harga saham mengikuti proses stokastik kontinu.
3. Saham tidak memberikan pembayaran dividen.
4. Jenis opsi yang digunakan adalah opsi Eropa.
5. Tidak terdapat biaya dalam melakukan transaksi.
6. Pada tingkat suku bunga bebas risiko, investor dapat meminjam dan meminjamkan dana dalam jumlah tidak terbatas.
7. Diperbolehkan adanya *short selling* tanpa batasan tambahan.

Berdasarkan asumsi-asumsi tersebut, penerapan model Black–Scholes pada opsi saham dengan jenis opsi *put* dinyatakan melalui Persamaan (1).

$$P_t = Ke^{-rT}N(-d_2) - S_tN(-d_1) \quad (1)$$

dengan P_t menyatakan harga opsi *put* pada waktu t , S_t menyatakan harga saham pada waktu t , K menyatakan harga pelaksanaan, r menyatakan tingkat suku bunga bebas risiko, dan $N(\cdot)$ menyatakan fungsi distribusi kumulatif normal baku. Nilai dari $N(-d_1)$ dan $N(-d_2)$ diperoleh dengan menghitung fungsi distribusi kumulatif normal baku dari parameter d_1 dan d_2 . Kedua parameter tersebut dihitung menggunakan persamaan (2).

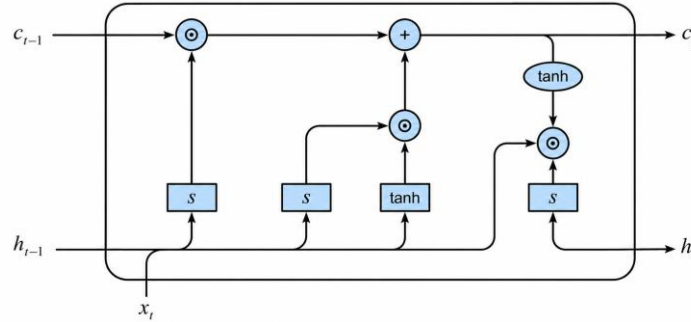
$$d_1 = \frac{\ln(S_t/K) + (r + \sigma^2/2)T}{\sigma\sqrt{T}} \quad (2)$$

$$d_2 = \frac{\ln(S_t/K) + (r - \sigma^2/2)T}{\sigma\sqrt{T}} = d_1 - \sigma\sqrt{T}$$

dengan σ menyatakan volatilitas *return* saham.

2.5. Model Long Short-Term Memory (LSTM)

Model LSTM dalam penelitian ini digunakan sebagai pendekatan *deep learning* untuk menilai harga opsi *put*. Sebagai salah satu jenis Recurrent Neural Network (RNN), LSTM memiliki kemampuan menangkap ketergantungan jangka pendek maupun jangka panjang [11]. Kemampuan ini didukung oleh arsitekturnya yang terdiri atas unit-unit dengan sel memori dan mekanisme gerbang, yaitu *input gate*, *forget gate*, dan *output gate*, yang berfungsi mengatur aliran informasi. Ilustrasi satu unit LSTM ditunjukkan pada Gambar 1.



Gambar 1. Ilustrasi Satu Unit LSTM

Berdasarkan Gambar 1, mekanisme aliran informasi pada satu unit LSTM dimulai dari masuknya informasi dari *hidden state* sebelumnya (h_{t-1}) dan informasi dari *input* saat ini (x_t) ke dalam *forget gate* (f_t) untuk menentukan informasi lama yang dipertahankan. Selanjutnya, dibentuk *candidate state* (\tilde{c}_t) sebagai kandidat informasi baru. Besarnya informasi baru yang ditambahkan ke memori diatur oleh *input gate* (i_t). *Cell state* lama (c_{t-1}) kemudian diperbarui menjadi (c_t) melalui kombinasi informasi yang dipertahankan dan informasi baru. Selanjutnya, *output gate* (o_t) menentukan bagian *cell state* yang akan diteruskan sebagai keluaran. Nilai *cell state* diproses menggunakan fungsi aktivasi *tanh* untuk membatasi rentang nilai, dan hasilnya dikalikan dengan *output gate* untuk menghasilkan *hidden state* baru. Informasi dari satu unit LSTM yang telah diproses kemudian diteruskan ke unit berikutnya dengan mekanisme aliran yang sama. Persamaan untuk masing-masing fungsi dalam mekanisme tersebut disajikan pada Persamaan (3) hingga (8)[19].

$$f_t = S(W_f x_t + U_f h_{t-1} + b_f), \quad (3)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (4)$$

$$i_t = S(W_i x_t + U_i h_{t-1} + b_i), \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (6)$$

$$o_t = S(W_o x_t + U_o h_{t-1} + b_o), \quad (7)$$

$$h_t = o_t \odot \tanh(c_t). \quad (8)$$

dengan W, U , dan b menyatakan parameter pada setiap *gate* dan S menyatakan fungsi sigmoid.

Informasi dalam LSTM merupakan representasi tersembunyi yang dibentuk dari variabel *input* melalui proses pembelajaran dan mekanisme gerbang. Dalam penelitian ini, variabel *input* disusun dalam bentuk *sequence window* sepanjang lima hari berturut-turut untuk menangkap pola temporal antarvariabel. Pemilihan *sequence window* lima hari bertujuan agar model mampu melakukan penilaian harga pada opsi dengan waktu jatuh tempo yang singkat, seperti opsi mingguan, sehingga variasi jatuh tempo yang digunakan menjadi lebih beragam dan dapat merepresentasikan kondisi pasar yang sebenarnya. Pendekatan ini menyebabkan model hanya

mempertahankan memori jangka pendek sehingga lebih sensitif terhadap perubahan harga dan volatilitas terbaru. Oleh karena itu, pendekatan ini dinilai efektif dalam meningkatkan kinerja penilaian harga opsi [9].

Skala antar variabel *input* yang digunakan pada model ini memiliki peredaan cukup jauh karena memiliki satuan yang berbeda. Perbedaan ini dapat menyebabkan model kurang optimal dalam mempelajari pola temporal antar variabel. Oleh karena itu, dilakukan penskalaan untuk menyeragamkan nilai setiap variabel menggunakan fungsi *MinMaxScaler*. Persamaan fungsi *MinMaxScaler* dalam penelitian ini mengacu pada [9].

Selain dipengaruhi oleh skala antar variabel *input*, kinerja model juga ditentukan oleh kombinasi hiperparameter yang digunakan. Kombinasi hiperparameter yang menghasilkan kinerja model optimal diperoleh melalui eksplorasi berbagai konfigurasi menggunakan metode *random search*, yaitu dengan memilih parameter secara acak dari rentang yang telah ditentukan. Rincian hiperparameter beserta rentang nilainya disajikan pada Tabel 1.

Tabel 1. Hiperparameter dan Rentang Nilainya

Hiperparameter	Rentang Nilai
Jumlah Lapisan LSTM	2, 3, 4
Unit LSTM	32, 64, 128
<i>Learning Rate</i>	0.0005 – 0.005
<i>Mini-Batch Size</i>	128, 256, 512
<i>Weight Decay</i>	0 – 1×10^{-4}

2.6. Evaluasi dan Perbandingan Kinerja Model

Evaluasi kinerja model dilakukan untuk mengukur tingkat akurasi model Black–Scholes dan LSTM dalam menilai harga opsi *put*. Dalam penelitian ini, digunakan dua metrik evaluasi, yaitu Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE). Perhitungan kedua metrik tersebut mengacu pada [13]. Nilai RMSE dan MAE kemudian digunakan untuk membandingkan kinerja relatif kedua model. Semakin rendah nilai yang dihasilkan, semakin tinggi tingkat akurasi model. Oleh karena itu, model dengan nilai RMSE dan MAE terendah dianggap memiliki kinerja terbaik dalam penilaian harga opsi dan dipilih sebagai model terbaik dalam penelitian ini.

3. HASIL DAN PEMBAHASAN

3.1. Statistik Deskriptif

Gambaran umum karakteristik data penelitian disajikan melalui analisis statistik deskriptif. Data yang dianalisis meliputi harga penutupan harian saham (*S*), harga *bid*, harga *ask*, dan harga pelaksanaan (*K*). Keempat data tersebut merupakan komponen utama dalam penentuan harga opsi. Hasil perhitungan statistik deskriptif disajikan pada Tabel 2.

Tabel 2. Hasil Statistik Deskriptif

Variabel	N	Mean	Std Dev	Median	Min	Max	Q1	Q3
<i>S</i>	532	276.499	119.112	243.890	112.320	504.090	171.645	409.070
BID	697,267	85.905	114.231	31.600	0.000	594.550	1.560	135.450
ASK	697,267	87.735	115.910	32.800	0.010	601.400	1.770	138.650
<i>K</i>	697,267	333.699	210.595	290.000	5.000	1000.000	165.000	460.000

Berdasarkan Tabel 2, nilai rata-rata dan median pada seluruh variabel menunjukkan adanya perbedaan yang cukup besar, yang menandakan bahwa distribusi data cenderung tidak simetris. Selain itu, nilai standar deviasi yang relatif besar dan rentang antara nilai minimum dan maksimum yang lebar menunjukkan tingginya variasi data. Kondisi ini mencerminkan karakteristik data harga saham dan harga opsi memiliki volatilitas tinggi. Dari nilai kuartil pertama dan kuartil ketiga, terlihat bahwa variabel tersebar cukup luas dengan rentang nilai antara kedua kuartil tersebut yang besar. Sementara itu, terlihat bahwa terdapat selisih yang cukup besar antara nilai kuartal ketiga dengan nilai maksimum. Kondisi ini mengindikasikan adanya *outlier* dalam data penelitian.

3.2. Hasil Pengujian Asumsi Teoritis

Berdasarkan hasil statistik deskriptif pada pembahasan sebelumnya, diketahui bahwa data harga saham mengindikasikan bahwa asumsi teoritis dalam model mungkin tidak sepenuhnya terpenuhi. Oleh karena itu, perlu dilakukan pengujian asumsi teoritis. Pengujian asumsi teoritis ini meliputi uji normalitas *log return* dan volatilitas konstan.

1. Normalitas Log Return

Hasil pengujian normalitas *log return* menggunakan metode pengujian Shapiro–Wilk ditampilkan pada Tabel 3.

Shapiro-Wilk normality test		
Data	<i>W</i>	<i>p – value</i>
<i>Log return</i>	0.97485	5.923×10^{-8}

Berdasarkan Tabel 3, hasil pengujian normalitas terhadap *log return* saham menghasilkan nilai $p - value = 5.923 \times 10^{-8}$. Nilai tersebut lebih kecil dari tingkat signifikansi ($\alpha = 0.05$) menyebabkan H_0 ditolak, sehingga *log return* tidak berdistribusi normal. Pelanggaran terhadap asumsi normalitas *log return* sering terjadi pada kondisi pasar yang sesungguhnya. Hal ini diperkuat oleh pernyataan dari [15] yang mengatakan bahwa distribusi *log return* sering kali tidak sepenuhnya mengikuti asumsi normalitas. Penyimpangan terhadap asumsi normalitas umumnya disebabkan oleh distribusi yang memiliki ekor lebih tebal dibandingkan dengan distribusi normal. Karakteristik ekor distribusi *log return* dapat dianalisis melalui nilai *excess kurtosis*. Perhitungan *excess kurtosis* menunjukkan nilai sebesar 2.837841. Nilai tersebut mengindikasikan bahwa distribusi *log return* memiliki ekor yang lebih tebal dibandingkan distribusi normal. Temuan ini memperkuat hasil pengujian normalitas yang menunjukkan bahwa asumsi normalitas *log return* tidak terpenuhi pada data harga saham dalam penelitian ini.

2. Volatilitas Konstan

Hasil pengujian volatilitas konstan menggunakan metode pengujian ARCH-LM ditampilkan pada Tabel 4.

ARCH LM-test			
Data	Chi-squared	<i>df</i>	<i>p – value</i>
<i>Log return</i>	5.1478	12	0.9529

Berdasarkan Tabel 4, hasil pengujian volatilitas terhadap *log return* saham menunjukkan nilai $p - value$ sebesar 0.9529. Nilai tersebut lebih besar dari tingkat signifikansi ($\alpha = 0.05$) menyebabkan H_0 gagal ditolak, sehingga tidak terdapat bukti adanya perubahan variansi dari waktu ke waktu. Karena volatilitas didefinisikan sebagai variansi dari *log return*, maka hasil ini menunjukkan bahwa volatilitas *log return* tidak mengalami perubahan sehingga dapat disimpulkan bersifat konstan dan asumsi teoritis ini terpenuhi. Kondisi volatilitas konstan

mengindikasikan bahwa *log return* memiliki pola pergerakan yang sistematis di mana variansnya tidak menunjukkan kecenderungan meningkat atau menurun secara terus menerus.

3.3. Hasil dan Analisis Model Black–Scholes

Model Black–Scholes dalam penelitian ini digunakan sebagai pendekatan matematis untuk menilai harga opsi *put* saham NVIDIA. Model ini mengasumsikan bahwa volatilitas bersifat konstan sepanjang periode penilaian, serta tingkat suku bunga bebas risiko tetap dalam satu kontrak selama sisa umur kontrak. Hasil penilaian harga opsi disajikan pada Tabel 5.

Tabel 5. Hasil Penilaian Harga Opsi Put Menggunakan Model Black–Scholes

ID Kontrak	Tanggal Observasi	Waktu Hingga Jatuh Tempo	Harga Aktual Opsi	Harga Penilaian Opsi
1703883600_800.0	2023-12-29	0.0	304.875	302.950
1703883600_820.0	2023-12-29	0.0	324.850	322.950
1703883600_840.0	2023-12-29	0.0	344.850	342.950
1766178000_800.0	2023-12-29	721.0	312.650	303.574
1766178000_820.0	2023-12-29	721.0	330.100	318.779
1766178000_840.0	2023-12-29	721.0	347.825	334.156

Hasil penilaian harga opsi *put* pada Tabel 5 merupakan sebagian dari keseluruhan hasil penilaian selama periode pengamatan, dengan data yang ditampilkan mencakup beberapa kontrak opsi pada tanggal observasi 29 Desember 2023. Pada kontrak dengan jatuh tempo nol hari dan harga pelaksanaan 800, 820, dan 840, diperoleh harga penilaian masing-masing sebesar 302.950, 322.950, dan 342.950. Di sisi lain, kontrak dengan jatuh tempo 721 hari pada harga pelaksanaan yang sama menghasilkan nilai sebesar 303.574, 318.779, dan 334.156. Jika dibandingkan dengan harga aktual, kontrak dengan jatuh tempo nol hari menunjukkan nilai kesalahan yang relatif kecil, yaitu masing-masing 1.925, 1.90, dan 1.90. Sebaliknya, kontrak dengan jatuh tempo 721 hari memiliki nilai kesalahan yang lebih besar, yaitu 9.076, 11.321, dan 13.669.

Hasil penilaian opsi *put* menggunakan model Black–Scholes menunjukkan adanya kecenderungan peningkatan nilai kesalahan seiring bertambahnya waktu hingga jatuh tempo. Kondisi ini diduga disebabkan oleh penyimpangan terhadap asumsi normalitas *log return*. Temuan ini sejalan dengan [20], yang menyatakan bahwa pelanggaran terhadap asumsi normalitas *log return* dapat menyebabkan harga opsi yang dihasilkan oleh model Black–Scholes menjadi *underpricing* maupun *overpricing*.

Selain itu, asumsi tingkat suku bunga yang konstan selama sisa umur kontrak turut memengaruhi kesalahan penilaian harga opsi *put* dalam model Black–Scholes. Perlakuan suku bunga sebagai nilai tetap berpotensi menimbulkan kesalahan penilaian yang signifikan, terutama pada kontrak dengan waktu jatuh tempo yang relatif panjang [8]. Dalam model ini, suku bunga berperan sebagai faktor diskonto untuk menghitung nilai sekarang dari harga pelaksanaan di masa mendatang. Oleh karena itu, perubahan suku bunga yang tidak diperhitungkan dapat menyebabkan ketidaktepatan dalam proses diskonto, sehingga harga opsi yang dihasilkan menyimpang dari harga aktual.

3.4. Hasil dan Analisis Model Long Short-Term Memory (LSTM)

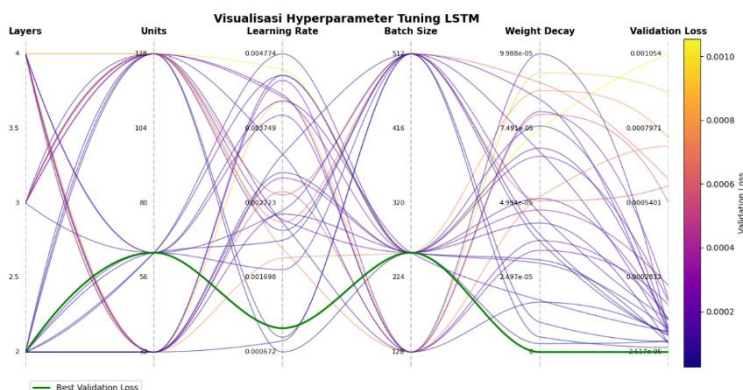
Model LSTM dalam penelitian ini digunakan sebagai pendekatan berbasis *deep learning* untuk menilai harga opsi *put*. Berbeda dengan model Black–Scholes, variabel volatilitas dan tingkat suku bunga pada model ini diperlakukan sebagai nilai yang dinamis, karena pendekatan *deep learning* tidak bergantung pada asumsi teoritis tertentu. Sebelum proses penilaian dilakukan, terlebih dahulu dilakukan pencarian hiperparameter untuk memperoleh kombinasi yang mampu

mengoptimalkan kinerja model. Kombinasi hiperparameter optimal yang digunakan dalam penelitian ini disajikan pada Tabel 6.

Tabel 6. Hasil Optimasi Hiperparameter

Hiperparameter	Nilai
Jumlah Lapisan LSTM	2
Unit LSTM	64
Learning Rate	0.001
Mini-Batch Size	256
Weight Decay	0

Kombinasi hiperparameter optimal ditentukan berdasarkan nilai kesalahan paling rendah di antara seluruh kombinasi hiperparameter yang diuji. Nilai kesalahan yang dihasilkan oleh kombinasi pada Tabel 6 sebesar 2.67×10^{-5} . Secara keseluruhan, kombinasi hiperparameter lainnya menghasilkan nilai kesalahan yang cenderung kecil. Hal ini dapat dilihat pada ilustrasi seluruh kombinasi hiperparameter yang dituning dalam penelitian ini yang ditunjukkan pada Gambar 2.



Gambar 2. Hasil Seluruh Kombinasi Hiperparameter

Berdasarkan Gambar 2, kombinasi hiperparameter cenderung berada di bawah angka 5.40×10^{-4} . Hal ini menunjukkan bahwa model memiliki tingkat sensitivitas yang rendah terhadap variasi hiperparameter dalam rentang yang diuji, sehingga terdapat beberapa kombinasi yang mampu meminimalkan nilai kesalahan.

Selanjutnya, kombinasi hiperparameter optimal diterapkan pada model LSTM untuk menilai harga opsi *put*. Hasil penilaian harga opsi *put* disajikan pada Tabel 7.

Tabel 7. Hasil Prediksi Harga Opsi Put Menggunakan Model LSTM

ID Kontrak	Tanggal Observasi	Waktu Hingga Jatuh Tempo	Harga Aktual Opsi	Harga Penilaian Opsi
1703883600_800.0	2023-12-29	0.0	304.875	299.708
1703883600_820.0	2023-12-29	0.0	324.850	319.289
1703883600_840.0	2023-12-29	0.0	344.850	338.877
1766178000_800.0	2023-12-29	721.0	312.650	310.764
1766178000_820.0	2023-12-29	721.0	330.100	328.394
1766178000_840.0	2023-12-29	721.0	347.825	346.311

Hasil penilaian harga opsi *put* pada Tabel 7 merupakan sebagian dari keseluruhan hasil penilaian selama periode pengamatan, dengan data yang ditampilkan mencakup beberapa kontrak opsi pada tanggal observasi 29 Desember 2023. Pada kontrak dengan jatuh tempo nol hari dan harga pelaksanaan 800, 820, dan 840, diperoleh harga penilaian masing-masing sebesar 299.708, 319.289, dan 338.877. Di sisi lain, kontrak dengan jatuh tempo 721 hari pada harga pelaksanaan yang sama menghasilkan nilai sebesar 310.764, 328.394, dan 346.311. Jika dibandingkan dengan harga aktual, kontrak dengan jatuh tempo nol hari menunjukkan nilai kesalahan yang relatif moderat, yaitu masing-masing 5.167, 5.561, dan 5.973. Sebaliknya, kontrak dengan jatuh tempo 721 hari memiliki nilai kesalahan yang lebih kecil, yaitu 1.886, 1.706, dan 1.514.

Hasil penilaian opsi *put* menggunakan model LSTM menunjukkan adanya kecenderungan penurunan nilai kesalahan seiring bertambahnya waktu hingga jatuh tempo. Kondisi ini dapat dipengaruhi oleh penggunaan pendekatan bergulir dalam penilaian harga opsi *put*. Pendekatan tersebut meniru metode penilaian harga opsi yang dilakukan oleh pelaku pasar yang sebenarnya [9]. Melalui pendekatan ini, nilai kesalahan dapat diminimalkan karena model dilatih ulang pada setiap periode menggunakan data pelatihan, validasi, dan pengujian yang diperbarui.

Meskipun demikian, hasil penilaian yang dihasilkan masih berpotensi mengandung bias. Hal ini terlihat dari perbandingan dengan harga aktual yang cenderung menunjukkan *underpricing*. Dalam praktik investasi, kecenderungan *underpricing* dapat menyebabkan nilai perlindungan risiko yang diperoleh investor menjadi kurang optimal. Kondisi ini diduga dipengaruhi oleh karakteristik model yang melakukan *denoising* untuk menghasilkan prediksi yang lebih halus, sehingga model menjadi kurang responsif terhadap lonjakan harga yang ekstrem [21]. Akibatnya, lonjakan harga yang tidak tertangkap oleh model menyebabkan perbedaan antara harga hasil penilaian dan harga aktual.

3.5. Evaluasi dan Perbandingan Kinerja Model

Evaluasi kinerja model dilakukan menggunakan metrik RMSE dan MAE untuk mengukur tingkat akurasi hasil penilaian harga opsi *put* terhadap harga aktual. Hasil perhitungan kedua metrik tersebut disajikan pada Tabel 8.

Tabel 8. Hasil Perhitungan Metrik Evaluasi

Model	RMSE	MAE
Black–Scholes	7.303	3.656
LSTM	5.100	3.097


Berdasarkan Tabel 8, model Black–Scholes menghasilkan nilai RMSE sebesar 7.303 dan MAE sebesar 3.656, sedangkan model LSTM menghasilkan RMSE sebesar 5.100 dan MAE sebesar 3.079. Hasil ini menunjukkan bahwa model LSTM memiliki tingkat akurasi yang lebih tinggi dibandingkan model Black–Scholes berdasarkan kedua metrik evaluasi. Oleh karena itu, model LSTM dapat dipilih sebagai model terbaik dalam penelitian ini. Meskipun demikian, model Black–Scholes tidak selalu menunjukkan akurasi yang lebih rendah.

Pada Tabel 5 dan Tabel 7 terlihat bahwa model Black–Scholes memiliki akurasi yang lebih baik dari model LSTM pada opsi dengan jatuh tempo nol hari. Sebaliknya, model LSTM menunjukkan akurasi yang lebih unggul pada opsi dengan jatuh tempo 721 hari. Hasil ini mengindikasikan bahwa akurasi kinerja kedua model bergantung pada variabel waktu hingga jatuh tempo. Oleh sebab itu, evaluasi kinerja model juga dilakukan berdasarkan pengelompokan terhadap variabel ini. Hasil perhitungan metrik evaluasi pada setiap kelompok waktu hingga jatuh tempo disajikan pada Tabel 9.

Tabel 9. Hasil Perhitungan Metrik Evaluasi Berdasarkan Waktu Jatuh Tempo

Waktu Hingga Jatuh Tempo	RMSE		MAE	
	Black–Scholes	LSTM	Black–Scholes	LSTM
1 Bulan	1.753	5.165	0.891	2.891
3 Bulan	3.458	5.118	2.285	3.015
6 Bulan	6.030	5.303	3.827	3.240
9 Bulan	7.860	5.001	4.810	3.186
1 Tahun	10.294	4.545	6.031	2.947
1.5 Tahun	13.106	4.742	7.553	3.072
2 Tahun	12.499	5.329	7.198	3.639

Berdasarkan Tabel 9, terlihat bahwa model Black–Scholes memiliki tingkat akurasi yang lebih tinggi pada opsi dengan jatuh tempo satu dan tiga bulan. Pada jatuh tempo yang relatif singkat, asumsi teoritis dalam model Black–Scholes masih cukup relevan dan mampu mendekati kondisi pasar yang sebenarnya, sehingga kesalahan penilaian yang dihasilkan cenderung lebih kecil. Sementara itu, model LSTM menunjukkan akurasi yang lebih baik pada opsi dengan jatuh tempo enam bulan hingga dua tahun. Kondisi ini diduga dipengaruhi oleh penggunaan pendekatan bergulir yang memungkinkan model menyesuaikan pembelajaran secara berkala terhadap data terbaru, sehingga kestabilan akurasi penilaian dapat lebih terjaga. Tingkat akurasi kedua model tersebut diilustrasikan melalui grafik garis pada Gambar 3.



Gambar 3. a) Grafik Perbandingan RMSE; b) Grafik Perbandingan MAE

Berdasarkan Gambar 3. a) dan b) terlihat bahwa nilai kesalahan pada model Black–Scholes, baik RMSE maupun MAE, menunjukkan kecenderungan meningkat seiring bertambahnya waktu hingga jatuh tempo. Sebaliknya, model LSTM menunjukkan pola kesalahan yang relatif stabil. Berdasarkan hasil tersebut, dapat disimpulkan bahwa model Black–Scholes lebih sesuai digunakan untuk penilaian harga opsi dengan waktu hingga jatuh tempo kurang dari tiga bulan. Sementara itu, model LSTM lebih unggul dan direkomendasikan untuk opsi dengan waktu hingga jatuh tempo lebih dari enam bulan.

4. KESIMPULAN

Model Black–Scholes menghasilkan penilaian harga opsi put saham NVIDIA yang bervariasi. Pada tanggal observasi 29 Desember 2023, untuk jatuh tempo nol hari, harga opsi *put* dengan harga pelaksanaan 800, 820, dan 840 masing-masing sebesar 302.950, 322.950, dan 342.950. Sementara itu, untuk jatuh tempo 721 hari, harga yang dihasilkan masing-masing sebesar 303.574, 318.779, dan 334.156. Pada observasi yang sama, model LSTM menghasilkan harga opsi *put* sebesar 299.708, 319.289, dan 338.877 untuk jatuh tempo nol hari, serta 310.764, 328.394, dan 346.311 untuk jatuh tempo 721 hari.

Berdasarkan hasil evaluasi kinerja, secara keseluruhan model LSTM menunjukkan tingkat akurasi yang lebih tinggi dibandingkan model Black–Scholes. Namun, jika ditinjau berdasarkan waktu hingga jatuh tempo, model Black–Scholes cenderung lebih unggul pada opsi dengan jatuh tempo kurang dari tiga bulan, sedangkan model LSTM menunjukkan performa yang lebih baik pada opsi dengan jatuh tempo lebih dari enam bulan. Oleh karena itu, model Black–Scholes lebih direkomendasikan untuk penilaian opsi jangka pendek, sementara model LSTM lebih sesuai digunakan untuk opsi dengan jatuh tempo yang lebih panjang.

Penelitian selanjutnya disarankan menggunakan data keuangan dengan tahun terbaru supaya mampu merepresentasikan kondisi pasar secara lebih akurat dan meningkatkan kinerja model. Selain itu, estimasi tingkat suku bunga bebas risiko dapat ditingkatkan melalui penggunaan metode interpolasi dengan derajat lebih tinggi untuk memperoleh hasil yang lebih halus dan mendekati nilai sebenarnya. Diharapkan peningkatan pada kualitas data dan metode estimasi dapat memperbaiki kinerja model serta menghasilkan penilaian harga opsi yang lebih akurat.

ACKNOWLEDGEMENT

Penulis menyampaikan ucapan terima kasih kepada Universitas Negeri Malang atas dukungan pendanaan melalui skema hibah penelitian skripsi tahun anggaran 2026 dengan nomor kontrak 14.04.833/UN32.14.1/LT/2026. Dukungan tersebut memberikan kontribusi yang besar dalam seluruh proses penelitian dari awal sampai akhir.

REFERENSI

- [1] World Federation of Exchanges, “FY 2025 Market Highlights,” 2026.
- [2] K. Grobys, “Magnificent 7: unsustainable growth and systemic risk,” *Review of Quantitative Finance and Accounting*, Oct. 2025, doi: 10.1007/s11156-025-01458-6.
- [3] NVIDIA Corporation, “NVIDIA announces financial results for third quarter fiscal 2024,” Nov. 21, 2023.
- [4] Yahoo Finance, “NVIDIA Corporation (NVDA) Historical Data.” [Online]. Available: <https://finance.yahoo.com/quote/NVDA/history>. Accessed: Apr. 26, 2026.
- [5] S. Yang, “Analysis on hedging and risk management of options and futures,” *Highlights in Business, Economics and Management*, vol. 15, pp. 273–280, 2023, doi: 10.54097/hbem.v15i.9456.
- [6] J. Hull, *Options, Futures, and Other Derivatives*. Pearson, 2022.
- [7] A. Rakshit, G. Bandyopadhyay, and T. Chakraborty, “Hedge error analysis in Black-Scholes option pricing model: an asymptotic approach towards finite difference,” 2024.
- [8] V. K. Singh and P. Kumar, “Effectiveness of deterministic option pricing models: new evidence from Nifty and Bank Nifty index options,” *Journal of Asset Management*, vol. 25, no. 2, pp. 172–189, Feb. 2024, doi: 10.1057/s41260-024-00348-1.
- [9] R. Pimentel et al., “Option pricing with deep learning: a long short-term memory approach,” *Decisions in Economics and Finance*, pp. 1–32, Apr. 2025, doi: 10.1007/s10203-025-00518-9.
- [10] A. M. D’Uggento, M. Biancardi, and D. Ciriello, “Predicting option prices: from the Black-Scholes model to machine learning methods,” *Big Data Research*, vol. 40, May 2025, doi: 10.1016/j.bdr.2025.100518.
- [11] O. B. Sezer, M. U. Gudelek, and A. M. Ozbayoglu, “Financial time series forecasting with deep learning: a systematic literature review: 2005–2019,” *Applied Soft Computing*, vol. 90, May 2020, doi: 10.1016/j.asoc.2020.106181.
- [12] D. Liu and A. Wei, “Regulated LSTM artificial neural networks for option risks,” *FinTech*, vol. 1, no. 2, pp. 180–190, Jun. 2022, doi: 10.3390/fintech1020014.

- [13] L. Liang and X. Cai, “Time-sequencing European options and pricing with deep learning – Analyzing based on interpretable ALE method,” *Expert Systems with Applications*, vol. 187, Jan. 2022, doi: 10.1016/j.eswa.2021.115951.
- [14] Y. Liu and X. Zhang, “Option pricing using LSTM: a perspective of realized skewness,” *Mathematics*, vol. 11, no. 2, p. 314, Jan. 2023, doi: 10.3390/math11020314.
- [15] R. S. Tsay, *Analysis of Financial Time Series*. Wiley, 2010.
- [16] G. D. Ahadi and N. T. L. E. Zain, “Pemeriksaan uji kenormalan dengan Kolmogorov-Smirnov, Anderson-Darling dan Shapiro-Wilk,” *Eigen Mathematics Journal*, vol. 6, no. 1, pp. 11–19, Jun. 2023, doi: 10.29303/emj.v6i1.131.
- [17] G. Hatem, J. Zeidan, M. Godossens, and C. Moreira, “Normality testing methods and the importance of skewness and kurtosis in statistical analysis,” *BAU Journal – Science and Technology*, vol. 3, no. 2, Jun. 2022, doi: 10.54729/ktpe9512.
- [18] F. Black and M. Scholes, “The pricing of options and corporate liabilities,” *Journal of Political Economy*, vol. 81, no. 3, pp. 637–654, 1973. [Online]. Available: <https://doi.org/10.1086/260062>
- [19] P. A. Riyantoko, T. M. Fahrudin, K. M. Hindrayani, and E. M. Safitri, “Analisis prediksi harga saham sektor perbankan menggunakan algoritma long short-term memory (LSTM),” in Proc. *Seminar Nasional Informatika*, pp. 427–435, Dec. 2020.
- [20] F. N. Nwobi, C. A. Ugomma, and E. U. Ohaegbulem, “An empirical assessment of lognormality in Black-Scholes option pricing model,” *International Journal of Scientific and Research Publications*, vol. 11, no. 11, pp. 408–419, Nov. 2021, doi: 10.29322/ijsrp.11.11.2021.p11950.
- [21] Q. Tang, T. Fan, R. Shi, and J. Huang, “Prediction of financial time series using LSTM and data denoising methods,” arXiv preprint arXiv:2103.03505, Mar. 2021, doi: 10.48550/arXiv.2103.03505.