

BAB II

Kajian Pustaka

2.1 Penelitian Terdahulu

Tabel 2. 1 Penelitian Terdahulu

No	Peneliti (Tahun)	Judul Penelitian	Metode yang Digunakan	Hasil Utama
1	Jahanshahi et al. (2022)	Artificial Intelligence-Based Prediction of Crude Oil Prices Using Multiple Features under the Effect of Russia-Ukraine War and COVID-19 Pandemic	LSTM, Bi-LSTM, SVM, RF	MAE terbaik: 0.3786 pada Bi-LSTM
2	Huang (2023)	Enhancing Stock Market Prediction Through LSTM Modeling and Analysis	LSTM	Peningkatan Kinerja: 35.18% RMSE: ~0.355 (Training) Model LSTM melampaui performa model benchmark (Xu & Cohen) secara signifikan.
3	Zhao et al. (2024)	Multi-Step Ahead Forecasting of Oil Prices Using Advanced LSTM Techniques	Stacked LSTM (Multi-layer)	RMSE: 0.1239, MAE: 0.09. Model Stacked LSTM menunjukkan mengurangi error hingga 40-50% dibanding single-layer LSTM.

Penggunaan model Long Short-Term Memory (LSTM) dalam prediksi deret waktu keuangan telah banyak dilakukan dan menunjukkan performa yang menjanjikan. Sebagaimana ditunjukkan pada **Tabel 2.1**, penelitian oleh Jahanshahi *et al.* (2022) dalam jurnal *Mathematics* membandingkan model LSTM, Bi-LSTM, serta sejumlah metode *machine learning* konvensional seperti Support Vector Machine (SVM), regresi linear, dan Random Forest. Studi tersebut memanfaatkan berbagai fitur input dengan mempertimbangkan pengaruh krisis global seperti pandemi COVID-19 dan perang Rusia–Ukraina. Hasil penelitian memperlihatkan bahwa model Bi-LSTM memberikan akurasi prediksi lebih tinggi dibanding model lainnya, dengan nilai rata-rata MAE sebesar 0.3786. Namun, penelitian ini belum mengadopsi pendekatan stacked LSTM untuk menangkap pola sekuensial yang lebih kompleks dari data historis harga minyak [21].

Pada **Tabel 2.1** juga ditampilkan penelitian oleh Huang (2023) dalam *EAI Endorsed Transactions* yang berfokus pada prediksi harga saham Google (GOOGL) menggunakan model LSTM. Penelitian ini menegaskan efektivitas LSTM dalam menangkap dinamika harga saham yang nonlinier dan kompleks. Model LSTM pada studi tersebut terbukti mengungguli pendekatan lain seperti model Xu & Cohen serta K. Ullah & M. Qasim, masing-masing sebesar 35.18% dan 5.86%. Meskipun demikian, penelitian ini tidak mengeksplorasi penggunaan stacked LSTM dan tidak secara langsung mengkaji prediksi harga komoditas energi seperti minyak mentah. Walau begitu, pendekatan dan hasilnya memperkuat relevansi LSTM dalam analisis deret waktu keuangan [11].

Sementara itu, Zhao *et al.* (2024) mengembangkan pendekatan *multi-step ahead forecasting* untuk harga minyak mentah dengan menerapkan teknik *Stacked LSTM* yang melibatkan penggunaan lapisan tersembunyi (*hidden layers*) bertumpuk. Hasil eksperimen menunjukkan bahwa arsitektur bertumpuk ini mampu menghasilkan akurasi yang sangat tinggi dengan nilai RMSE sebesar 0.1239 dan R^2 mencapai 0.985, jauh mengungguli stabilitas model LSTM satu lapis (*single-layer*) dalam menangkap pola non-linear yang kompleks. Kendati demikian, fokus utama penelitian ini masih menitikberatkan pada pendalaman teknis arsitektur model semata dan belum sepenuhnya mengeksplorasi integrasi fitur eksternal yang dinamis, seperti sentimen berita geopolitik atau indikator makroekonomi. Hal ini mengindikasikan bahwa penggabungan arsitektur *Stacked LSTM* dengan variabel eksogen masih menjadi celah penelitian yang relevan untuk dikembangkan guna meningkatkan sensitivitas model terhadap guncangan pasar yang tiba-tiba [22].

Secara keseluruhan, ketiga penelitian yang dirangkum dalam **Tabel 2.1** menegaskan efektivitas LSTM dalam prediksi harga berbasis time series, tetapi belum banyak yang mengaplikasikan arsitektur stacked LSTM secara eksplisit untuk prediksi harga USOIL. Kondisi ini menunjukkan adanya celah penelitian (*research gap*) yang dapat diisi oleh penelitian ini, yakni dengan menguji

kemampuan stacked LSTM dalam menangkap pola yang lebih dalam dan kompleks pada data historis harga minyak mentah (USOIL).

2.2 Minyak Mentah dan Pergerakan Harganya

2.2.1 Pengertian USOIL (WTI Crude Oil)

Minyak mentah merupakan salah satu komoditas energi paling berpengaruh dalam perekonomian global, dengan tingkat konsumsi dan permintaan yang tinggi di seluruh dunia. Salah satu jenis minyak mentah yang menjadi standar harga di pasar internasional adalah *West Texas Intermediate (WTI)*, yang dalam perdagangan komoditas dikenal sebagai *USOIL*. *WTI* adalah jenis minyak mentah ringan dan manis yang berasal dari *Amerika Serikat* dan digunakan sebagai acuan dalam kontrak berjangka di pasar *New York Mercantile Exchange (NYMEX)*. Keunggulan *WTI* terletak pada kadar sulfur yang rendah dan densitas yang ringan, sehingga menjadikannya lebih efisien dalam proses penyulingan menjadi produk bahan bakar akhir [2].

Dalam konteks pasar global, harga *USOIL* merepresentasikan dinamika permintaan dan pasokan energi dunia serta menjadi barometer kondisi ekonomi makro dan geopolitik global. Perdagangan *USOIL* bersifat *real-time* dan sangat dipengaruhi oleh fluktuasi sentimen pasar yang dinamis. Selain menjadi indikator utama dalam pasar energi, pergerakan harga *USOIL* juga menjadi dasar pengambilan keputusan oleh pelaku pasar, analis keuangan, hingga otoritas kebijakan energi [3], [6]. Oleh karena itu, pemahaman mendalam mengenai karakteristik dan perilaku harga *USOIL* menjadi fondasi penting dalam pengembangan model prediktif yang presisi [2], [3].

2.2.2 Faktor-Faktor yang Mempengaruhi Harga Minyak

Harga minyak mentah, termasuk *USOIL*, ditentukan oleh interaksi kompleks antara faktor fundamental, geopolitik, dan ekspektasi pasar. Secara fundamental, penawaran dan permintaan global menjadi penentu utama, di mana pertumbuhan ekonomi, konsumsi energi, serta kapasitas produksi negara-negara seperti *Amerika Serikat*, *Rusia*, dan anggota *OPEC* memainkan peran kunci. Geopolitik seperti konflik di *Timur Tengah* dapat menyebabkan gangguan pasokan, sementara inovasi teknologi seperti *hydraulic fracturing* di *AS* berkontribusi pada peningkatan suplai global. Selain itu, pasar minyak juga dipengaruhi oleh faktor spekulatif, di mana aktivitas *trader*, *hedge fund*, dan algoritma perdagangan menciptakan volatilitas harga jangka pendek. Nilai tukar dolar *AS* juga berdampak langsung, karena minyak global diperdagangkan dalam mata uang tersebut, sehingga perubahan kurs dapat mempengaruhi daya beli negara importir. Permintaan energi pasca-pandemi *COVID-19*, peralihan ke energi terbarukan, serta kebijakan iklim global menjadi faktor struktural yang menekan volatilitas harga minyak dalam jangka panjang. Faktor-faktor ini sering kali menimbulkan ketidakpastian pasar, menjadikan prediksi harga minyak sebagai

tantangan besar dalam analisis komoditas [6], [4]. Oleh karena itu, penting untuk mempertimbangkan faktor-faktor multidimensi ini dalam mengembangkan pendekatan prediksi yang mampu menangkap kompleksitas pasar minyak.

2.2.3 Karakteristik Time Series Harga Minyak

Harga minyak mentah, seperti *USOIL*, merupakan jenis data deret waktu (*time series*) yang memiliki karakteristik khusus dan kompleks, yang harus diperhatikan dalam analisis prediktif. Salah satu karakteristik utamanya adalah non-stasioneritas, yaitu perubahan nilai rata-rata dan variansi sepanjang waktu, yang sering kali disebabkan oleh peristiwa eksternal seperti krisis ekonomi atau kebijakan geopolitik. Selain itu, data harga minyak menunjukkan volatilitas tinggi (*high volatility*), dengan fluktuasi harga yang besar dalam periode pendek akibat reaksi pasar terhadap informasi baru. Sering pula ditemukan autokorelasi, yaitu hubungan antara nilai harga masa kini dengan harga sebelumnya, yang menunjukkan adanya pola dalam deret waktu. Karakteristik lain adalah musiman (*seasonality*), misalnya peningkatan permintaan selama musim dingin atau liburan. Selain itu, fenomena heteroskedastisitas, yaitu variabilitas *error* yang tidak konstan, menjadikan analisis model linier seperti *ARIMA* kurang efektif. Oleh sebab itu, pendekatan berbasis *deep learning* seperti *Long Short-Term Memory (LSTM)* menjadi solusi alternatif karena mampu menangkap pola sekuensial dan non-linier dalam data dengan akurasi lebih tinggi. Penelitian terdahulu telah menunjukkan efektivitas *LSTM* dalam merespons dinamika pasar energi yang fluktuatif dan sulit diprediksi [1], [9], [7]. Pendekatan ini menjadi semakin relevan mengingat kebutuhan untuk memahami pola deret waktu yang tidak terstruktur dan tidak linier dalam pergerakan harga minyak mentah.

2.3 Prediksi Time Series

2.3.1 Definisi Time Series

Time series atau deret waktu merupakan kumpulan data yang direkam secara berurutan berdasarkan waktu, dengan interval waktu yang konstan, seperti harian, mingguan, atau bulanan. Data ini memiliki ciri khas berupa ketergantungan temporal, yang berarti nilai masa lalu memiliki pengaruh terhadap nilai saat ini maupun masa depan. Dalam konteks ekonomi dan finansial, time series sangat penting karena menggambarkan dinamika harga, volume perdagangan, indeks pasar, dan indikator ekonomi lainnya. Data harga minyak mentah (*USOIL*), misalnya, termasuk jenis data time series karena perubahan nilainya dicatat secara berkala dan dipengaruhi oleh faktor historis. Analisis time series tidak hanya bertujuan untuk memahami pola masa lalu, tetapi juga untuk membangun model prediksi berdasarkan pola, tren, dan siklus yang teridentifikasi dalam data. Beberapa komponen penting yang sering dianalisis dalam *time series* adalah tren jangka panjang, pola musiman, dan fluktuasi acak. Pemodelan *time series* memerlukan pendekatan statistik atau komputasional yang mampu mengenali pola kompleks dalam data historis yang sering bersifat *non-stasioner*

dan *non-linier*. Oleh karena itu, penting untuk memahami karakteristik dasar dari data *time series* sebelum memilih metode prediksi yang sesuai [1], [8].

2.3.2 Teknik Umum untuk Prediksi Time Series (ARIMA, SVR, Random Forest, dll)

Seiring dengan meningkatnya kebutuhan untuk melakukan prediksi deret waktu yang akurat, berbagai teknik telah dikembangkan dan diaplikasikan dalam banyak studi. Pendekatan tradisional seperti *AutoRegressive Integrated Moving Average (ARIMA)* telah lama digunakan untuk memodelkan data *time series* yang *stasioner*, dengan asumsi bahwa hubungan masa lalu dapat direpresentasikan secara *linier*. Meskipun cukup efektif pada data yang memiliki pola musiman atau *tren linier*, *ARIMA* tidak mampu menangkap dinamika *non-linier* atau ketergantungan jangka panjang. Di sisi lain, pendekatan berbasis *machine learning* seperti *Support Vector Regression (SVR)* dan *Random Forest* mulai digunakan untuk menangani kompleksitas *non-linier* dalam data *time series*. *SVR* unggul dalam memodelkan hubungan kompleks dengan margin yang ketat, sedangkan *Random Forest* mengandalkan banyak pohon keputusan untuk menghasilkan prediksi yang *robust* terhadap *outlier* dan *noise*. Namun, metode tersebut tetap memiliki keterbatasan dalam memahami struktur sekuensial dan memori jangka panjang dari data *time series*. Oleh karena itu, muncul kebutuhan akan metode yang mampu mengekstraksi pola temporal yang lebih dalam dari deret waktu yang panjang dan kompleks [2], [6].

2.3.3 Perbandingan Metode Konvensional dan Deep Learning dalam Prediksi Time Series

Dalam dekade terakhir, pendekatan berbasis *deep learning*, khususnya *Recurrent Neural Network (RNN)* dan turunannya seperti *Long Short-Term Memory (LSTM)*, telah menjadi alternatif unggulan untuk prediksi data *time series* karena kemampuannya dalam mengatasi keterbatasan metode konvensional. Berbeda dari *ARIMA* atau *SVR* yang umumnya memiliki asumsi distribusi dan stasioneritas tertentu, *LSTM* mampu menangkap ketergantungan jangka panjang dan pola sekuensial dalam data yang bersifat *non-linier* dan *non-stasioner*. *LSTM* dirancang dengan mekanisme *gating (input, forget, dan output gates)* yang memungkinkannya untuk mempertahankan informasi relevan dalam urutan data yang panjang tanpa mengalami masalah *vanishing gradient* seperti pada *RNN* standar. Beberapa studi membuktikan bahwa performa *LSTM* dalam prediksi harga komoditas, termasuk minyak mentah, menunjukkan akurasi yang lebih tinggi dibanding metode statistik tradisional. Penelitian oleh Raut [3] dan Xiao [4] menyatakan bahwa model *LSTM* memiliki nilai *MAE* dan *RMSE* yang lebih rendah dalam prediksi harga energi dibandingkan *ARIMA* dan *SVR*. Selain itu, Sha [5] menunjukkan bahwa penggabungan beberapa *layer LSTM* dalam konfigurasi *stacked LSTM* meningkatkan kemampuan model dalam menangkap representasi fitur temporal yang lebih dalam, sehingga menghasilkan prediksi yang lebih stabil dan presisi. Berdasarkan perbandingan ini, dapat disimpulkan bahwa pendekatan *deep learning* menawarkan keunggulan signifikan dalam pemodelan deret waktu

kompleks seperti harga *USOIL*, yang memiliki dinamika pasar yang sangat fluktuatif dan tidak linier.

2.4 LSTM dan Stacked LSTM

2.4.1 Konsep Dasar LSTM

Long Short-Term Memory (LSTM) adalah salah satu varian dari *Recurrent Neural Network (RNN)* yang dirancang untuk mengatasi masalah *vanishing gradient* yang sering muncul dalam pelatihan jaringan neural berurutan. *RNN* tradisional memiliki kesulitan dalam mengingat informasi dari data urutan panjang karena gradien cenderung menghilang saat proses *backpropagation*. *LSTM* memperkenalkan mekanisme sel memori (*memory cell*) dan gerbang-gerbang pengontrol (*gates*) yang memungkinkan informasi penting dapat dipertahankan atau dibuang secara selektif selama proses pelatihan. Mekanisme ini menjadikan *LSTM* sangat efektif dalam menangkap ketergantungan temporal jangka panjang dalam data *time series*.

Secara matematis, *LSTM* memproses informasi melalui beberapa gerbang utama, dengan persamaan sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (\text{Forget gate})$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (\text{Input gate})$$

$$\underline{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (\text{Candidate cell state})$$

$$C_t = f_t * C_{t-1} + i_t * \underline{C}_t \quad (\text{Cell state update})$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (\text{Output gate})$$

$$h_t = o_t * \tanh(C_t) \quad (\text{Hidden state})$$

Di mana:

x_t adalah input pada waktu t

h_{t-1} adalah *hidden state* dari waktu sebelumnya

C_t adalah *cell state*

σ adalah fungsi aktivasi sigmoid

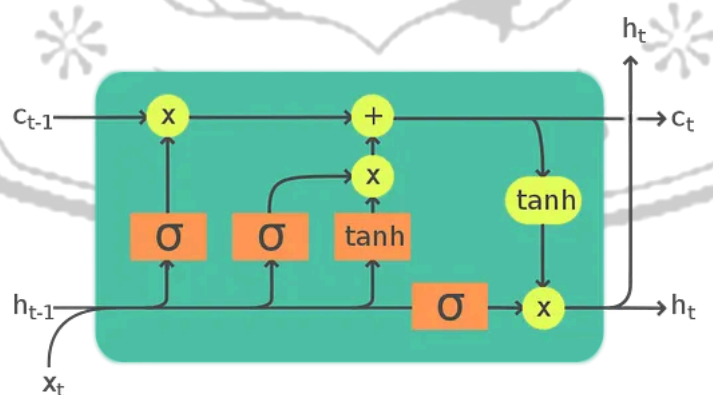
\tanh adalah fungsi aktivasi tanh

W dan b adalah bobot dan bias pada masing-masing gerbang

LSTM banyak digunakan dalam berbagai bidang seperti *pemrosesan bahasa alami*, *pengenalan suara*, dan terutama dalam prediksi deret waktu seperti harga komoditas. Model ini memiliki kemampuan untuk menyesuaikan dengan pola-pola dinamis yang kompleks, menjadikannya sangat relevan untuk diterapkan dalam konteks volatilitas harga minyak mentah (*USOIL*) [3], [5].

2.4.2 Arsitektur LSTM

Arsitektur dasar *LSTM* terdiri dari tiga jenis gerbang (*gate*) utama: *input gate*, *forget gate*, dan *output gate*. *Input gate* menentukan informasi baru mana yang akan disimpan dalam sel memori (*cell state*); *forget gate* mengontrol informasi mana yang harus dibuang dari sel memori; dan *output gate* memutuskan bagian dari informasi dalam sel memori yang akan digunakan sebagai *output*. Sel memori (*cell state*) bertindak sebagai jalur transportasi informasi utama yang memungkinkan informasi mengalir sepanjang waktu tanpa perubahan signifikan, kecuali dimodulasi oleh ketiga gerbang tersebut. Proses ini membuat *LSTM* sangat cocok untuk menangani data urutan yang panjang dan mempertahankan informasi yang relevan sepanjang waktu. Setiap unit *LSTM* memiliki fungsi aktivasi seperti *sigmoid* dan *tanh* yang bertugas memfilter dan mentransformasi informasi dengan tepat. Kombinasi komponen-komponen ini membentuk jaringan yang stabil dan fleksibel, sehingga dapat menangani noise serta perubahan pola yang kompleks dalam data historis harga minyak mentah [6].



Legend:

Layer	Componentwise	Copy	Concatenate
		\updownarrow	\hookrightarrow

Gambar 2.1 *Architecture LSTM*

2.4.3 Kekurangan LSTM dan Keunggulan Stacked LSTM

Meskipun *LSTM* menawarkan keunggulan signifikan dibandingkan *RNN* konvensional, arsitektur dasar *LSTM* yang hanya terdiri dari satu lapisan tersembunyi memiliki keterbatasan dalam mempelajari fitur hierarkis dari data sekuensial yang kompleks. Pada kasus data *time series* seperti harga minyak yang mengandung banyak faktor non-linier dan hubungan jangka panjang yang dalam, model *LSTM* standar sering kali tidak cukup untuk menangkap semua kompleksitas tersebut. Untuk mengatasi keterbatasan ini, dikembangkanlah model *stacked LSTM*, yaitu struktur jaringan yang menggabungkan beberapa lapisan *LSTM* secara bertingkat. *Stacked LSTM* memungkinkan jaringan untuk mempelajari representasi fitur yang lebih abstrak dan kompleks dari data urutan, karena lapisan yang lebih tinggi dapat mengekstraksi pola-pola yang lebih dalam dari keluaran lapisan sebelumnya. Dengan demikian, *stacked LSTM* memberikan kemampuan prediksi yang lebih baik dan akurat dalam konteks fluktuasi pasar minyak [7], [1].

2.4.4 Penjelasan tentang Konsep Stacked LSTM (Multiple LSTM Layers)

Stacked LSTM adalah pengembangan dari arsitektur *LSTM* standar di mana beberapa lapisan *LSTM* disusun secara vertikal. Output dari satu lapisan *LSTM* digunakan sebagai input untuk lapisan berikutnya, sehingga jaringan dapat membangun pemahaman yang lebih dalam terhadap struktur temporal data. Lapisan bawah bertugas menangkap pola lokal atau hubungan temporal jangka pendek, sedangkan lapisan atas menyusun dan menyimpulkan informasi global dari pola-pola yang telah diekstraksi sebelumnya. Dalam implementasinya, *stacked LSTM* sering digunakan untuk data yang kompleks dan berisik seperti data finansial, karena memiliki kemampuan untuk mengurangi *overfitting* serta meningkatkan kapasitas generalisasi model.

Secara matematis, struktur *stacked LSTM* dapat direpresentasikan sebagai berikut [3], [6], [9]:

$$\begin{aligned}h_t^{(1)} &= LSTM^{(1)}\left(x_t, h_{t-1}^{(1)}, C_{t-1}^{(1)}\right) \\h_t^{(2)} &= LSTM^{(2)}\left(h_t^{(1)}, h_{t-1}^{(2)}, C_{t-1}^{(2)}\right) \\&\downarrow \\h_t^{(L)} &= LSTM^{(L)}\left(h_t^{(L-1)}, h_{t-1}^{(L)}, C_{t-1}^{(L)}\right)\end{aligned}$$

Di mana:

L adalah jumlah lapisan LSTM,

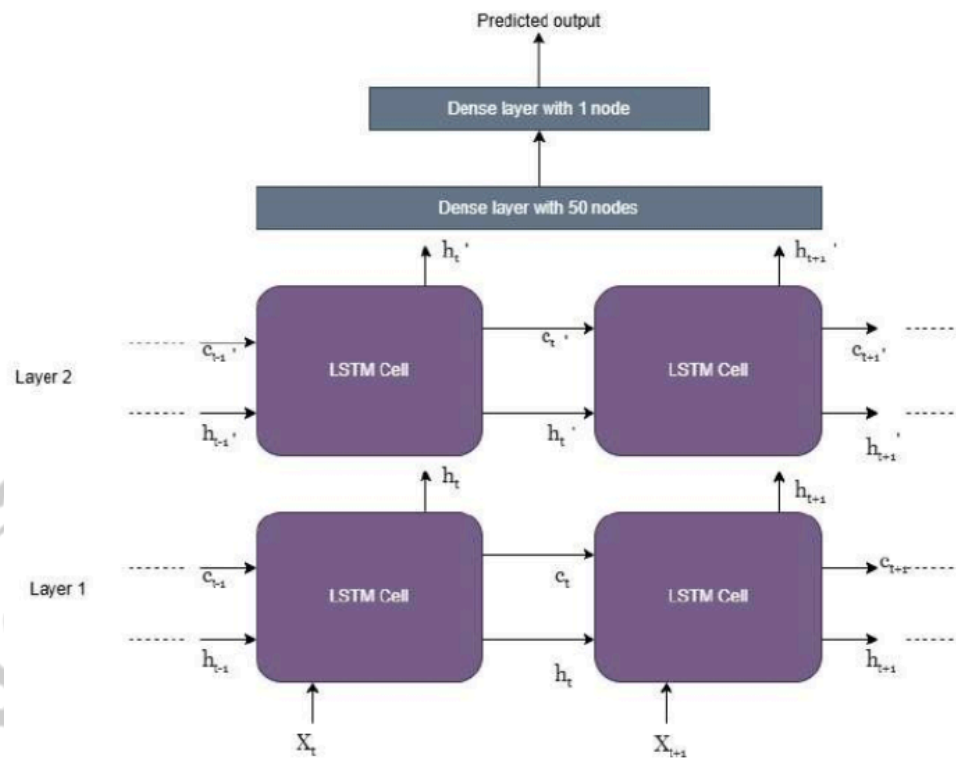
$h_t^{(l)}$ dan $C_t^{(l)}$ masing-masing adalah *hidden state* dan *cell state* dari lapisan ke- l ,

Output dari lapisan ke- l menjadi input untuk lapisan ke- $l + 1$,

Penelitian terbaru oleh Raut [1] menunjukkan bahwa *stacked LSTM* memberikan hasil prediksi yang lebih akurat dibandingkan *LSTM* tunggal dalam konteks prediksi harga energi, terutama dalam mengantisipasi lonjakan harga mendadak yang tidak dapat ditangkap oleh model yang lebih dangkal. Selain itu, studi oleh Chen et al. [3] dan Wang & Wang [6] juga menegaskan bahwa arsitektur bertingkat ini secara signifikan meningkatkan akurasi dalam prediksi harga minyak dan saham. Oleh karena itu, penggunaan *stacked LSTM* menjadi pilihan yang logis dalam pengembangan sistem prediksi harga USOIL berbasis data historis.

2.4.5 Keunggulan Stacked LSTM dalam Menangkap Pola Kompleks pada Data Time Series

Keunggulan utama dari *stacked LSTM* terletak pada kemampuannya dalam membangun representasi fitur secara *hierarkis*. Lapisan-lapisan tambahan dalam jaringan memungkinkan model mempelajari relasi *temporal* yang lebih dalam dan kompleks, seperti siklus ekonomi, efek musiman, serta respons pasar terhadap peristiwa tertentu. *Stacked LSTM* juga menunjukkan ketahanan terhadap *noise* dalam data serta ketepatan dalam mendeteksi *turning point* dalam deret waktu harga. Selain itu, model ini lebih fleksibel dalam menangani *dataset* besar dengan dimensi *input* yang bervariasi. Studi oleh Raut [1] dan Wang & Wang [6] menunjukkan bahwa *stacked LSTM* mampu mengurangi *error* prediksi seperti *RMSE* dan *MAE* secara signifikan, dibandingkan metode seperti *ARIMA* dan *SVR*. Oleh karena itu, *stacked LSTM* sangat cocok digunakan dalam penelitian ini yang bertujuan untuk membangun sistem prediksi harga USOIL yang akurat, adaptif, dan berbasis pada data historis pasar.



Gambar 2.2 *Architecture Stacked LSTM*[23]

2.5 Evaluasi Model

Evaluasi model merupakan tahap krusial dalam proses pembangunan sistem prediksi, khususnya pada konteks pemodelan deret waktu seperti prediksi harga minyak mentah (USOIL). Tahapan ini bertujuan untuk menilai seberapa baik model yang dikembangkan mampu menangkap pola historis dan memproyeksikan data masa depan secara akurat. Dalam penelitian ini, evaluasi dilakukan untuk mengukur kinerja model *stacked LSTM* dalam menghasilkan prediksi harga yang mendekati nilai aktual. Proses evaluasi model tidak hanya penting untuk mengetahui tingkat kesalahan prediksi, tetapi juga untuk membandingkan efektivitas model dibandingkan pendekatan lain atau konfigurasi berbeda dalam arsitektur model. Oleh karena itu, pemilihan metrik evaluasi harus relevan, terukur, dan sesuai dengan karakteristik data serta tujuan penelitian [3], [5].

Beberapa metrik yang umum digunakan dalam evaluasi model prediksi *time series* meliputi **Mean Absolute Error (MAE)**, **R-squared (R²)** dan **Root Mean Squared Error (RMSE)**. MAE mengukur rata-rata besar kesalahan absolut antara nilai aktual dan hasil prediksi tanpa mempertimbangkan arah kesalahan. Metrik ini memberikan gambaran umum mengenai deviasi prediksi

terhadap data sebenarnya, dan bersifat lebih tahan terhadap *outlier*. Rumus MAE dapat dituliskan sebagai berikut:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |\gamma_t - \hat{\gamma}_t|$$

Sementara itu, R^2 Mengukur seberapa baik model menjelaskan variabilitas data. Nilai berkisar 0 hingga 1. Rumus R^2 adalah:

$$R^2 = 1 - \frac{\sum_{n=1}^n (\gamma_t - \hat{\gamma}_t)^2}{\sum_{n=1}^n (\gamma_t - \bar{\gamma}_t)^2}$$

MSE sangat berguna dalam mendeteksi model yang sering melakukan kesalahan prediksi besar. RMSE, sebagai akar dari MSE, menyajikan hasil dalam satuan yang sama dengan data asli dan lebih sensitif terhadap *error* besar, sehingga sangat cocok digunakan dalam mengukur akurasi prediksi harga pasar seperti USOIL. Rumus RMSE adalah:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\gamma_t - \hat{\gamma}_t)^2}$$

Selain ketiga metrik tersebut, metrik tambahan seperti **Mean Absolute Percentage Error (MAPE)** juga dapat digunakan untuk menilai tingkat kesalahan relatif dalam bentuk persentase. Namun, MAPE memiliki kelemahan ketika nilai aktual mendekati nol, karena dapat menghasilkan nilai *error* yang ekstrem atau tidak terdefinisi [10]. Dalam konteks data harga minyak mentah yang memiliki fluktuasi tajam namun jarang bernilai nol, MAPE masih dapat digunakan dengan hati-hati. Pemilihan kombinasi metrik ini penting agar evaluasi kinerja model tidak bersifat bias terhadap satu jenis kesalahan tertentu, dan memberikan gambaran yang lebih holistik tentang performa model prediksi [3], [7].

Dalam penelitian ini, metrik utama yang digunakan adalah RMSE dan MAE, karena keduanya memberikan ukuran kesalahan yang realistis dan sering digunakan dalam studi sebelumnya sebagai standar evaluasi model *time series*. Studi oleh Wang & Wang [6], Xiao [9], dan Chen et al. [3] juga menggunakan metrik yang sama dalam mengevaluasi model LSTM dan *stacked LSTM* untuk prediksi pasar energi dan saham. Dengan menggunakan metrik ini, hasil evaluasi model dapat dibandingkan secara langsung dengan penelitian terdahulu serta memberikan validasi terhadap efektivitas model yang dibangun dalam konteks harga USOIL.

Secara umum, proses evaluasi model ini juga mencakup proses validasi menggunakan *data uji (testing data)* yang sebelumnya tidak digunakan dalam pelatihan model. Hal ini bertujuan untuk menghindari *overfitting* dan memastikan bahwa model memiliki kemampuan generalisasi yang baik [2], [13]. Teknik validasi umum yang digunakan dalam *time series* adalah *train-test split* berdasarkan waktu, bukan secara acak, agar ketergantungan temporal antar data tetap terjaga. Selain itu, visualisasi hasil prediksi terhadap data aktual melalui grafik juga menjadi bagian dari evaluasi kualitatif untuk melihat apakah pola pergerakan harga berhasil ditangkap model secara keseluruhan [5], [7].

Dengan menerapkan proses evaluasi model yang sistematis dan berbasis pada metrik yang relevan, penelitian ini bertujuan untuk menghasilkan model *stacked LSTM* yang tidak hanya akurat secara numerik, tetapi juga andal secara praktis dalam memprediksi pergerakan harga USOIL di masa mendatang. Evaluasi ini menjadi dasar untuk menyimpulkan apakah model yang dikembangkan mampu memenuhi tujuan penelitian serta memberikan kontribusi signifikan dalam bidang prediksi *time series* berbasis *deep learning*.

