

**PENERAPAN METODE *LONG SHORT TERM MEMORY* (LSTM) PADA  
PREDIKSI HARGA MINYAK DUNIA**

**Skripsi**

**Oleh**

**AINI RAHMAWATI  
NPM. 2217031119**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG**

**2026**

## **ABSTRACT**

### **IMPLEMENTATION OF THE LONG SHORT TERM MEMORY (LSTM) METHOD IN FORECASTING GLOBAL CRUDE OIL PRICES**

By

**Aini Rahmawati**

Long Short Term Memory (LSTM) is a deep learning method widely used for time series prediction due to its ability to capture nonlinear patterns and long term dependencies. This method is an extension of the Recurrent Neural Network (RNN), designed to address the vanishing gradient problem through memory cell and gate mechanisms, making it effective in modeling complex and dynamic data. In this study, the LSTM method was applied to predict global oil prices, which exhibit fluctuating behavior and are influenced by various economic and geopolitical factors. The model was developed through several stages, including data preprocessing, such as normalization and transformation into supervised time series data, as well as data splitting using the Time Series Cross Validation method. To achieve optimal model performance, hyperparameter tuning was conducted using the Grid Search method. The model performance was then evaluated using Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE) metrics. The results indicate that the LSTM model with optimal parameters is capable of producing a low prediction error, with an average RMSE of 2.90 and MAPE of 2.77%.

**Keywords:** Time Series, Deep Learning, LSTM, Oil Prices, Prediction, Hyperparameter Tuning, Grid Search.

## ABSTRAK

### PENERAPAN METODE *LONG SHORT TERM MEMORY* (LSTM) PADA PREDIKSI HARGA MINYAK DUNIA

Oleh

**Aini Rahmawati**

*Long Short Term Memory* (LSTM) merupakan salah satu metode *deep learning* yang banyak digunakan dalam prediksi data deret waktu karena kemampuannya dalam menangkap pola nonlinear serta ketergantungan jangka panjang. Metode ini merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* melalui mekanisme *memory cell* dan *gate*, sehingga efektif dalam memodelkan data yang bersifat kompleks dan dinamis. Dalam penelitian ini, metode LSTM diterapkan untuk memprediksi harga minyak dunia yang memiliki pergerakan fluktuatif dan dipengaruhi oleh berbagai faktor ekonomi serta kondisi geopolitik. Model dibangun melalui tahapan pra-pemrosesan data, termasuk normalisasi dan pembentukan data *time series supervised learning*, serta pembagian data menggunakan metode *Time Series Cross Validation*. Untuk memperoleh performa model yang optimal, dilakukan proses *hyperparameter tuning* menggunakan metode *Grid Search*. Kinerja model kemudian dievaluasi menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa model LSTM dengan parameter optimal mampu menghasilkan tingkat kesalahan yang rendah, dengan nilai rata-rata RMSE sebesar 2,90 dan MAPE sebesar 2,77%.

**Kata-kata kunci:** *Time Series, Deep Learning, LSTM, Harga Minyak, Prediksi, Hyperparameter Tuning, Grid Search*

**PENERAPAN METODE *LONG SHORT TERM MEMORY* (LSTM) PADA  
PREDIKSI HARGA MINYAK DUNIA**

**AINI RAHMAWATI**

**Skripsi**

Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG**

**2026**


Judul Skripsi : **PENERAPAN METODE *LONG SHORT TERM MEMORY* (LSTM) PADA PREDIKSI HARGA MINYAK DUNIA**

Nama Mahasiswa : **Aini Rahmawati**

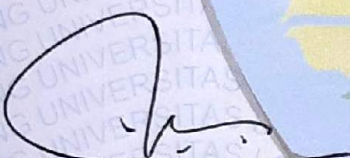
Nomor Pokok Mahasiswa : **2217031119**

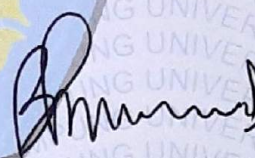
Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

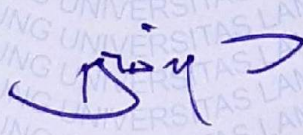


1. Komisi Pembimbing

  
**Dr. Subian Saidi, S.Si., M.Si.**  
NIP 198008212008121001

  
**Dr. Bernadhita H. S. U, S.Si., M.Sc**  
NIP 199206302023212034

2. Wakil Dekan Bidang Akademik dan Kerjasama  
FMIPA Universitas Lampung

  
**Mulyono, S.Si., M.Si., Ph.D.**  
NIP. 197406112000031002

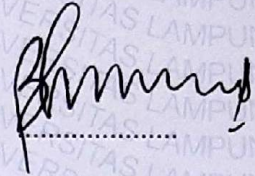
**MENGENSAHKAN**

**1. Tim Penguji**

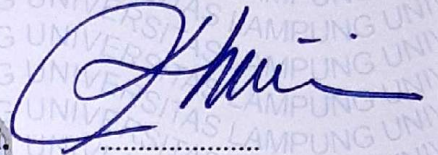
**Ketua : Dr. Subian Saidi, S.Si., M.Si.**



**Sekretaris : Dr. Bernadhita H. S. U, S.Si., M.Sc**



**Penguji  
Bukan Pembimbing : Dr. Khoirin Nisa, S.Si., M.Si.**



**2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**



**Dr. Eng. Heri Satria, S.Si., M.Si.**

**NIP. 197110012005011002**

**Tanggal Lulus Ujian Skripsi: 30 April 2026**

## PERNYATAAN SKRIPSI MAHASISWA

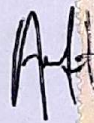
Yang bertanda tangan di bawah ini:

Nama : **Aini Rahmawati**  
Nomor Pokok Mahasiswa : **2217031119**  
Jurusan : **Matematika**  
Judul Skripsi : **Penerapan Metode *Long Short Term Memory* (LSTM) Pada Prediksi Harga Minyak Dunia**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 4 Mei 2026

Penulis,



Aini Rahmawati

## **RIWAYAT HIDUP**

Penulis memiliki nama lengkap Aini Rahmawati lahir di Bandar Lampung pada tanggal 18 Desember 2004. Sebagai anak ketiga dari lima bersaudara oleh pasangan Bapak Eko Sunu Sutrisno, S.E. dan Ibu Agus Sriyanti, S.Pd.

Penulis menempuh pendidikan di TK Transmigrasi pada tahun 2009-2010, Sekolah Dasar (SDN) 03 Labuhan Ratu pada tahun 2010-2016, Sekolah Menengah Pertama (SMPN) 8 Bandar Lampung pada tahun 2016-2019, Sekolah Menengah Atas (SMA) Muhammadiyah 2 pada tahun 2019-2022.

Pada tahun 2022, penulis terdaftar sebagai Mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis pernah mengikuti kegiatan kepanitiaan menjadi Anggota Divisi Sponsor dan Keamanan dan juga Divisi Kreatif pada DINAMIKA XXIV dan DINAMIKA XXV.

Pada tahun 2024 penulis melaksanakan Kerja Praktek (KP) di Kantor UPTD Pengelola Pendapatan Wilayah 1 Bandar Lampung selama 40 hari dari bulan Desember hingga Januari. Pada tahun 2025 Penulis melaksanakan Kuliah Kerja Nyata (KKN) selama 40 hari dari bulan Juli hingga Agustus di Kelurahan Rajabasa Jaya, Kecamatan Rajabasa, Kota Bandar Lampung, Provinsi Lampung.

## **KATA INSPIRASI**

”Allah tidak akan membebani hamba-Nya melainkan sesuai kemampuannya”  
— QS. Al Baqarah: 286

”Dan bersabarlah kamu, sesungguhnya janji Allah adalah benar”  
— QS. Ar Rum: 60

## **PERSEMBAHAN**

Dengan mengucapkan Alhamdulillah dan bersyukur kepada Allah SWT atas karunia dan petunjuk-Nya, sehingga tugas akhir ini dapat diselesaikan dengan baik dan sesuai waktunya. Dengan penuh rasa syukur dan kebahagiaan, saya ucapkan terimakasih kepada:

### **Bapak dan Ibuku Tercinta**

Terimakasih kepada orang tuaku atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Aku menghargai semua pelajaran berharga yang telah diajarkan kepadaku mengenai arti sejati dari perjalanan kehidupan, agar suatu saat bisa menjadi individu yang berguna bagi banyak orang.

### **Almamater Tercinta**

Universitas Lampung

## SANWACANA

Puji syukur ke hadirat Allah SWT, atas segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi dengan judul “Penerapan Metode *Long Short Term Memory* (LSTM) Pada Prediksi Harga Minyak Dunia”. Skripsi ini disusun sebagai salah satu syarat untuk mendapatkan gelar Sarjana Matematika pada Jurusan Matematika FMIPA Unila.

Dalam menyelesaikan skripsi ini, penulis mendapat dukungan, bimbingan dan bantuan dari beberapa pihak sehingga skripsi ini dapat terselesaikan. Oleh karena itu, penulis ingin menyampaikan terima kasih sebanyak-banyaknya kepada :

1. Bapak Dr. Subian Saidi, S.Si., M.Si. selaku dosen Pembimbing I yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Bernadhita Herindri Samodera Utami, S.Si., M.Sc., selaku dosen pembimbing II yang senantiasa memberikan arahan, bantuan, dan saran kepada penulis dalam menyusun skripsi ini.
3. Ibu Dr. Khoirin Nisa, S.Si., M.Si. selaku dosen Pembahas yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Ibu Dr. Notiragayu, S.Si., M.Si. selaku dosen pembimbing akademik.
6. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Orang tuaku tercinta, Bapak dan Ibu yang senantiasa tidak lelah untuk mendo'akan penulis, selalu memberi motivasi dan selalu mengajarkan penulis untuk bersyukur setiap harinya. Semoga penulis dapat memberikan kebahagiaan dan selalu menjadi anak kebanggaan Bapak dan Ibu.
8. Untuk keluarga besarku, Eyang, Om, Tante, Mas Bagus, Mba Dinda, Annisa dan Fatih selalu menyemangati dan menghibur di kala penulis sedang kesulitan
9. Sahabat perjuanganku sejak awal hingga sekarang, Widya Febriyana, Anggun Dwi Maharani, Aurelia Daffa Raihan Mariyam, Fika Nazma Khoiriah, Katarina Vani Wulandari, Leony Putri Kinanti, M. Farhan Aboeruslan Mulyadi, dan teman-teman KKN Rajabasa Jaya yang telah memberi semangat dan dukungan kepada penulis selama masa perkuliahan.
10. Teman-teman seperjuangan Jurusan Matematika angkatan 2022.
11. Seluruh pihak terkait yang membantu dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari laporan ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan baik dalam penyajian maupun teknik penulisan. Oleh sebab itu, saran dan kritikan yang membangun senantiasa penulis harapkan dari seluru pihak. Penulis berharap skripsi ini bermanfaat oleh pembaca dan penulis sendiri.

Bandar Lampung, 30 April 2026

Aini Rahmawati

## DAFTAR ISI

<b>DAFTAR ISI</b> . . . . .	<b>xiii</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xiv</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xiv</b>
<b>I PENDAHULUAN</b> . . . . .	<b>1</b>
1.1 Latar Belakang Masalah . . . . .	1
1.2 Tujuan Penelitian . . . . .	3
1.3 Manfaat Penelitian . . . . .	3
<b>II TINJAUAN PUSTAKA</b> . . . . .	<b>4</b>
2.1 Data Deret Waktu . . . . .	4
2.1.1 Pola Data Deret Waktu . . . . .	4
2.2 Prediksi . . . . .	6
2.3 <i>Machine Learning</i> . . . . .	6
2.4 <i>Deep Learning</i> . . . . .	7
2.5 <i>Recurrent Neural Network</i> (RNN) . . . . .	8
2.6 <i>Long Short Term Memory</i> (LSTM) . . . . .	9
2.7 <i>Hyperparameter Tuning</i> . . . . .	15
2.8 Validasi Model . . . . .	16
2.8.1 <i>Cross Validation</i> . . . . .	16
2.8.2 <i>Time Series Cross Validation</i> . . . . .	17
2.9 Evaluasi Model . . . . .	17
2.10 Minyak . . . . .	18
<b>III METODE PENELITIAN</b> . . . . .	<b>20</b>
3.1 Waktu dan Tempat Penelitian . . . . .	20
3.2 Data Penelitian . . . . .	20
3.3 Metode Penelitian . . . . .	20
<b>IV HASIL DAN PEMBAHASAN</b> . . . . .	<b>24</b>
4.1 Analisis Deskriptif . . . . .	24
4.2 Pra-pemrosesan Data . . . . .	26
4.2.1 Pemilihan Kolom Penting . . . . .	26

4.2.2	Pengecekan <i>Missing Value</i> . . . . .	26
4.2.3	Normalisasi Data . . . . .	27
4.3	Pembagian Data Menggunakan <i>Time Series Split</i> . . . . .	28
4.4	<i>Hyperparameter Tuning</i> . . . . .	30
4.5	Hasil Pelatihan Model LSTM . . . . .	32
4.6	Hasil Evaluasi Model . . . . .	36
4.7	Pelatihan Model Ulang . . . . .	38
4.8	Hasil Analisis . . . . .	38
<b>V</b>	<b>PENUTUP</b> . . . . .	<b>41</b>
5.1	Kesimpulan . . . . .	41
	<b>DAFTAR PUSTAKA</b> . . . . .	<b>42</b>

## DAFTAR TABEL

1.	Karakteristik Data . . . . .	24
2.	Hasil <i>Missing Value</i> . . . . .	27
3.	Hasil Proses Normalisasi . . . . .	28
4.	Pembagian Data <i>Training</i> dan Data <i>Testing</i> . . . . .	29
5.	<i>Hyperparameter Tuning</i> . . . . .	31
6.	Arsitektur Model LSTM . . . . .	32
7.	Hasil K-Fold . . . . .	37
8.	Prediksi Harga Minyak Dunia dari Model LSTM . . . . .	39

## DAFTAR GAMBAR

1.	Pola Data Deret Waktu . . . . .	5
2.	Arsitektur LSTM . . . . .	9
3.	<i>Forget Gate</i> struktur LSTM . . . . .	11
4.	<i>Input Gate</i> struktur LSTM . . . . .	12
5.	<i>Output Gate</i> struktur LSTM . . . . .	14
6.	Diagram Alir Metode LSTM . . . . .	23
7.	Visualisasi Data Historis Harga Minyak Dunia . . . . .	25
8.	Visualisasi Prediksi 60 Hari . . . . .	39

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Prediksi merupakan proses memperkirakan hasil yang belum diketahui di masa depan dengan memanfaatkan informasi yang dipelajari dari data yang tersedia (Benidis *et al.*, 2020). Tujuan utama dari prediksi adalah untuk membantu pengambilan keputusan yang lebih akurat dengan mempertimbangkan informasi masa lalu sebagai dasar proyeksi (Makridakis *et al.*, 2019). Dalam bidang ekonomi dan energi, kemampuan untuk memprediksi dengan akurat menjadi hal yang sangat penting karena hasilnya bisa membantu dalam pengambilan keputusan strategis, seperti menentukan kebijakan harga, perencanaan produksi, atau investasi.

Data yang digunakan dalam proses prediksi biasanya dilakukan dengan menganalisis data deret waktu (*time series*), yaitu data yang dikumpulkan secara berurutan berdasarkan waktu. Pola pada data deret waktu sering kali bersifat nonlinear dan kompleks, sehingga metode prediksi tradisional seperti ARIMA (*Autoregressive Integrated Moving Average*) atau regresi linear tidak selalu mampu menangkap hubungan antar waktu dengan baik (Hyndman & Athanasopoulos, 2018). Oleh karena itu, pendekatan berbasis *machine learning* dan *deep learning* mulai banyak digunakan untuk meningkatkan akurasi prediksi data deret waktu (*time series*). Salah satu metode yang sering digunakan dalam analisis deret waktu adalah *Long Short Term Memory* (LSTM).

Metode *Long Short-Term Memory* pertama kali diperkenalkan oleh (Hochreiter & Schmidhuber, 1997) sebagai pengembangan dari *Recurrent Neural Network* (RNN) yang memiliki kemampuan untuk mengingat informasi jangka panjang. LSTM bekerja dengan menggunakan struktur khusus yang disebut *memory cell* yang terdiri dari tiga gerbang utama, yaitu *input gate*, *forget gate*, dan *output gate*. Ketiga komponen tersebut memungkinkan jaringan untuk mempertahankan

informasi penting dari data sebelumnya dan melupakan informasi yang tidak relevan. Hal ini membuat LSTM sangat efektif dalam mempelajari hubungan temporal pada data deret waktu yang panjang (Goodfellow *et al.*, 2016).

Struktur tersebut memberikan LSTM kemampuan untuk mengenali pola nonlinear yang kompleks serta memahami keterkaitan jangka panjang antar data. Dengan mekanisme kerja yang lebih mendalam dibandingkan model RNN konvensional, LSTM mampu menghasilkan prediksi yang lebih stabil dan akurat (Brownlee, 2020). Namun, dalam penerapannya, model ini memerlukan jumlah data yang cukup besar dan waktu pelatihan yang lebih lama agar dapat mempelajari pola dengan optimal. Selain itu, penentuan parameter seperti jumlah *neuron*, *learning rate*, dan jumlah *epoch* perlu dilakukan dengan baik untuk menghindari risiko *overfitting* dan menjaga kinerja model tetap efisien (Fischer & Krauss, 2018).

Beberapa penelitian yang pernah dilakukan sebelumnya menggunakan model LSTM oleh (Rifqi Muhammad & Ida Nurhaida, 2025) membuktikan bahwa LSTM mampu menghasilkan prediksi harga kopi dengan tingkat *error* yang rendah. Penelitian oleh (Zhang & Wang, 2021) melakukan perbandingan antara model LSTM dan *Gated Recurrent Unit* (GRU) dan menemukan bahwa LSTM lebih unggul dalam mengenali fluktuasi harga yang tajam. Penelitian lain oleh (Rahman *et al.*, 2022) menggabungkan ARIMA dan LSTM menjadi model *hybrid* ARIMA–LSTM, dan hasilnya menunjukkan peningkatan akurasi prediksi yang signifikan. Selain itu, (Jiao *et al.*, 2023) menerapkan model LSTM untuk peramalan harga energi jangka panjang dan menemukan bahwa LSTM dapat menyesuaikan diri terhadap tren dan pola musiman dengan baik, bahkan ketika data menunjukkan tingkat volatilitas yang tinggi. Hasil-hasil tersebut memperkuat bukti bahwa LSTM memang cocok digunakan untuk memprediksi data yang bersifat kompleks dan berubah-ubah secara dinamis.

Minyak mentah atau *crude oil* merupakan salah satu sumber daya yang sangat penting, dikarenakan hasil olahan minyak mentah merupakan sumber energi utama dalam berbagai sektor. Kebutuhan masyarakat terhadap minyak untuk kebutuhan sehari-hari cenderung meningkat. Hal tersebut menyebabkan kapasitas minyak semakin hari semakin berkurang. Apabila konsumsi terhadap minyak terus mengalami peningkatan tanpa diimbangi dengan ketersediaan minyak yang ada maka berpotensi menimbulkan kelangkaan sumber daya minyak. Ketidakseimbangan antara produksi dan konsumsi minyak dapat memicu kenaikan harga minyak yang

berfluktuatif (Fauzanissa *et al.*, 2016). Prediksi harga minyak memberikan gambaran mengenai keadaan ketersediaan minyak pada dinamika energi di masa mendatang. Selain itu, informasi harga minyak harus diketahui secara spesifik karena memiliki dampak signifikan terhadap stabilitas dan aktivitas perekonomian.

Berdasarkan latar belakang tersebut, pada penelitian ini akan melakukan prediksi harga minyak dunia melalui penerapan metode *Long Short Term Memory* (LSTM), yang diharapkan dapat memberikan hasil prediksi yang lebih akurat guna membantu pengambilan keputusan dalam menghadapi dinamika pasar minyak global.

## **1.2 Tujuan Penelitian**

Adapun tujuan yang ingin dicapai pada penelitian ini adalah :

1. Menerapkan metode *Long Short Term Memory* (LSTM) untuk memprediksi harga minyak dunia;
2. Menganalisis performa model *Long Short Term Memory* (LSTM) menggunakan metrik evaluasi RMSE dan MAPE.

## **1.3 Manfaat Penelitian**

Adapun manfaat yang dapat diambil dari penelitian ini adalah :

1. Sebagai bahan rujukan dalam pengembangan ilmu matematika, khususnya pada analisis metode *Long Short Term Memory* (LSTM);
2. Dapat menjadi bahan pertimbangan serta informasi tambahan bagi pembaca apabila ingin melakukan penelitian lanjutan berdasarkan hasil analisis yang diperoleh.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Data Deret Waktu**

Data deret waktu merupakan analisis peramalan atau prediksi menggunakan hubungan antar variabel yang diperkirakan dengan deret waktu. Data deret waktu mencerminkan dinamika temporal dari berbagai fenomena, seperti harga minyak dunia harian, nilai tukar rupiah bulanan, atau pendapatan nasional tahunan. Analisis deret waktu memungkinkan identifikasi tren jangka panjang, pola musiman, dan fluktuasi acak dalam data, yang penting untuk prediksi dan pengambilan keputusan di berbagai bidang seperti keuangan, meteorologi, dan epidemiologi (Le-Hang Le, 2024).

##### **2.1.1 Pola Data Deret Waktu**

Pemilih metode pada peramalan yang tepat bergantung pada jenis pola data yang dianalisis, sehingga metode peramalan yang paling sesuai dengan pola data tersebut dapat diterapkan. Secara umum pola data dapat diklasifikasikan menjadi empat jenis utama, yaitu horizontal, musiman, siklis, dan tren dengan masing-masing memiliki karakteristik berbeda (Aden, 2020). Berikut adalah pola data deret waktu:

##### **a. Horizontal**

Pola horizontal ditandai dengan pergerakan data yang relatif stabil di sekitar nilai rata-rata, meskipun tetap terdapat fluktuasi kecil. Pola ini biasanya muncul pada data yang tidak menunjukkan kecenderungan naik atau turun dalam jangka panjang. Contohnya pada data penjualan produk yang tidak meningkat dan menurun selama waktu tertentu (Aden, 2020).

b. Musiman

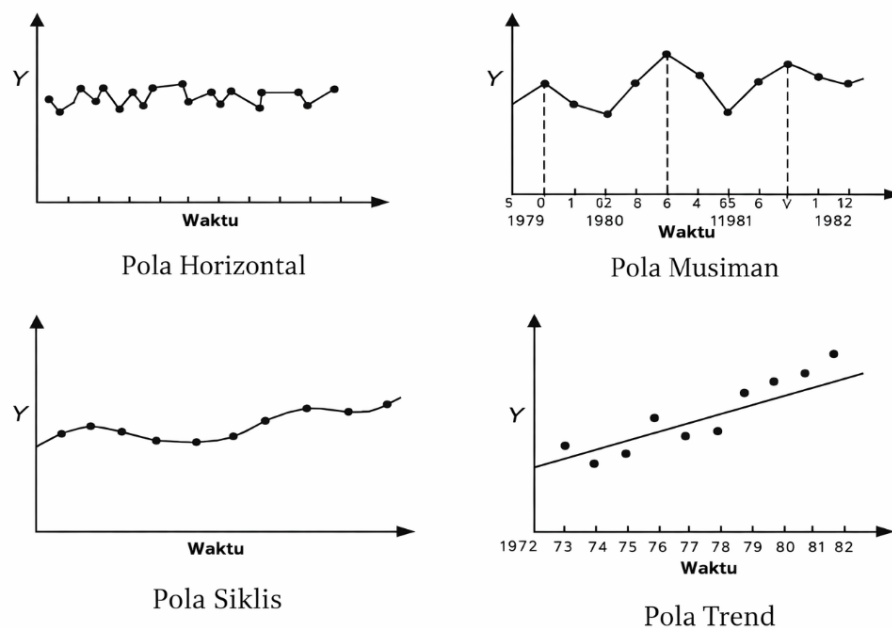
Pola musiman terjadi ketika data memperlihatkan perulangan yang teratur dalam periode tertentu, misalnya harian, bulanan, atau tahunan. Variasi ini umumnya dipengaruhi oleh faktor musiman yang bersifat periodik (Aden, 2020).

c. Siklis

Pola data siklis dipengaruhi oleh fluktuasi dalam jangka panjang yang tidak memiliki periode tetap. Pola ini sering dikaitkan dengan dinamika ekonomi atau perubahan struktural yang berlangsung selama beberapa tahun (Aden, 2020).

d. Tren

Pola data tren merupakan kenaikan atau penurunan data yang terjadi dalam waktu secara bertahap dalam periode waktu yang panjang (Aden, 2020).



Gambar 1. Pola Data Deret Waktu

Berdasarkan Gambar 1, terlihat bahwa data deret waktu dapat memiliki berbagai bentuk pola, yaitu horizontal, musiman, siklis, dan tren. Identifikasi pola ini penting dilakukan sebelum melakukan peramalan karena setiap pola memerlukan metode analisis yang berbeda agar hasil prediksi yang diperoleh lebih optimal.

## 2.2 Prediksi

Prediksi merupakan proses memperkirakan hasil yang belum diketahui di masa depan dengan memanfaatkan informasi yang dipelajari dari data yang tersedia (Benidis *et al.*, 2020). Dalam praktiknya, prediksi tidak dimaksudkan untuk menghasilkan nilai yang sepenuhnya pasti, melainkan memberikan estimasi yang sedekat mungkin dengan realisasi aktual (Herjanto, 2006). Prediksi bertujuan untuk mengidentifikasi pola-pola yang bersifat sistematis serta memahami kecenderungan hubungan yang terbentuk dari data masa lalu. Dalam proses tersebut, pengumpulan data historis menjadi tahap awal yang sangat penting karena berfungsi sebagai dasar utama dalam membangun model prediksi (Makridakis *et al.*, 2006).

## 2.3 *Machine Learning*

*Machine learning* atau pembelajaran mesin merupakan cabang ilmu dari kecerdasan buatan (*artificial intelligence*), yang berfokus pengembangan sistem agar komputer mampu belajar secara otomatis dari data. Melalui pendekatan ini, komputer dapat meningkatkan kemampuan analisisnya berdasarkan pengalaman tanpa perlu diprogram secara rinci seperti aturan konvensional (Kusuma, 2020). *Machine learning* memberikan kemampuan kepada sistem komputer untuk mempelajari pola dari kumpulan data secara langsung, sehingga model yang terbentuk dapat menjalankan pemetaan antara *input* dan *output* secara otomatis tanpa memerlukan aturan yang diprogram secara eksplisit.

Secara umum, metode *machine learning* dapat diklasifikasikan ke dalam tiga kategori utama, yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning* (Bishop, 2006). Pada *supervised learning*, model dilatih menggunakan data berlabel, *unsupervised learning* digunakan untuk menemukan pola tersembunyi pada data tanpa label dan *reinforcement learning* melibatkan proses pembelajaran melalui interaksi dengan lingkungan dengan tujuan memaksimalkan suatu *reward*.

Dalam konteks data runtun waktu (*time series*), *machine learning* banyak digunakan untuk peramalan karena kemampuannya dalam menangkap pola nonlinear dan dependensi jangka panjang pada data (Hochreiter & Schmidhuber, 1997). Oleh karena itu, pendekatan *machine learning* menjadi alternatif yang efektif

dibandingkan metode statistik konvensional, terutama ketika data bersifat kompleks dan dinamis.

## **2.4 Deep Learning**

*Deep Learning* merupakan cabang dari *machine learning* yang berfokus pada penggunaan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan tersembunyi (*hidden layers*) untuk memproses data dalam skala besar dan kompleks. Pendekatan *deep learning* telah menjadi metode yang menonjol dalam analisis deret waktu (*time series*), salah satu arsitektur *deep learning* yang sering digunakan yaitu *Recurrent Neural Network* (RNN). RNN dirancang untuk memproses data sekuensial dengan memanfaatkan informasi dari langkah waktu sebelumnya sehingga model dapat memahami ketergantungan antar waktu dalam suatu data. Struktur ini memungkinkan RNN untuk menangkap pola temporal yang muncul dalam data deret waktu, seperti tren atau fluktuasi yang terjadi dari waktu ke waktu.

Namun, RNN memiliki keterbatasan dalam mempertahankan informasi jangka panjang akibat permasalahan *vanishing gradient*, yang dapat menyebabkan informasi dari waktu sebelumnya sulit dipertahankan dalam proses pelatihan. Untuk mengatasi keterbatasan tersebut, dikembangkan beberapa varian dari RNN berupa *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Model-model ini dirancang untuk menangani data sekuensial serta memiliki kemampuan mempertahankan informasi dalam rentang waktu yang panjang, yang berperan dalam memahami pola pergerakan harga minyak yang kompleks dan dinamis (Karim & Ahmed, 2021).

Oleh karena itu, pendekatan *deep learning* banyak diterapkan dalam peramalan deret waktu, terutama pada data yang memiliki dinamika tinggi dan fluktuasi yang kompleks, seperti data ekonomi, keuangan, dan harga komoditas. Dengan memanfaatkan arsitektur jaringan yang mendalam, model *deep learning* mampu mengekstraksi fitur penting dari data secara lebih efektif sehingga dapat meningkatkan akurasi prediksi.

## 2.5 Recurrent Neural Network (RNN)

*Recurrent Neural Network* (RNN) merupakan salah satu arsitektur *deep learning* yang dirancang khusus untuk menangani data sekuensial atau deret waktu, seperti data harga minyak, teks, dan sinyal. Berbeda dari jaringan saraf *feedforward* biasa, RNN memiliki mekanisme memori internal yang memungkinkan informasi dari *input* sebelumnya digunakan dalam memproses *input* pada waktu berikutnya. Hal ini menjadikannya sangat efektif dalam memahami pola dan dependensi temporal jangka pendek dalam data (Kumar & Bhattacharya, 2021).


Pada RNN, setiap neuron tidak hanya menerima *input* dari lapisan sebelumnya, tetapi juga menerima informasi dari keadaan tersembunyi (*hidden state*) pada waktu sebelumnya. *Hidden state* ini berfungsi sebagai memori yang menyimpan informasi dari proses sebelumnya sehingga model dapat mempertimbangkan konteks historis ketika menghasilkan *output* pada waktu tertentu. Struktur berulang ini membuat RNN banyak digunakan dalam berbagai permasalahan yang melibatkan data sekuensial, seperti pemrosesan bahasa alami, pengenalan suara, serta peramalan deret waktu (Goodfellow *et al.*, 2016).

Meskipun memiliki kelebihan dalam pengolahan data sekuensial, RNN tradisional sering kali mengalami kendala dalam mempelajari dependensi jangka panjang akibat masalah *vanishing gradient* selama proses pelatihan. Permasalahan ini menyebabkan informasi dari langkah waktu sebelumnya menjadi semakin kecil ketika propagasi balik dilakukan sehingga model sulit mempertahankan informasi dalam jangka waktu yang panjang (Bengio *et al.*, 1994).

Untuk mengatasi keterbatasan ini, berbagai varian dari RNN dikembangkan, seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Arsitektur ini dirancang dengan mekanisme gerbang (*gate*) yang memungkinkan model untuk mengatur informasi yang perlu disimpan, diperbarui, atau dihapus selama proses pembelajaran. Dengan mekanisme tersebut, model dapat mempertahankan informasi penting dalam rentang waktu yang lebih panjang sehingga lebih stabil dalam memodelkan data deret waktu dan banyak digunakan dalam berbagai penelitian prediksi, termasuk dalam prediksi harga minyak (Putra & Wibowo, 2021).

## 2.6 Long Short Term Memory (LSTM)

*Long Short-Term Memory* (LSTM) merupakan varian *Recurrent Neural Network* (RNN) yang dikembangkan untuk mengatasi kelemahan RNN dalam mempertahankan memori jangka panjang, terutama masalah *vanishing gradient* selama proses pembelajaran berulang. Struktur LSTM menggunakan komponen bernama *memory cell* yang dilengkapi tiga gerbang pengatur: *forget gate*, *input gate*, dan *output gate*. Ketiga gerbang ini menentukan informasi mana yang harus disimpan, diperbarui, atau dikeluarkan ke langkah berikutnya. Selain itu, setiap sel LSTM memiliki tiga lapisan *sigmoid* dan satu lapisan *tanh* yang berperan dalam mengatur aliran data dan menjaga stabilitas nilai dalam model (Qiu *et al.*, [2020]). Dengan mekanisme tersebut, LSTM mampu mempelajari pola jangka panjang dan memberikan hasil yang lebih akurat dalam pemodelan data deret waktu, seperti prediksi harga minyak dunia.



Gambar 2. Arsitektur *Long Short Term Memory* (LSTM)

Struktur sel LSTM. Inti dari sel LSTM yaitu status sel  $C_t$ , yang bertindak sebagai saluran untuk membawa informasi historis melalui sel LSTM. Sel LSTM mencakup *forget gate*  $f_t$ , *input gate*  $i_t$ , dan *output gate*  $o_t$ . Komponen-komponen ini bekerja sama dengan status tersembunyi sebelumnya  $h_{t-1}$  dan *input*  $X_t$  saat ini untuk mengelola jalannya dan transformasi informasi (Hochreiter & Schmidhuber, 1997).

Persamaan matematis fungsi *sigmoid* dan *tanh* dapat dinyatakan sebagai berikut:

### 1. Fungsi *Sigmoid*

Lapisan *sigmoid* menghasilkan nilai dalam rentang nol hingga satu, dimana nilai tersebut merepresentasikan seberapa banyak proporsi informasi yang diteruskan pada setiap komponen. Nilai yang mendekati nol menunjukkan bahwa informasi

cenderung diabaikan, sedangkan nilai yang mendekati satu menunjukkan bahwa informasi cenderung diteruskan sepenuhnya. Persamaan fungsi *sigmoid* dapat dinyatakan sebagai berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad -\infty < x < \infty \quad (2.6.1)$$

Keterangan:

$\sigma(x)$  = fungsi *sigmoid*

$x$  = variabel *input*

$e$  = konstanta bilangan natural

## 2. Fungsi *tanh*

Fungsi *tanh* atau disebut dengan tangen hiperbolik menghasilkan nilai dalam rentang -1 sampai dengan 1. Dibandingkan dengan fungsi *sigmoid*, fungsi *tanh* memiliki rentang nilai yang lebih luas, sehingga lebih efektif digunakan untuk pemodelan nonlinear yang kompleks (Lewis, 2017). Persamaan fungsi *tanh* dapat dinyatakan sebagai berikut:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad -\infty < x < \infty \quad (2.6.2)$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \quad (2.6.3)$$

Keterangan:


$x$  = variabel *input*

$e$  = konstanta bilangan natural

$\sinh(x)$ ,  $\cosh(x)$  = fungsi *sinus* dan fungsi *cosinus* hiperbolik

Panduan jalannya metode LSTM sebagai berikut:

### 1. *Forget Gate*



Gambar 3. *Forget Gate* struktur LSTM

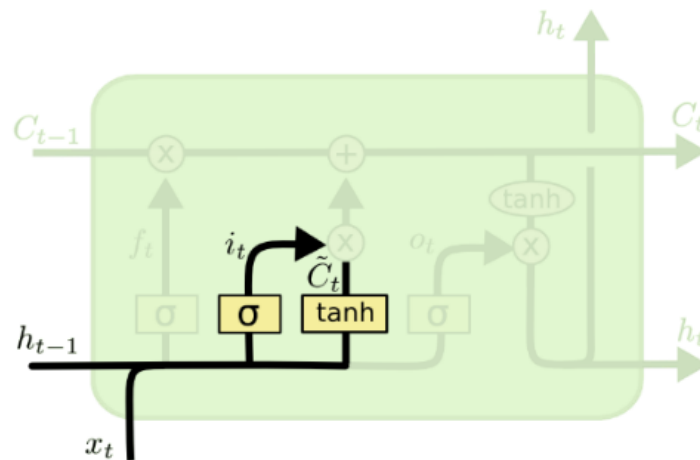
*Forget gate* berfungsi untuk memutuskan informasi apa yang akan dibuang dari status sel berdasarkan masukan saat ini dan status tersembunyi sebelumnya. *Output*  $f_t$  berkisar antara 0 dan 1.

$$f(t) = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.6.4)$$

Keterangan:

- $\sigma$  = fungsi *sigmoid*
- $W_f$  = nilai bobot untuk *forget gate*
- $b_f$  = nilai bias untuk *forget gate*
- $x_t$  = nilai *input* pada waktu ke- $t$
- $h_{t-1}$  = *hidden state* pada waktu ke- $(t - 1)$
- $f_t$  = *forget gate*

## 2. Input Gate



Gambar 4. *Input Gate* struktur LSTM

Pada tahap berikutnya memutuskan informasi baru apa yang akan kita simpan dalam status sel. Lapisan ini memiliki dua komponen utama. Pertama, lapisan *sigmoid* yaitu *input gate layer* memutuskan informasi yang perlu diperbarui. Kedua, lapisan *tanh* membuat vektor kandidat baru,  $\tilde{C}_t$ , yang berpotensi ditambahkan ke keadaan sel (*cell state*).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad t = 1, 2, \dots, T \quad (2.6.5)$$

Keterangan:

$\sigma$  = fungsi *sigmoid*

$W_i$  = nilai bobot untuk *input gate*

$b_i$  = nilai bias untuk *input gate*

$x_t$  = nilai *input* pada waktu ke- $t$

$h_{t-1}$  = *hidden state* pada waktu ke- $(t - 1)$

$i_t$  = *input gate*

Selanjutnya, sebuah lapisan *tanh* akan menghasilkan vektor kandidat baru  $C_t$ , yang berpotensi ditambahkan ke keadaan sel. Pada tahap berikutnya, kedua komponen ini akan digabungkan untuk memperbarui keadaan sel.

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.6.6)$$

Keterangan:

$\tilde{C}_t$  = nilai kandidat *cell state* baru pada waktu ke- $t$

$\tanh$  = fungsi *tanh*

$W_c$  = nilai bobot untuk *cell state*

$h_{t-1}$  = *hidden state* pada waktu ke- $(t - 1)$

$x_t$  = nilai *input* pada waktu ke- $t$

$b_c$  = nilai bias pada *cell state*

Berikutnya, memperbarui status sel lama,  $C_{t-1}$ , ke status sel baru  $C_t$ . *Cell state* ( $C_t$ ) berfungsi sebagai jalur utama yang membawa informasi dalam jangka panjang. Perbaruan nilai  $C_t$  pada setiap langkah waktu ditentukan oleh kombinasi antara nilai keadaan sel sebelumnya ( $C_{t-1}$ ) dan informasi baru yang diperoleh melalui mekanisme gerbang.

Secara matematis, nilai keadaan sel pada waktu  $t$  dirumuskan sebagai berikut:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.6.7)$$

Keterangan:

$C_t$  = nilai *cell state* pada waktu ke- $t$


$f_t$  = output *forget gate* pada waktu ke- $t$

$C_{t-1}$  = *cell state* pada waktu ke- $(t - 1)$

$i_t$  = output *input gate* pada waktu ke- $t$

$\tilde{C}_t$  = nilai kandidat *cell state* baru pada waktu ke- $t$

### 3. Output Gate



Gambar 5. Output Gate struktur LSTM

Terakhir, kita perlu menentukan informasi apa yang akan dikeluarkan dari sel. Nilai keluaran ini didasarkan pada keadaan sel, tetapi dalam bentuk yang telah difilter.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.6.8)$$

Keterangan:

$o_t = \text{output gate}$

$\sigma = \text{fungsi sigmoid}$

$W_o = \text{nilai bobot untuk output gate}$

$h_{t-1} = \text{hidden state pada waktu ke-}(t - 1)$

$x_t = \text{nilai input pada waktu ke-}t$

$b_o = \text{nilai bias pada output gate}$

Pertama, kita menerapkan lapisan *sigmoid* untuk menentukan bagian mana dari keadaan sel yang akan dijadikan keluaran. Selanjutnya, keadaan sel diproses melalui fungsi aktivasi *tanh* (untuk membatasi nilainya dalam rentang -1 hingga 1) dan dikalikan dengan hasil dari gerbang keluaran (*output gate*). Dengan demikian, hanya informasi yang dipilih yang akan dikeluarkan.

$$h_t = o_t \cdot \tanh(C_t), \quad t = 1, 2, \dots, T \quad (2.6.9)$$

Keterangan:

$h_t$  = *hidden state* pada waktu ke- $t$

$o_t$  = *output gate*

$\tanh$  = fungsi *tanh*

$C_t$  = *cell state*

Dengan adanya *gate-gate* ini, *Long Short-Term Memory* (LSTM) dapat secara selektif mengontrol aliran informasi dalam dan keluar dari memori jangka panjang. Hal ini memungkinkan model untuk mengatasi hubungan jangka panjang, sehingga model mampu menghasilkan prediksi yang lebih akurat (Samal *et al.*, 2021).

## 2.7 Hyperparameter Tuning

*Hyperparameter tuning* merupakan proses optimasi untuk menentukan kombinasi parameter terbaik pada suatu model *machine learning* atau *deep learning* sebelum proses pelatihan dilakukan. Berbeda dengan parameter model yang dipelajari secara otomatis selama proses *training* melalui proses pembaruan bobot (*weights*), *hyperparameter* ditetapkan terlebih dahulu untuk mengontrol struktur model dan proses pembelajaran jaringan saraf. Pemilihan *hyperparameter* yang tepat sangat berpengaruh terhadap kemampuan model dalam mempelajari pola data serta kinerja prediksi yang dihasilkan (Goodfellow *et al.*, 2016).

Pada model *deep learning*, *hyperparameter* berperan dalam menentukan arsitektur jaringan serta mekanisme pelatihan model. Beberapa *hyperparameter* yang umum digunakan pada model *Long Short-Term Memory* (LSTM) antara lain jumlah unit neuron pada lapisan LSTM, nilai *dropout* untuk mengurangi *overfitting*, *learning rate* yang mengatur kecepatan pembaruan bobot model, *batch size* yang menentukan jumlah data yang diproses dalam satu iterasi pelatihan, serta jumlah *epoch* yang menunjukkan berapa kali seluruh data pelatihan digunakan dalam proses pembelajaran model (Chollet & Allaire, 2021). Oleh karena itu, proses penentuan *hyperparameter* yang optimal menjadi tahap penting dalam pembangunan model *deep learning* (Brownlee, 2018).

Salah satu metode yang sering digunakan dalam proses *hyperparameter tuning* adalah *Grid Search*. Metode ini bekerja dengan cara mencoba seluruh kombinasi nilai *hyperparameter* yang telah ditentukan sebelumnya, kemudian mengevaluasi performa model pada setiap kombinasi tersebut. Kombinasi parameter yang menghasilkan nilai kesalahan prediksi paling kecil akan dipilih sebagai konfigurasi *hyperparameter* terbaik untuk digunakan pada model yang dibangun (Bergstra & Bengio, 2012).

## 2.8 Validasi Model

Validasi model merupakan proses untuk menilai kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Proses ini bertujuan untuk mengetahui sejauh mana model mampu melakukan generalisasi terhadap data baru sehingga dapat mengurangi risiko *overfitting* pada model yang dibangun. Melalui validasi model, peneliti dapat menilai apakah model yang dihasilkan memiliki performa yang stabil ketika diterapkan pada data yang berbeda dari data pelatihan (Kuhn & Johnson, 2013).

Salah satu metode validasi yang umum digunakan yaitu *cross validation*, di mana data dibagi menjadi beberapa bagian untuk proses pelatihan dan pengujian secara berulang. Pendekatan ini memungkinkan setiap bagian data digunakan sebagai data pengujian secara bergantian sehingga evaluasi model dapat dilakukan secara lebih menyeluruh. Melalui proses tersebut, performa model yang dihasilkan diharapkan lebih stabil dan mampu merepresentasikan kemampuan model dalam memprediksi data baru dengan lebih akurat (Friedman *et al.*, 2009).

### 2.8.1 Cross Validation

*Cross validation* merupakan metode validasi model dengan cara membagi *dataset* ke dalam beberapa *subset* yang disebut sebagai *fold*. Pada setiap iterasi, satu *subset* digunakan sebagai data pengujian dan *subset* lainnya digunakan sebagai data pelatihan. Proses tersebut dilakukan secara berulang sehingga setiap *subset* memperoleh kesempatan menjadi data pengujian sehingga kinerja model dapat dievaluasi secara lebih menyeluruh (Raschka & Mirjalili., 2020).

Metode *cross validation* banyak digunakan dalam penelitian *machine learning* atau *deep learning* karena mampu memberikan estimasi performa model yang lebih stabil dibandingkan dengan pembagian data tunggal. Dengan melakukan proses pelatihan dan pengujian secara berulang pada beberapa *subset* data, metode ini dapat membantu mengurangi bias dalam evaluasi model serta memberikan gambaran yang lebih representatif mengenai kemampuan model dalam melakukan prediksi (Arlot & Celisse, 2010).

### **2.8.2 Time Series Cross Validation**

Pada data deret waktu, pembagian data tidak dapat dilakukan secara acak karena dapat merusak urutan temporal data. Jika data diacak, maka informasi dari masa depan dapat secara tidak sengaja digunakan dalam proses pelatihan model, sehingga menyebabkan hasil evaluasi menjadi tidak realistis. Oleh karena itu, digunakan metode *Time Series Cross Validation*, di mana data pelatihan selalu berasal dari periode waktu sebelum data pengujian (Brownlee, 2018).

Dalam metode ini, data pelatihan selalu terdiri dari observasi pada periode waktu sebelumnya, sedangkan data pengujian berasal dari periode waktu setelahnya. Pendekatan ini sering diterapkan menggunakan teknik *rolling window* atau *expanding window*, di mana ukuran data pelatihan bertambah secara bertahap seiring dengan proses evaluasi model. Dengan demikian, model dapat diuji pada beberapa periode waktu yang berbeda sehingga memberikan gambaran yang lebih akurat mengenai kemampuan model dalam melakukan prediksi pada data deret waktu (Bergmeir & Benítez, 2012).

## **2.9 Evaluasi Model**

Penilaian performa model prediksi deret waktu memegang peran krusial guna menilai tingkat ketepatan model dalam menangkap pola data dan menghasilkan ramalan yang sesuai dengan nilai sebenarnya. Terdapat beberapa indikator evaluasi yang lazim dipakai, *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Penentuan indikator evaluasi yang tepat sangat dipengaruhi oleh karakteristik masalah dan jenis deviasi yang menjadi prioritas untuk dikurangi.

Menurut (Brownlee, 2018) menjelaskan bahwa *Root Mean Squared Error* (RMSE) memberikan gambaran yang lebih intuitif karena satuannya sama dengan data asli. Adapun *Mean Absolute Percentage Error* (MAPE) mengkuantifikasi kesalahan dalam bentuk persentase, sehingga memudahkan perbandingan kinerja model antar dataset yang berbeda. Berikut formulasi matematis ketiga metrik evaluasi tersebut:

1. *Root Mean Squared Error* (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad i = 1, 2, \dots, n. \quad (2.9.10)$$

2. *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad i = 1, 2, \dots, n. \quad (2.9.11)$$

Keterangan:

$y_i$  = nilai aktual

$\hat{y}_i$  = nilai prediksi

$n$  = jumlah data

## 2.10 Minyak

Salah satu sumber daya alam yang tidak dapat diperbaharui adalah minyak bumi. Minyak mentah atau *crude oil* merupakan salah satu sumber daya yang sangat penting, dikarenakan hasil olahan minyak mentah merupakan sumber energi utama dalam berbagai sektor. Kebutuhan masyarakat terhadap minyak untuk kebutuhan sehari-hari cenderung meningkat. Hal tersebut menyebabkan kapasitas minyak semakin hari semakin berkurang. Apabila konsumsi terhadap minyak terus mengalami peningkatan tanpa diimbangi dengan ketersediaan minyak yang ada maka berpotensi menimbulkan kelangkaan sumber daya minyak. Ketidakseimbangan antara produksi dan konsumsi minyak dapat memicu kenaikan harga minyak yang berfluktuatif (Fauzanissa *et al.*, 2016).

Harga minyak dihitung menggunakan harga spot pasar minyak dunia. Acuan standar harga minyak dunia merujuk pada *West Texas Intermediate (WTI)* (Rahman *et al.*, 2022). Pergerakan harga minyak dunia dipengaruhi oleh tiga kelompok faktor utama, yaitu:

1. Faktor fundamental, yang mencakup permintaan dan penawaran minyak, tingkat ketersediaan minyak, kapasitas cadangan produksi dunia, serta kemampuan kilang dunia.
2. Faktor non fundamental, yang meliputi kondisi geopolitik, kebijakan pemerintah, faktor cuaca, bencana alam, serta pelemahan nilai tukar dollar.
3. Faktor kebijakan pasokan OPEC, yang berkaitan dengan keputusan produksi dan pengaturan suplai oleh negara-negara anggota OPEC.

## **BAB III**

### **METODE PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

Penelitian ini dilakukan pada semester ganjil tahun akademik 2025/2026 bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

#### **3.2 Data Penelitian**

Data yang digunakan dalam penelitian ini adalah data historis harga minyak dunia harian periode 27 Oktober 2020 sampai 27 Oktober 2025 dengan jumlah 1.311 data yang diperoleh melalui situs Investing Indonesia <https://id.investing.com/commodities/crude-oil-historical-data>. Harga minyak dinyatakan dalam satu satuan US Dollar per *barrel* (159 liter). Dataset kemudian dipisah menjadi data *training* dan data *testing* untuk keperluan pembangunan serta evaluasi model.

#### **3.3 Metode Penelitian**

Pada penelitian ini dilakukan analisis prediksi harga minyak dunia menggunakan metode *Long Short Term Memory* dengan bantuan bahasa pemrograman *Python*. Tahapan penelitian disusun secara sistematis, dengan langkah-langkah yang dilakukan sebagai berikut:

##### **a. Analisis Deskriptif**

Analisis deskriptif dilakukan untuk memberikan gambaran umum mengenai karakteristik data harga minyak dunia sebelum dilakukan pemodelan. Analisis ini

meliputi perhitungan nilai minimum, maksimum, rata-rata, dan standar deviasi, serta visualisasi data dalam bentuk grafik *time series*.

Analisis deskriptif bertujuan untuk mengidentifikasi pola pergerakan harga minyak dunia, seperti tren, fluktuasi, dan kemungkinan adanya lonjakan harga pada periode tertentu. Informasi ini penting untuk memahami sifat data *time series* yang digunakan serta menjadi dasar dalam pemilihan metode peramalan yang sesuai (Brownlee, 2018).

b. Pra-pemrosesan Data

Data harga minyak dunia diubah menjadi bentuk yang sesuai untuk pemodelan LSTM, yaitu dalam bentuk *time series supervised learning* menggunakan metode *sliding window*. Selanjutnya dilakukan normalisasi data menggunakan *Min-Max Scaling* agar data berada dalam rentang 0-1, yang membantu proses pelatihan model menjadi lebih stabil (Goodfellow *et al.*, 2016).

c. Pembagian Data menggunakan K-Fold *Time Series Split*

Pada penelitian ini, pembagian data tidak dilakukan secara acak, melainkan menggunakan metode *Time Series Split* sebanyak 5 fold. Metode ini membagi data berdasarkan urutan waktu sehingga struktur kronologis data tetap terjaga. Pada setiap fold, data dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian, di mana data pelatihan selalu berada sebelum data pengujian secara waktu. Hal ini bertujuan untuk menghindari terjadinya data *leakage* dalam proses peramalan (Brownlee, 2018).

d. *Hyperparameter Tuning*

*Hyperparameter tuning* merupakan proses untuk menentukan kombinasi parameter terbaik pada model *machine learning* sebelum proses pelatihan dilakukan. Pada penelitian ini digunakan metode *Grid Search* untuk menguji beberapa kombinasi parameter model LSTM seperti jumlah unit LSTM, *dropout*, dan *batch size*. Kombinasi parameter dengan nilai kesalahan prediksi terkecil dipilih sebagai parameter terbaik yang digunakan dalam pembangunan model (Bergstra & Bengio, 2012).

e. Pembangunan Model LSTM

Model LSTM dibangun menggunakan pustaka *TensorFlow* dan *Keras* pada bahasa pemrograman *Python*. Arsitektur model terdiri atas lapisan LSTM, lapisan *Dropout* untuk mencegah *overfitting*, dan lapisan *output Dense* untuk menghasilkan prediksi harga minyak (Chollet & Allaire, 2021).

f. Pelatihan Model

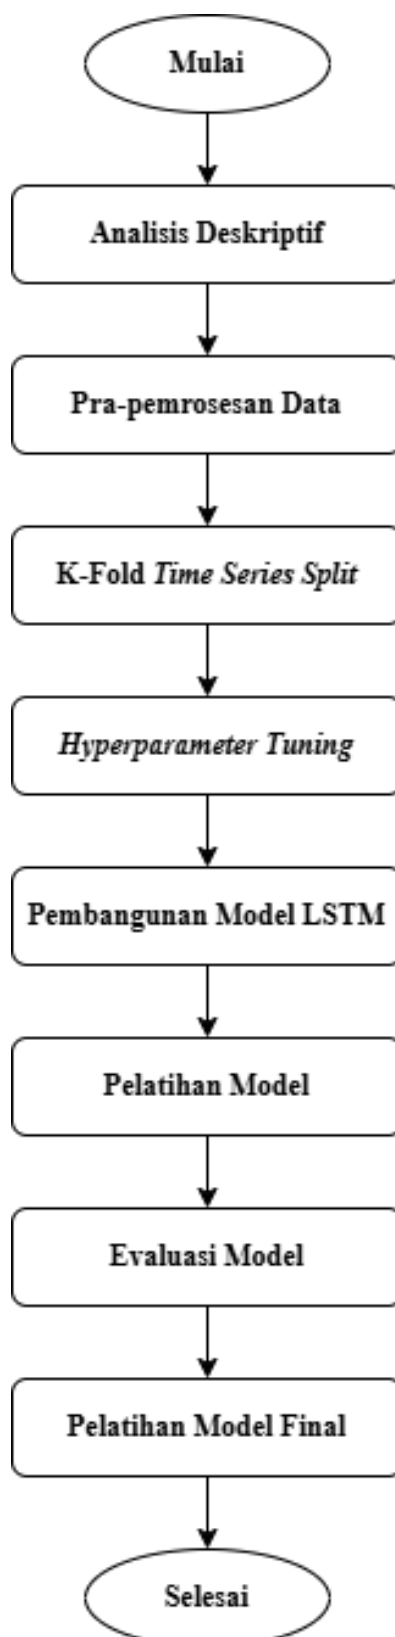
Model dilatih menggunakan data pelatihan dengan parameter seperti jumlah *epoch*, *batch size*, dan fungsi optimasi *Adam* (Goodfellow *et al.*, 2016).

g. Evaluasi Model

Kinerja model dievaluasi menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Evaluasi dilakukan pada setiap fold, kemudian dihitung nilai rata-rata RMSE dan MAPE untuk mengetahui performa keseluruhan model. Nilai RMSE dan MAPE yang rendah menunjukkan bahwa model mampu memprediksi harga minyak dunia dengan baik (Raschka & Mirjalili., 2020).

h. Pelatihan Model Final

Setelah proses validasi menggunakan *K-Fold Time Series Split* selesai, model kemudian dilatih kembali menggunakan seluruh data untuk menghasilkan model akhir (*final model*). Model akhir ini digunakan untuk melakukan prediksi harga minyak dunia pada periode selanjutnya.



Gambar 6. Diagram Alir Metode LSTM

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Adapun kesimpulan yang diperoleh adalah sebagai berikut:

1. Metode *Long Short-Term Memory* (LSTM) berhasil diterapkan untuk melakukan prediksi harga minyak dunia menggunakan data historis. Proses pemodelan meliputi tahap pra-pemrosesan data, pembentukan arsitektur model, pelatihan, serta evaluasi kinerja model. Hasil pengujian menunjukkan bahwa LSTM mampu menangkap pola temporal dan karakteristik fluktuasi harga minyak dunia secara efektif.
2. Berdasarkan hasil evaluasi menggunakan *Time Series Cross Validation*, model LSTM yang dibangun menunjukkan kinerja prediksi yang sangat baik, yang ditunjukkan dari nilai rata-rata RMSE sebesar 2,90%, MAPE sebesar 2,77%. Nilai-nilai tersebut mengindikasikan bahwa tingkat kesalahan prediksi model sangat rendah. Dengan demikian, dapat disimpulkan bahwa metode LSTM memiliki performa yang akurat, stabil, dan dapat diandalkan untuk memprediksi harga minyak dunia.

## DAFTAR PUSTAKA

- Aden. (2020). *Forecasting The Exponential Smoothing Methods*. Unpam Press.
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4, 40–79.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166.
- Benidis, K., Rangapuram, S. S., Flunkert, V., Wang, Y., Maddix, D., Türkmen, C., Gasthaus, J., Bohlke-Schneider, M., Salinas, D., Stella, L., Aubet, F.-X., Callot, L., & Januschowski, T. (2020). Deep learning for time series forecasting: Tutorial and literature survey. *Journal of Machine Learning Research*, 21(116): 1–6.
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192–213.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281–305.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Brownlee, J. (2018). *Deep learning for time series forecasting*. Machine Learning Mastery.
- Brownlee, J. (2020). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
- Chollet, F., & Allaire, J. J. (2021). *Deep Learning with R* (2nd ed.). Manning Publications.
- Fauzannissa, R. A., Yasin, H., & Ispriyanti, D. (2016). Peramalan harga minyak mentah dunia menggunakan metode Radial Basis Function Neural Network. *Jurnal Gaussian*, 5(1): 193–202.

- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, **270**(2): 654–669.
- Friedman, J., Hastie, T., & Tibshirani, R. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Herjanto, E. (2006). *Manajemen Operasi* (Edisi Ketiga). Grasindo.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, **9**(8): 1735–1780.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts.
- Jiao, Y., Sun, L., & Chen, H. (2023). Long short-term memory networks for energy price forecasting: A comparative study. *Energy Reports*, **9**, 2512–2526.
- Karim, M. E., & Ahmed, S. (2021). A deep learning-based approach for stock price prediction using bidirectional gated recurrent unit and bidirectional long short term memory model. *ResearchGate*.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.
- Kumar, R., & Bhattacharya, S. (2021). A comparative study of RNN, LSTM and GRU for stock market forecasting. *Journal of Intelligent Systems*, **30**(1): 137–147.
- Kusuma, P. D. (2020). *Machine Learning: Teori, Program, dan Studi Kasus*. Deepublish.
- Le-Hang, L. (2024). Time series analysis and applications in data analysis, forecasting and prediction. *HPU2 Journal of Science: Natural Sciences and Technology*, **3**(1): 20–29.
- Lewis, J. (2017). *Deep Learning Step by Step with Python: A Very Gentle Introduction to Deep Neural Networks for Practical Data Science*. Independently Published.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2019). The M4 competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, **35**(1): 1–26.

- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (2006). *Forecasting: Methods and Applications* (3rd ed.). Wiley.
- Muhammad, R., & Nurhaida, I. (2025). Penerapan LSTM dalam deep learning untuk prediksi harga kopi jangka pendek dan jangka panjang. *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, **10**(1), 554–564.
- Putra, A. D., & Wibowo, H. (2021). Prediksi harga saham PT Bank Rakyat Indonesia menggunakan RNN dan LSTM. *Jurnal Teknologi dan Sistem Komputer*, **9**(3): 155–160.
- Qiu, X., Sun, T., Xu, Y., Dai, N., & Huang, X. (2020). Pre-trained models for natural language processing: A survey. *Science China Technological Sciences*, **63**(10): 1872–1897.
- Rahman, M., Hasan, M., & Islam, M. (2022). Hybrid ARIMA–LSTM model for crude oil price forecasting. *Energy Reports*, **8**, 1895–1905.
- Raschka, S., & Mirjalili, V. (2020). *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2* (3rd ed.). Packt Publishing.
- Samal, K. K. R., Babu, K. S., & Das, S. K. (2021). Time series forecasting of air pollution using deep neural network with multi-output learning. *2021 IEEE 18th India Council International Conference (INDICON)*, 1–5.
- Zhang, Q., & Wang, L. (2021). Comparison of LSTM and GRU networks for oil price forecasting. *Applied Energy*, 298, 117145.