

BAB IV

HASIL DAN PEMBAHASAN

Bab ini akan menyajikan gambaran umum data harga emas dunia melalui analisis statistika deskriptif. Analisis ini bertujuan untuk memberikan pemahaman awal mengenai karakteristik data, seperti kecenderungan nilai, penyebaran, serta pola fluktuasi yang terjadi selama periode pengamatan. Dengan demikian, hasil deskripsi ini dapat menjadi dasar dalam menginterpretasikan perilaku data sebelum dilakukan pemodelan lebih lanjut menggunakan *metode Ensemble Empirical Mode Decomposition* (EEMD) dan *Long Short-Term Memory* (LSTM).

4.1 Statistika Deskriptif

Pada penelitian ini, data diolah dengan bantuan *software Python*. Pengolahan statistika deskriptif data menampilkan gambaran data yang meliputi rata-rata (*mean*), nilai minimum, nilai maksimum dan grafik nilai aktual (Gambar 4.1). Hasil statistika deskriptif ditunjukkan pada Tabel 4.1.

Tabel 4. 1 Statistika Deskriptif Data Harga Emas Dunia

N (Jumlah Data)	Mean	Nilai Maksimum	Nilai Minimum	Standar Deviasi
3.977	1.569,447	3.236,21	1.051,74	391,69

Sumber: Diolah Peneliti

Berdasarkan hasil analisis statistika deskriptif pada Tabel 4.1, diperoleh jumlah data harga emas dunia sebanyak 3.977 observasi dengan rata-rata sebesar 1.569,45 USD/*troy ounce* dan standar deviasi 391,69 USD/*troy ounce*. Harga emas minimum tercatat sebesar 1.051,74 USD/*troy ounce* pada bulan Desember 2015, sedangkan harga emas maksimum mencapai 3.236,21 USD/*troy ounce* pada bulan April 2025. Nilai standar deviasi yang cukup besar ini menunjukkan adanya variasi yang signifikan pada data harga emas dunia terhadap nilai rata-ratanya. Hal ini mencerminkan fluktuasi harga emas yang dipengaruhi oleh dinamika kondisi global, sehingga memerlukan metode prediksi yang mampu mengakomodasi pola

data yang kompleks. Adapun plot grafik data Harga Emas Dunia ditunjukkan pada Gambar 4.1.



Sumber: Diolah Peneliti

Gambar 4. 1 Data Aktual Harga Emas Dunia Periode Tahunan

Pada Gambar 4.1 terlihat bahwa harga emas dunia selama periode 2010 hingga 2025 mengalami fluktuasi tajam dengan pola pergerakan yang *nonlinier* dan bersifat non-stasioner. Meskipun data harga emas dunia dalam penelitian ini bersifat harian, pada gambar tersebut disajikan dalam bentuk rata-rata tahunan untuk mempermudah pembacaan pola jangka panjang. Harga emas dunia mencapai titik terendah pada Desember 2015 sebesar 1.051,74 USD/*troy ounce*, yang dipengaruhi oleh penguatan dolar AS serta kebijakan moneter The Federal Reserve yang menaikkan suku bunga, sehingga minat investor terhadap emas menurun. Namun, setelah periode tersebut harga emas berbalik naik dengan fluktuasi yang cukup tinggi, hingga akhirnya mencapai puncak tertinggi pada April 2025 sebesar 3.236,21 USD/*troy ounce*. Kenaikan ini didorong oleh pelemahan dolar AS, meningkatnya permintaan emas sebagai aset *safe haven* di tengah ketidakpastian ekonomi global, serta gejolak geopolitik dan kebijakan perdagangan internasional. Kondisi ini menunjukkan bahwa harga emas dunia bersifat tidak stasioner serta sangat dipengaruhi oleh dinamika faktor eksternal, sehingga diperlukan metode prediksi yang mampu menangkap pola data yang kompleks, seperti kombinasi EEMD-LSTM yang digunakan dalam penelitian ini.

4.2 Preprocessing Data

Setelah dilakukan statistika deskriptif, dilakukan tahapan *preprocessing* data yang terbagi menjadi tiga tahapan sebagai berikut:

4.2.1 Data Cleaning

Pada tahap *data cleaning* dilakukan pengecekan terhadap keberadaan *missing value* pada data harga emas dunia yang digunakan dalam penelitian. Hasil pengecekan menunjukkan bahwa seluruh data pada kolom harga emas dunia tidak memiliki *missing value* (jumlah *missing value* = 0 atau 0%). Dengan demikian, data yang digunakan dinyatakan bersih dari nilai kosong maupun data yang tidak lengkap, sehingga layak untuk dilanjutkan ke tahap berikutnya, yaitu pembagian data menjadi data pelatihan (*training*) dan data pengujian (*testing*). Tahapan ini bertujuan untuk melatih model pada sebagian besar data agar mampu mempelajari pola historis, serta menguji kinerjanya pada data baru yang belum pernah dilihat sebelumnya.

4.2.2 Pembagian Data

Pada tahap pembagian data, harga emas dunia yang telah dinormalisasi dipisahkan menjadi dua bagian, yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih model LSTM pada masing-masing komponen hasil dekomposisi EEMD agar model dapat mempelajari pola historis harga emas dunia secara optimal. Sementara itu, data *testing* berfungsi untuk mengevaluasi kemampuan model dalam memprediksi data yang belum pernah digunakan pada tahap pelatihan, sehingga dapat menilai tingkat keakuratan metode EEMD-LSTM dalam penelitian ini. Adapun Tabel 4.2 menyajikan pembagian data harga emas dunia menjadi data *training* sebesar 80% dan data *testing* sebesar 20% yang digunakan dalam pemodelan.

Tabel 4. 2 Pembagian Data *Training* dan Data *Testing*

Jenis Data	Proporsi	Jumlah Data	Periode Waktu
<i>Training</i>	80%	3.181	Januari 2010 – Juli 2023
<i>Testing</i>	20%	796	Agustus 2023 - April 2025
Total	100%	3.977	Januari 2010 – April 2025

Sumber: Diolah Peneliti

Berdasarkan Tabel 4.2 menunjukkan pembagian data harga emas dunia menjadi data *training* sebesar 80% (3.181 observasi) dan data *testing* sebesar 20% (796 observasi). Proporsi ini mengikuti prinsip Pareto (80:20), di mana sebagian besar data dimanfaatkan untuk melatih model agar dapat mengenali pola historis dengan baik, sedangkan sebagian kecil data dialokasikan untuk menguji performa prediksi secara objektif. Setelah pembagian ini, dilakukan tahap normalisasi guna menyeragamkan skala data sebelum dekomposisi EEMD dan pemodelan LSTM.

4.2.3 Normalisasi Data

Pada tahapan *preprocessing* dilakukan normalisasi data harga emas dunia untuk membobotkan atau memetakan nilai ke dalam rentang yang sama dengan skala 0 hingga 1 agar memiliki distribusi yang seragam dan mempermudah proses pemodelan. Data harga emas dunia dinormalisasikan menggunakan rumus Persamaan (1), Proses normalisasi ini dilakukan pada setiap data harian harga emas dunia melalui perhitungan menggunakan nilai minimum sebesar 1.051,74 dan nilai maksimum sebesar 3.236,21. Nilai minimum dan maksimum data diperoleh dari hasil analisis statistika deskriptif pada Sub bab 4.1 (Halaman 35). Selanjutnya, hasil normalisasi data harga emas dunia ini akan dilanjutkan proses pelatihan dan pengujian model prediksi harga emas dunia berbasis EEMD-LSTM.

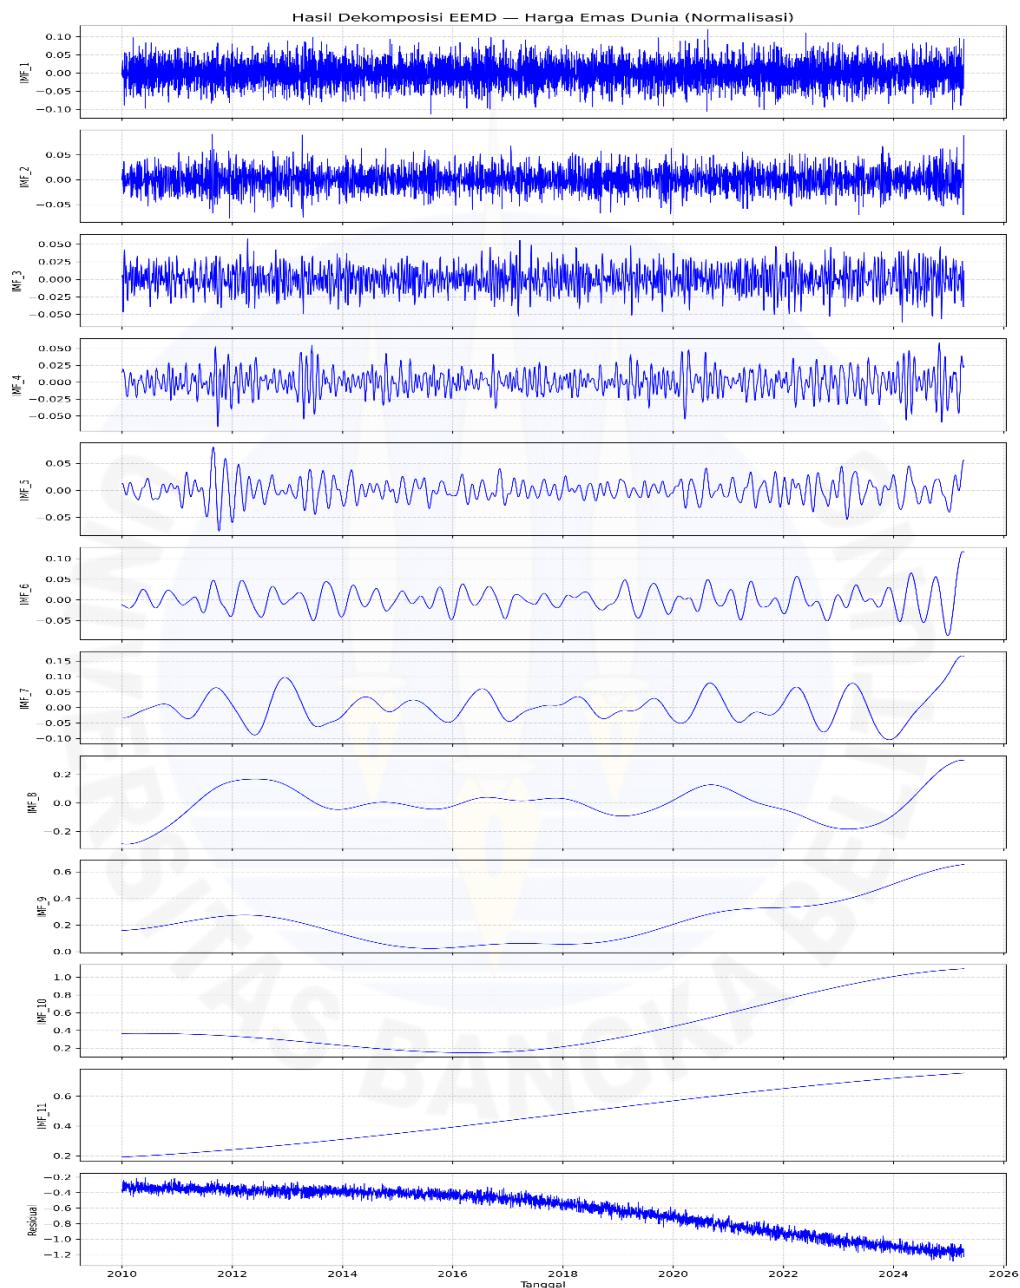
4.3 Analisis dan Dekomposisi Data dengan *Ensemble Empirical Mode Decomposition* (EEMD)

Pada tahap ini dilakukan proses dekomposisi data harga emas dunia menggunakan metode *Ensemble Empirical Mode Decomposition* (EEMD). Metode EEMD ini bertujuan untuk memecah data asli yang bersifat kompleks menjadi beberapa komponen sinyal yang lebih sederhana, yaitu *Intrinsic Mode Function* (IMF) dan *residual*.

4.3.1 Komponen *Intrinsic Mode Function* (IMF) dan *Residual*

Dekomposisi data harga emas dunia menggunakan metode EEMD berhasil memisahkan data menjadi 11 komponen IMF dan residual, Sesuai penjelasan pada Subbab 2.1.8 (halaman 15), IMF terbentuk dari frekuensi tinggi hingga rendah yang merepresentasikan fluktuasi jangka pendek hingga jangka panjang, sedangkan residual menunjukkan tren utama data. Hasil dekomposisi berupa komponen IMF

dapat dilihat pada Gambar 4.2, yang menunjukkan pola osilasi masing-masing komponen secara jelas. Selanjutnya, setiap IMF digunakan sebagai input dalam proses pemodelan LSTM secara terpisah untuk memprediksi harga emas dunia. Hasil akhir dari prediksi ini akan direkonstruksi dan dianalisis pada tahap berikutnya.



Sumber: Diolah Peneliti

Gambar 4. 2 Hasil Dekomposisi *Ensemble Empirical Mode Decomposition* (EEMD) Data Harga Emas Dunia

Rataan periode masing-masing IMF ditentukan berdasarkan jumlah puncak dan lembah yang terdapat pada komponen tersebut. Semakin sedikit jumlah puncak dan lembah, maka semakin besar rataan periode yang dihasilkan, yang mencerminkan frekuensi semakin rendah. Nilai jumlah puncak, jumlah lembah, rataan periode, korelasi, ragam, serta rasio ragam (%) untuk setiap IMF dan residual disajikan pada Tabel 4.3.

Tabel 4. 3 Deskripsi Komponen IMF dan Residual Hasil Dekomposisi *Ensemble Empirical Mode Decomposition* (EEMD)

	Jumlah Puncak	Jumlah Lembah	Rataan Periode	Korelasi <i>Pearson</i>	Ragam	Rasio Ragam (%)
Data						0,241969
IMF1	1450	1450	2,74	0,0053	0,001195	0,8
IMF2	758	757	5,25	0,0119	0,000473	0,32
IMF3	393	393	10,12	0,0158	0,00029	0,19
IMF4	188	188	21,18	0,0419	0,000283	0,19
IMF5	86	85	46,75	0,0989	0,000363	0,24
IMF6	36	36	110,63	0,1656	0,0007	0,47
IMF7	15	15	269,21	0,3458	0,002159	1,44
IMF8	6	6	668,6	0,4292	0,013061	8,72
IMF9	2	2	1306	0,9441	0,026819	17,91
IMF10	1	1	-	0,8797	0,088322	58,98
IMF11	0	0	-	0,6597	0,031173	20,82
Residual	1321	1322	3,01	-0,7862	0,077132	51,51
Jumlah						161,59

Sumber: Diolah Peneliti

Berdasarkan Tabel 4.3, menampilkan deskripsi karakteristik setiap komponen IMF dan residual hasil dekomposisi EEMD pada harga emas dunia. Jumlah puncak dan jumlah lembah merepresentasikan banyaknya titik tertinggi dan terendah pada sinyal, nilainya tinggi pada IMF berfrekuensi tinggi seperti IMF1 (1450) dan menurun pada IMF bernomor besar hingga IMF11 yang tidak memiliki

puncak maupun lembah. Rataan periode meningkat dari 2,74 pada IMF1 hingga mencapai ribuan hari pada IMF9, menandakan pergeseran dari fluktuasi jangka pendek menuju tren jangka panjang. Korelasi Pearson relatif rendah pada IMF1–IMF6, namun tinggi pada IMF frekuensi rendah seperti IMF9 (0,9441) dan IMF10 (0,8797), yang berperan dominan membentuk tren harga emas. Rasio ragam menunjukkan kontribusi variasi masing-masing komponen terhadap ragam total data asli (0,241969), dengan kontribusi terbesar dari IMF10 (58,98%), diikuti residual (51,51%), IMF11 (20,82%), dan IMF9 (17,91%). Total rasio ragam mencapai 161,59% akibat adanya *overlapping* atau tumpang tindih informasi antar komponen yang merupakan sifat alami metode EEMD.

4.4 Pemodelan *Long Short Term Memory* (LSTM) pada Data Hasil *Ensemble Empirical Mode Decomposition* (EEMD)

Setelah proses dekomposisi menggunakan EEMD, setiap komponen IMF dan residual diprediksi secara terpisah menggunakan algoritma LSTM. Model ini dipilih karena kemampuannya dalam mempelajari pola data deret waktu, baik jangka pendek maupun jangka panjang. Setiap komponen hasil dekomposisi dimasukkan ke dalam model LSTM untuk dilatih dan diuji guna menghasilkan prediksi yang akurat. Tahap ini diawali dengan penentuan parameter dan arsitektur model yang digunakan.

4.4.1 Membangun Model *Long Short Term Memory* (LSTM)

Setelah dilakukan dekomposisi data harga emas dunia menggunakan metode EEMD, tahap berikutnya adalah melakukan *tuning hyperparameter* menggunakan python untuk menentukan konfigurasi optimal model LSTM dalam memprediksi setiap komponen hasil dekomposisi. *Hyperparameter* yang diuji meliputi *time step*, *units*, *epoch*, dan *batch size*. *Time step* adalah jumlah langkah waktu sebelumnya yang digunakan sebagai acuan untuk memprediksi nilai pada langkah waktu berikutnya. *Units* adalah jumlah neuron pada lapisan tersembunyi (*hidden layer*) LSTM yang berfungsi untuk menangkap pola dan keterkaitan dalam data deret waktu. *Epoch* merupakan jumlah iterasi penuh seluruh data pelatihan melalui model, di mana setiap iterasi terdiri atas sejumlah *batch*. *Batch size* adalah jumlah sampel data yang diproses model dalam satu kali perhitungan gradien dan pembaruan bobot. Pemilihan *hyperparameter* yang tepat tidak hanya bertujuan

untuk meningkatkan akurasi prediksi, tetapi juga untuk menghindari *overfitting* dengan menjaga keseimbangan antara kompleksitas model dan kemampuan generalisasi. Tabel 4.4 menyajikan kombinasi *hyperparameter* terbaik yang diperoleh pada penelitian ini.

Tabel 4. 4 Hasil Hyperparameter Setiap *Intrinsic Mode Function* (IMF) Model *Long Short Tem Memory* (LSTM)

Komponen	Time Step	Units	Epochs	Batch Size	RMSE	MAPE
IMF 1	5	32	16	50	0,030753	380,4914
IMF 2	10	32	16	100	0,00894	126,3087
IMF 3	10	64	8	100	0,001405	57,91048
IMF 4	10	64	8	100	0,000497	7,579798
IMF 5	10	32	8	50	0,000394	7,406159
IMF 6	5	32	8	100	0,00021	3,471516
IMF 7	5	32	8	100	0,000164	0,969042
IMF 8	10	64	8	50	0,000677	49,51526
IMF 9	5	32	16	100	0,006079	0,853762
IMF 10	5	64	8	50	0,00673	0,559513
IMF 11	10	64	16	50	0,001316	0,168541
Residual	10	32	16	50	0,048824	3,562997

Sumber: Diolah Peneliti

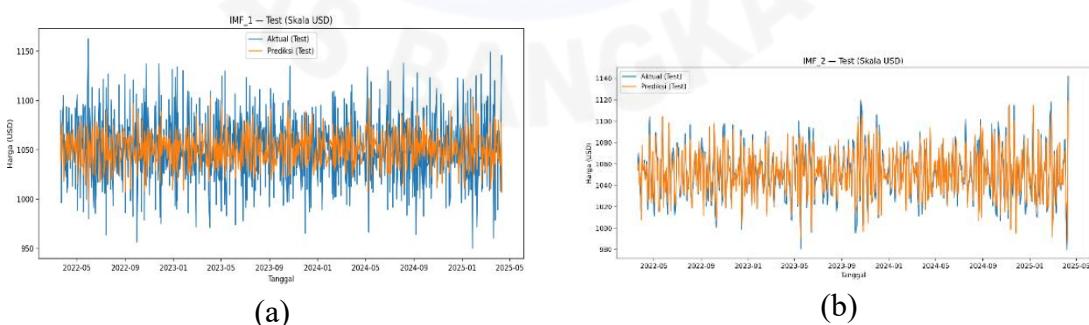
Berdasarkan Tabel 4.4 proses *tuning hyperparameter* pada penelitian ini dilakukan dengan pendekatan *mini grid search*, yaitu pencarian kombinasi parameter terbaik dari rentang nilai yang terbatas namun relevan. Pendekatan ini dipilih karena lebih efisien dibandingkan *full grid search* yang membutuhkan waktu komputasi sangat besar. Rentang nilai yang diuji meliputi *time step* (5 dan 10), *units* (32 dan 64), *epochs* (8 dan 16), serta *batch size* (50 dan 100). Pemilihan ruang pencarian ini ditetapkan berdasarkan nilai *hyperparameter* yang umum digunakan dalam penelitian deret waktu serta disesuaikan dengan karakteristik data harga emas, di mana *time step* merepresentasikan jendela waktu pendek dan menengah,

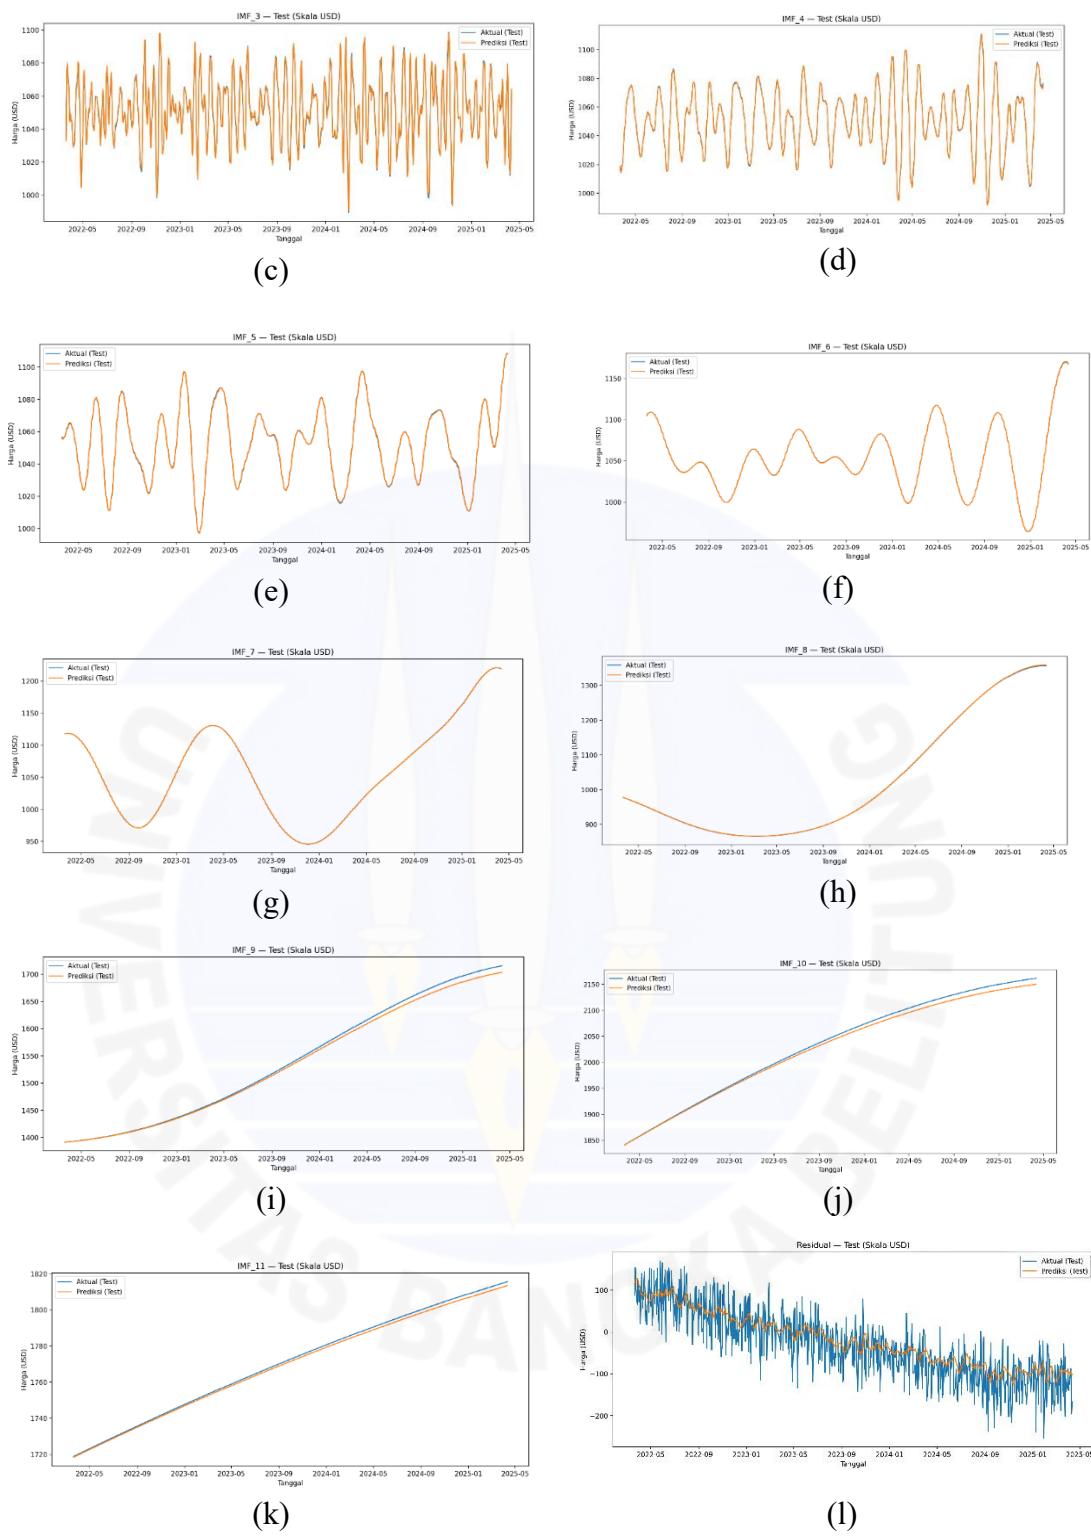
units mengontrol kompleksitas jaringan, sementara *epochs* dan *batch size* diatur untuk mencapai konvergensi tanpa *overfitting* sekaligus menjaga stabilitas pelatihan.

Berdasarkan hasil *tuning* yang ditampilkan pada Tabel 4.4, setiap IMF menunjukkan konfigurasi optimal yang berbeda sesuai karakteristik sinyalnya. IMF dengan frekuensi tinggi menghasilkan nilai MAPE lebih besar meskipun RMSE relatif kecil, sedangkan IMF dengan frekuensi rendah serta residual memperlihatkan MAPE yang sangat kecil dan lebih stabil. Secara keseluruhan, konfigurasi terbaik yang diperoleh mampu menghasilkan nilai RMSE dan MAPE terendah pada tiap komponen, sehingga model EEMD-LSTM dapat mempelajari pola temporal secara lebih akurat dan berkontribusi terhadap peningkatan akurasi rekonstruksi akhir.

4.4.2 Hasil Prediksi Setiap Komponen *Intrinsic Mode Function* (IMF)

Setelah model LSTM dibangun dengan model *hyperparameter* terbaik, langkah selanjutnya adalah menerapkannya untuk memprediksi masing-masing komponen hasil dekomposisi EEMD, yaitu IMF1 hingga IMF 11 dan residual. Model dilatih menggunakan data *training* dan dievaluasi pada data *testing* untuk mengukur kemampuan generalisasi. Setiap komponen diprediksi secara terpisah guna menangkap pola waktu yang berbeda-beda pada masing-masing spektrum frekuensi. Adapun Gambar 4.3 (a-l) menyajikan hasil prediksi model LSTM terhadap setiap komponen *Intrinsic Mode Function* (IMF) dan residual yang dihasilkan dari dekomposisi EEMD.





Sumber: Diolah Peneliti

Gambar 4.3 (a–c) Prediksi LSTM IMF dengan pola fluktuatif berfrekuensi tinggi, **(d–h)** Prediksi LSTM IMF dengan osilasi stabil berfrekuensi menengah-rendah, **(i–k)** Prediksi LSTM IMF yang merepresentasikan tren jangka panjang, dan **(l)** Prediksi LSTM residual yang menggambarkan tren utama.

Berdasarkan Gambar 4.3 (a-l), Hasil prediksi LSTM pada masing-masing komponen IMF dan *residual* dapat dijelaskan pada tabel 4.5 sebagai berikut:

Tabel 4. 5 Hasil Prediksi Setiap *Intrinsic Mode Function* (IMF) dan Residual

Komponen	Keterangan
IMF 1	Gambar 4.3 (a) merupakan IMF 1 yang memperlihatkan Pola pergerakan harga pada IMF ini bersifat sangat fluktuatif dengan frekuensi tinggi dan amplitudo yang bervariasi menandakan dominasi <i>noise</i> pada sinyal.
IMF 2	Gambar 4.3 (b) merupakan IMF 2 menampilkan pola fluktuasi berfrekuensi tinggi dengan amplitudo lebih rendah dibanding IMF 1. Meskipun <i>noise</i> masih terlihat, pola pergerakan mulai menunjukkan keteraturan yang lebih jelas.
IMF 3	Gambar 4.3 (c) merupakan IMF 3 menunjukkan pola osilasi yang lebih teratur dengan frekuensi menengah dan amplitudo stabil. Kandungan <i>noise</i> sudah jauh berkurang dibanding IMF 1 dan IMF 2.
IMF 4	Gambar 4.3 (d) merupakan IMF 4 menampilkan pola pergerakan yang halus dan stabil dengan frekuensi lebih rendah. Kandungan <i>noise</i> sangat minim, sehingga garis prediksi (oranye) hampir sepenuhnya berhimpit dengan garis aktual (biru) di seluruh periode pengujian.
IMF 5	Gambar 4.3 (e) merupakan IMF 5 menunjukkan pola osilasi dengan amplitudo sedang dan frekuensi relatif rendah. Kandungan <i>noise</i> hampir tidak terlihat.
IMF 6	Gambar 4.3 (f) merupakan IMF 6 memperlihatkan pola gelombang yang lebih panjang dan halus dengan amplitudo stabil. Kandungan <i>noise</i> tidak signifikan.
IMF 7	Gambar 4.3 (g) merupakan IMF 7 menampilkan pola gelombang jangka menengah hingga panjang dengan amplitudo relatif stabil. Kandungan <i>noise</i> sangat minim.

IMF 8	Gambar 4.3 (h) merupakan IMF 8 menunjukkan pola tren jangka panjang yang halus dan stabil dengan amplitudo rendah. Kandungan <i>noise</i> hampir tidak ada.
IMF 9	Gambar 4.3 (i) merupakan IMF 9 menampilkan tren jangka panjang yang relatif mulus dengan sedikit fluktuasi kecil. Kandungan <i>noise</i> sangat rendah.
IMF 10	Gambar 4.3 (j) merupakan IMF 10 menunjukkan tren kenaikan jangka panjang yang halus dengan fluktuasi minimal. Kandungan <i>noise</i> hampir tidak ada.
IMF 11	Gambar 4.3 (k) merupakan IMF 11 memperlihatkan tren kenaikan jangka panjang yang sangat halus dan stabil, dengan kandungan <i>noise</i> sedikit tidak ada.
Residual	Gambar 4.3 (l) merupakan residual menunjukkan pola tren menurun jangka panjang yang disertai fluktuasi acak berfrekuensi tinggi, menandakan kandungan <i>noise</i> masih cukup dominan.

Sumber: Diolah Peneliti

Secara keseluruhan, penerapan LSTM pada hasil dekomposisi EEMD menunjukkan performa yang sangat baik dalam memprediksi masing-masing komponen sinyal, baik pada frekuensi tinggi maupun rendah. Tingginya kesesuaian antara garis prediksi dan data aktual pada hampir seluruh komponen menegaskan kemampuan model dalam mempelajari pola waktu dari berbagai spektrum frekuensi. Hasil ini memperkuat validitas pendekatan EEMD-LSTM dan menjadi landasan penting untuk tahap rekonstruksi prediksi gabungan dalam memperkirakan harga emas dunia secara menyeluruh.

4.4.3 Rekonstruksi Prediksi Harga Emas Dunia dari Gabungan *Intrinsic Mode Function* (IMF) dan Residual (*Summation*)

Setelah dilakukan prediksi terhadap masing-masing komponen hasil dekomposisi EEMD IMF1 - IMF11 hingga residual. Langkah selanjutnya adalah merekonstruksi hasil prediksi tersebut menjadi satu kesatuan. Proses ini dilakukan dengan menjumlahkan seluruh hasil prediksi per komponen untuk memperoleh estimasi akhir harga emas dunia. Adapun hasil rekonstruksi ini kemudian dibandingkan dengan data aktual untuk mengevaluasi kinerja model secara keseluruhan. Adapun Gambar 4.4 menggambarkan hasil prediksi gabungan pada LSTM.



Sumber: Diolah Peneliti

Gambar 4. 4 Grafik Prediksi Harga Emas Dunia dari Gabungan *Intrinsic Mode Function* (IMF) dan Residual

Berdasarkan Gambar 4.4, Gambar tersebut menunjukkan hasil rekonstruksi akhir harga emas dunia dalam skala USD menggunakan metode EEMD-LSTM, yang diperoleh dari penjumlahan (*summation*) seluruh komponen IMF dan residual hasil prediksi. Garis biru merepresentasikan data aktual pada periode pelatihan (*train*), sedangkan garis oranye menunjukkan hasil prediksi pada periode yang sama. Untuk periode pengujian (*test*), data aktual ditampilkan dengan garis biru putus-putus, sementara prediksi ditampilkan dengan garis oranye putus-putus. Garis merah vertikal berfungsi sebagai penanda batas antara data pelatihan dan pengujian.

Secara visual, garis prediksi mampu mengikuti pola dan tren historis harga emas dunia dengan sangat baik, baik pada periode pelatihan maupun pengujian. Hal ini menunjukkan bahwa proses rekonstruksi melalui penjumlahan semua komponen IMF yang telah dimodelkan menggunakan LSTM berhasil menggabungkan sinyal frekuensi tinggi, menengah, hingga rendah menjadi representasi harga emas yang akurat. Kesesuaian pola ini mengindikasikan bahwa model EEMD-LSTM efektif dalam mempelajari dinamika kompleks pergerakan harga emas dan mampu mempertahankan akurasi prediksi setelah proses rekonstruksi akhir.

4.4.4 Denormalisasi Data

Setelah seluruh komponen hasil prediksi LSTM, dari IMF 1 hingga *residual*, dijumlahkan melalui proses *summation* untuk merekonstruksi sinyal harga emas dunia, dilakukan denormalisasi untuk mengembalikan skala data ke bentuk aslinya seperti sebelum normalisasi. Langkah ini memastikan hasil prediksi memiliki satuan yang sesuai dengan data aktual, sehingga dapat dievaluasi secara kuantitatif menggunakan RMSE dan MAPE. Dengan denormalisasi, prediksi dalam skala 0–1 menggunakan rumus Persamaan (16), sehingga interpretasi terhadap akurasi model menjadi lebih valid dan representatif terhadap kondisi nyata.

4.4.5 Evaluasi Model EEMD-LSTM

Setelah diperoleh hasil prediksi gabungan dari seluruh komponen hasil dekomposisi EEMD yang telah diproses menggunakan model LSTM, tahap selanjutnya adalah melakukan evaluasi kinerja model. Evaluasi ini bertujuan untuk mengukur sejauh mana tingkat akurasi dan efektivitas model dalam memprediksi harga emas dunia berdasarkan data historis. Evaluasi model dilakukan pada tahap pelatihan menggunakan data *testing* untuk mengukur kemampuan generalisasi. Pengukuran dilakukan dengan membandingkan hasil prediksi yang telah didenormalisasi dengan data aktual pada skala aslinya. Dua metrik evaluasi yang digunakan adalah *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE), yang menggambarkan besarnya kesalahan prediksi terhadap data aktual. Adapun Tabel 4.6 menyajikan hasil perhitungan RMSE dan MAPE dari prediksi akhir harga emas dunia.

Tabel 4. 6 Hasil Evaluasi Model EEMD-LSTM

Model	RMSE	MAPE (%)
EEMD-LSTM	36,63363	1,38936

Sumber: Diolah Peneliti

Berdasarkan hasil evaluasi pada Tabel 4.6, metode EEMD-LSTM menghasilkan nilai RMSE sebesar 36,63 dan MAPE sebesar 1,39%. Jika dibandingkan dengan rata-rata harga emas dunia sebesar 1.569 USD (Tabel 4.1), kesalahan prediksi sebesar 36 USD hanya sekitar 2,3% dari nilai *mean*, Menurut Tabel 2.2 (halaman 24) nilai RMSE yang kurang dari 10% dari rata-rata data menunjukkan performa model yang sangat baik. Dengan demikian, RMSE sebesar 2,3% ini memperkuat bahwa model mampu menghasilkan prediksi yang akurat.. Nilai MAPE tersebut juga jauh di bawah kriteria maksimum 10% yang menurut Tabel 2.1 (halaman 24) dikategorikan sebagai kemampuan prediksi sangat baik. Artinya, secara persentase, model ini hanya memiliki deviasi sekitar 1,39% dari nilai aktual harga emas dunia. Konsistensi antara RMSE yang rendah dan MAPE yang sangat kecil menunjukkan bahwa model mampu menangkap pola data dengan baik serta memiliki kemampuan generalisasi yang kuat. Dengan demikian, dapat disimpulkan bahwa metode EEMD-LSTM memiliki tingkat akurasi yang tinggi dan andal untuk memprediksi pergerakan harga emas dunia. Selanjutnya, model digunakan untuk analisis prediksi selama 365 hari ke depan berdasarkan hasil rekonstruksi gabungan komponen IMF dengan memanfaatkan struktur jaringan LSTM.

4.4.6 Analisis *Underfitting* dan *Overfitting* Pada Model EEMD-LSTM

Dalam pemodelan EEMD-LSTM, perlu diperhatikan potensi terjadinya *underfitting* maupun *overfitting*. *Underfitting* terjadi ketika model terlalu sederhana sehingga tidak bisa menangkap pola data dengan baik, akibatnya hasil prediksi jelek pada data latihan maupun data uji. Sementara itu, *overfitting* muncul ketika model terlalu menyesuaikan diri dengan data pelatihan sehingga performanya menurun pada data pengujian. Oleh karena itu, evaluasi dilakukan dengan membandingkan nilai kesalahan pada data pelatihan dan pengujian untuk memastikan model berada pada kondisi yang seimbang, yaitu ketika tingkat kesalahan pada kedua data relatif

sama sehingga model tidak mengalami *underfitting* maupun *overfitting*. Hasil perbandingan nilai kesalahan model ditunjukkan pada Tabel 4.7.

Tabel 4. 7 Hasil *Underfitting* dan *Overfitting* Pada Model EEMD-LSTM

Metrik	<i>Train</i>	<i>Test</i>	Rasio	Diagnosis
			<i>Train/Test</i>	
RMSE	37,10709	36,63363	0,987241	Tidak Mengalami <i>Underfitting</i> dan <i>Overfitting</i>
MAPE (%)	2,122958	1,38936	0,654446	Tidak Mengalami <i>Underfitting</i> dan <i>Overfitting</i>

Sumber: Diolah Peneliti

Berdasarkan Tabel 4.7 menunjukkan hasil evaluasi model EEMD-LSTM berdasarkan nilai RMSE dan MAPE pada data pelatihan (*train*) dan data pengujian (*test*). Nilai RMSE pada data pelatihan sebesar 37,11 dan pada data pengujian sebesar 36,63, dengan rasio yang hampir sama yaitu 0,99. Rasio ini diperoleh dengan membandingkan nilai *error* pada data pengujian terhadap *error* pada data pelatihan, sehingga dapat terlihat keseimbangan performa model antara data latih dan uji. Hal ini menandakan bahwa tingkat kesalahan pada data pelatihan dan pengujian relatif seimbang. Demikian pula pada nilai MAPE, diperoleh 2,12% untuk data pelatihan dan 1,39% untuk data pengujian, dengan rasio sebesar 0,65. Kedua nilai tersebut termasuk kategori akurasi tinggi karena berada di bawah 5%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa model mampu mempelajari pola data secara seimbang, di mana performa pada data pelatihan dan pengujian relatif konsisten sehingga tidak menunjukkan indikasi *overfitting* maupun *underfitting*. Selain itu, keseimbangan nilai *error* antara data latih dan uji memperlihatkan bahwa model EEMD-LSTM memiliki kemampuan generalisasi yang baik. Dengan kata lain, model tidak hanya efektif dalam memprediksi data historis, tetapi juga cukup andal untuk diaplikasikan pada data baru dalam memprediksi harga emas dunia.

4.4.7 Prediksi Harga Emas Dunia 365 Hari ke Depan Menggunakan EEMD-LSTM

Setelah model EEMD-LSTM melalui tahap evaluasi dan terbukti memiliki tingkat akurasi yang tinggi berdasarkan nilai RMSE dan MAPE, langkah selanjutnya adalah menggunakannya untuk melakukan prediksi harga emas dunia selama 365 hari ke depan. Proses prediksi ini memanfaatkan pola pergerakan harga yang telah dipelajari model dari data *training*, kemudian diaplikasikan pada data terbaru untuk menghasilkan proyeksi pergerakan harga satu tahun mendatang. Hasil prediksi ini memberikan gambaran tren harga emas dunia di masa depan yang dapat dimanfaatkan sebagai dasar analisis dan pengambilan keputusan strategis. Adapun Gambar 4.5 menyajikan hasil prediksi harga emas dunia selama 365 hari ke depan.



Sumber: Diolah Peneliti

Gambar 4. 5 Prediksi 365 Hari Kedepan Pada Model EEMD-LSTM

Berdasarkan Gambar 4.5, ditampilkan hasil rekonstruksi akhir harga emas dunia menggunakan metode EEMD-LSTM pada periode pelatihan (*train*), pengujian (*test*), serta proyeksi masa depan selama 365 hari ke depan. Garis biru merepresentasikan data aktual pada periode pelatihan, sedangkan garis oranye menunjukkan hasil prediksi pada periode yang sama. Kedua garis tersebut tampak hampir berhimpit, menandakan tingkat akurasi yang sangat tinggi. Pada periode pengujian, garis biru putus-putus menggambarkan data aktual dan garis merah putus-putus menggambarkan hasil prediksi, yang keduanya memperlihatkan kesesuaian pola pergerakan harga emas.

Garis ungu pada bagian akhir grafik merepresentasikan hasil prediksi masa depan, di mana model memproyeksikan adanya lonjakan harga emas yang signifikan hingga mencapai harga di atas 6.000 USD/*troy ounce* sebelum kemudian mengalami fluktuasi. Setelah berakhirnya periode pengujian, terlihat bahwa model memperkirakan tren kenaikan harga yang berlanjut dan bertahan pada kisaran tinggi hingga akhir horizon prediksi 365 hari ke depan. Secara keseluruhan, hasil ini menunjukkan bahwa metode EEMD-LSTM mampu merekonstruksi pola historis dengan akurasi tinggi sekaligus menghasilkan proyeksi masa depan yang konsisten dengan tren jangka Panjang.