

**PERBANDINGAN KINERJA MODEL TFT DAN N-BEATS DALAM
PREDIKSI HARGA EMAS DENGAN INKORPORASI FITUR
MAKROEKONOMI**

(Skripsi)

Oleh

EGY VEDRIYANTO

2117051035



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

PERBANDINGAN KINERJA MODEL TFT DAN N-BEATS DALAM PREDIKSI HARGA EMAS DENGAN INKORPORASI FITUR MAKROEKONOMI

Oleh

EGY VEDRIYANTO

Penelitian ini bertujuan untuk membandingkan kinerja dua model *deep learning* berbasis deret waktu, yaitu *Temporal Fusion Transformer* (TFT) dan N-BEATS, dalam memprediksi harga emas dengan dan tanpa inkorporasi fitur makroekonomi. Latar belakang penelitian ini didasari oleh pentingnya prediksi harga emas dalam dunia investasi dan ekonomi, serta potensi peningkatan akurasi melalui pemanfaatan data *multivariate* yang mencakup indikator makroekonomi seperti GDP, CPI, UNRATE, DXY, dan FEDFUNDS. Kedua model dibangun menggunakan pustaka *Darts* dan dilatih dengan skema *time-series cross-validation*, serta diuji secara *out-of-sample* untuk mengukur kemampuan generalisasi. Proses pengembangan mencakup *tuning hyperparameter*, transformasi data (*MinMax* dan logaritma natural), interpolasi (*linear* dan *spline*), serta seleksi fitur menggunakan *Recursive Feature Elimination* (RFE). Hasil eksperimen menunjukkan bahwa model N-BEATS dengan skenario *multivariate*, interpolasi linear, *scaling MinMax*, dan seleksi fitur RFE (N-BEATS1) mencapai performa terbaik dengan sMAPE sebesar 0.5322, RMSE sebesar 9.4337, dan MAE sebesar 7.0903 pada data uji. Secara keseluruhan, model N-BEATS terbukti lebih unggul dibandingkan TFT, serta lebih konsisten menghasilkan galat prediksi yang rendah. Selain itu, inkorporasi fitur makroekonomi terbukti memberikan dampak positif terhadap akurasi model, khususnya saat dikombinasikan dengan proses seleksi fitur yang tepat.

Kata Kunci: Prediksi Harga Emas, *Time-Series Forecasting*, N-BEATS, *Temporal Fusion Transformer*, Fitur Makroekonomi, *Deep Learning*

ABSTRACT

PERFORMANCE COMPARISON OF TFT AND N-BEATS MODELS IN GOLD PRICE FORECASTING WITH THE INCORPORATION OF MACROECONOMIC FEATURES

By

EGY VEDRIYANTO

This study aims to compare the performance of two time-series deep learning models, Temporal Fusion Transformer (TFT) and N-BEATS, in forecasting gold prices with and without the incorporation of macroeconomic features. The research is motivated by the crucial role of gold price prediction in investment and economic planning, and the potential improvement in accuracy through the use of multivariate data involving macroeconomic indicators such as GDP, CPI, UNRATE, DXY, and FEDFUNDS. Both models were implemented using the Darts library and trained using time-series cross-validation, with out-of-sample testing to evaluate generalization capability. The development process involved hyperparameter tuning, data transformations (MinMax and natural logarithm), interpolation methods (linear and spline), and feature selection using Recursive Feature Elimination (RFE). Experimental results show that the N-BEATS model with multivariate input, linear interpolation, MinMax scaling, and RFE feature selection (N-BEATS1) achieved the best performance, with a sMAPE of 0.5322, RMSE of 9.4337, and MAE of 7.0903 on the test set. Overall, the N-BEATS model outperformed TFT and demonstrated more consistent prediction accuracy. Moreover, the incorporation of macroeconomic features significantly enhanced model performance, especially when combined with proper feature selection.

Keywords: Gold Price Prediction, Time-Series Forecasting, N-BEATS, Temporal Fusion Transformer, Macroeconomic Features, Deep Learning

**PERBANDINGAN KINERJA MODEL TFT DAN N-BEATS DALAM
PREDIKSI HARGA EMAS DENGAN INKORPORASI FITUR
MAKROEKONOMI**

Oleh

EGY VEDRIYANTO

2117051035

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA ILMU KOMPUTER**

Pada

Jurusan Ilmu Komputer

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

Judul Skripsi

**PERBANDINGAN KINERJA MODEL TFT
DAN N-BEATS DALAM PREDIKSI
HARGA EMAS DENGAN INKORPORASI
FITUR MAKROEKONOMI**

Nama Mahasiswa

Egy Vedriyanto

Nomor Pokok Mahasiswa

2117051035

Program Studi

S1 Ilmu Komputer

Jurusan


Ilmu Komputer

Fakultas


Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing




Rahman Taufik, S.Pd., M.Kom.
NIP. 19930627 202203 1 007



Ridho Sholehurrohman, M.Mat.
NIP. 232111970128101

2. Ketua Jurusan Ilmu Komputer




Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001

MENGESAHKAN

1. Tim Penguji


Ketua : **Rahman Taufik, S.Pd., M.Kom.**




Sekretaris : **Ridho Sholehurrohman, M.Mat.**



Penguji Utama : **Tristiyanto, S.Kom., M.I.S., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam




Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: **8 Juli 2025**

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Egy Vedriyanto

NPM : 2117051035

Dengan ini menyatakan bahwa skripsi saya yang berjudul **“Perbandingan Kinerja Model TFT dan N-BEATS dalam Prediksi Harga Emas dengan Inkorporasi Fitur Makroekonomi”** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 21 Juli 2025

Penulis,



Egy Vedriyanto
NPM. 2117051035

RIWAYAT HIDUP



Penulis lahir di Kota Palangkaraya pada tanggal 29 Januari 2004 sebagai anak tunggal dari pasangan Bapak Santo Saputra dan Ibu Eni Yulisniati. Penulis menyelesaikan pendidikan dasar di SD Negeri 2 Pasarmadang pada tahun 2015, kemudian melanjutkan ke SMP Negeri 1 Kotaagung dan lulus pada tahun 2018, serta menamatkan pendidikan menengah atas di SMA Negeri 1 Kotaagung pada tahun 2021. Pada tahun yang sama, penulis diterima sebagai mahasiswa Program Studi S1 Ilmu Komputer di Universitas Lampung melalui jalur undangan (SNMPTN), dan merupakan penerima beasiswa KIP-Kuliah.

Selama menempuh pendidikan di Ilmu Komputer, penulis aktif dalam berbagai kegiatan, baik di dalam maupun di luar Universitas Lampung. Beberapa di antaranya adalah menjadi asisten dosen untuk mata kuliah Dasar-Dasar Pemrograman dan Kecerdasan Buatan, serta aktif dalam Himpunan Mahasiswa Ilmu Komputer (HIMAKOM) FMIPA Unila. Sejak tahun 2021, penulis juga aktif mengikuti kegiatan di Unit Kegiatan Mahasiswa (UKM) *English Society* (Eso) Universitas Lampung. Melalui UKM Eso, penulis pernah dipercaya sebagai *Liaison Officer* pada acara tingkat nasional *Lampung Overland Various English Competition* (LOVE-Comp) tahun 2021, serta menjadi *Tournament Director* pada acara yang sama di tahun 2022.

Selain aktif dalam kegiatan akademik dan organisasi, penulis juga telah meraih beberapa gelar juara dalam kompetisi *Scrabble* tingkat nasional, dan terpilih sebagai salah satu perwakilan Indonesia dalam kejuaraan dunia *Scrabble* pada tahun 2022. Pada tahun 2024, penulis juga terlibat sebagai panitia dalam acara *Lampung National Scrabble Competition* (LNSC) dan *The Nationals 2024*.

PERSEMBAHAN

Segala puji saya panjatkan kepada Allah Subhanahu wa Ta'ala atas segala rahmat-Nya. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu 'Alaihi wa Sallam sehingga saya dapat menyelesaikan skripsi ini.

Skripsi ini saya persembahkan kepada:

Keluarga tercinta serta seluruh rekan yang telah kebersamai dan memberikan dukungan selama proses penyelesaian skripsi ini. Ucapan terima kasih juga saya tujukan kepada diri saya sendiri atas ketekunan dan keberhasilan dalam menyelesaikan pendidikan di Program Studi S1 Ilmu Komputer Universitas Lampung.

MOTTO

“The only true wisdom is in knowing you know nothing.”

- Socrates

“Stay hungry, stay foolish.”

- Steve Jobs

“Saya tidak menanti kesempatan, saya bersiap agar pantas menerimanya.”

- Egy Vedriyanto

SANWACANA

Puji syukur kehadiran Allah Subhanahu wa Ta'ala, yang telah memberikan rahmat dan hidayat-Nya kepada penulis, sehingga penulis dapat menyelesaikan skripsi ini tepat waktu. Shalawat serta salam penulis sanjungkan kepada Nabi Muhammad Shallallahu 'alaihi wa sallam yang penulis harapkan syafaatnya di hari akhir kelak.

Skripsi yang berjudul “Perbandingan Kinerja Model TFT dan N-BEATS dalam Prediksi Harga Emas dengan Inkorporasi Fitur Makroekonomi” ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana pada Program Studi S1 Ilmu Komputer di Universitas Lampung.

Pada kesempatan ini penulis mengucapkan terima kasih kepada semua pihak yang telah berkontribusi dalam penyusunan skripsi ini, yaitu:

1. Kedua orang tua penulis, Bapak Dedi Suharja dan Ibu Eni Yulisniati, yang tidak henti-hentinya memberikan doa, semangat, serta kepercayaan kepada penulis dalam menyelesaikan skripsi ini. Kepada adik penulis, Qiana Nadhira yang selalu memberikan dukungan dan doa.
2. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
3. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D., selaku Ketua Program Studi S1 Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung sekaligus Dosen Pembahas penulis yang telah memberikan kritik dan saran yang bermanfaat bagi penulis dalam menyusun serta menyelesaikan skripsi.

6. Bapak Rahman Taufik, S.Pd., M.Kom., selaku Dosen Pembimbing Utama dan Dosen Pembimbing Akademik penulis yang telah membimbing dan memberikan banyak arahan kepada penulis sehingga penelitian yang penulis lakukan dapat berjalan dengan lancar.
7. Bapak Ridho Sholehurrohman, M.Mat., selaku Dosen Pembimbing Pembantu yang telah memberikan masukan dan saran yang bermakna sehingga penelitian yang penulis lakukan dapat menjadi lebih baik.
8. Bapak/Ibu Dosen dan seluruh Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan membantu dalam berbagai urusan akademik maupun administratif.
9. Sahabat dan teman dekat saya yang tergabung dalam komunitas Atsalsuki dan Triplay serta Vanilla Blue yang telah memberikan banyak dukungan moral dan material yang sangat bermanfaat bagi penulis.
10. Seluruh rekan mahasiswa Ilmu Komputer 2021 yang terlibat dalam proses penelitian skripsi ini yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, oleh karena itu kritik dan saran yang membangun sangat penulis harapkan demi perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi semua pihak.

Bandar Lampung, 21 Juli 2025
Penulis,

Egy Vedriyanto
NPM. 2117051035

DAFTAR ISI

	Halaman
DAFTAR GAMBAR.....	v
DAFTAR TABEL	vii
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	5
1.5 Manfaat Penelitian.....	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terdahulu	6
2.2 Emas	8
2.3 Makroekonomi	9
2.3.1 <i>Inflation</i>	10
2.3.2 <i>Interest Rate</i>	10
2.3.3 <i>Gross Domestic Product (GDP)</i>	10
2.3.4 <i>Unemployment Rate</i>	11
2.3.5 <i>US Dollar Index</i>	11
2.4 <i>Time-Series</i>	11
2.5 <i>Interpolation</i>	12
2.5.1 <i>Linear Interpolation</i>	12
2.5.2 <i>Spline Interpolation</i>	13
2.6 <i>Deep Learning</i>	14
2.7 <i>Transformer</i>	14
2.7.1 <i>Temporal Fusion Transformer</i>	14
2.8 N-BEATS.....	16
2.9 <i>Time-Series Cross Validation</i>	17
2.10 <i>Feature Engineering</i>	17
2.10.1 <i>Recursive Feature Elimination (RFE)</i>	18
2.11 <i>Hyperparameter</i>	18
2.11.1 <i>Epoch</i>	18
2.11.2 <i>Batch Size</i>	19
2.11.3 <i>Optimizer</i>	19
2.11.4 <i>Learning Rate</i>	19
2.11.5 <i>Input dan Output Chunk Length</i>	19
2.11.6 <i>Dropout</i>	20
2.12 Metrik Evaluasi	20

2.12.1 <i>Symmetric Mean Absolute Percentage Error (sMAPE)</i>	20
2.12.2 <i>Root Mean Squared Error (RMSE)</i>	21
2.12.3 <i>Mean Absolute Error (MAE)</i>	21
III. METODOLOGI PENELITIAN	22
3.1 Waktu dan Tempat	22
3.1.1 Waktu Penelitian	22
3.1.2 Tempat Penelitian	22
3.2 Alat dan Bahan	22
3.2.1 Alat Penelitian	22
3.2.2 Bahan Penelitian	23
3.3 Metode	23
3.3.1 <i>Data Collecting</i>	24
3.3.2 <i>Exploratory Data Analysis (EDA)</i>	26
3.3.3 <i>Data Preprocessing</i>	27
3.3.4 <i>Data Splitting</i>	29
3.3.5 <i>Model Building</i>	30
3.3.6 <i>Model Evaluating</i>	33
3.3.7 <i>Model Comparing</i>	35
IV. HASIL DAN PEMBAHASAN	36
4.1 Deskripsi Dataset	36
4.2 <i>Exploratory Data Analysis (EDA)</i>	38
4.3 <i>Data Preprocessing</i>	47
4.3.1 <i>Data Cleaning</i>	47
4.3.2 <i>Data Integration</i>	48
4.3.3 <i>Scaling</i>	49
4.3.4 <i>Feature Engineering</i>	51
4.4 <i>Data Splitting</i>	53
4.5 <i>Model Building dan Evaluasi</i>	54
4.5.1 <i>Temporal Fusion Transformer (TFT)</i>	54
4.5.2 <i>N-BEATS</i>	55
4.5.3 <i>Desain Eksperimen</i>	56
4.5.4 <i>Hyperparameter Tuning</i>	57
4.5.5 <i>Evaluasi Kinerja Model pada Data Latih</i>	62
4.5.6 <i>Evaluasi Kinerja Model pada Data Uji</i>	83
4.6 <i>Analisis Hasil dan Interpretasi</i>	95
4.6.1 <i>Perbandingan Kinerja Model</i>	95
4.6.2 <i>Evaluasi Dampak Inkorporasi Fitur Makroekonomi</i>	97
4.6.3 <i>Perbandingan dengan Penelitian Terdahulu</i>	98
V. SIMPULAN DAN SARAN	102
5.1 <i>Simpulan</i>	102
5.2 <i>Saran</i>	103
DAFTAR PUSTAKA	105

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur TFT.....	15
2. Arsitektur N-BEATS.....	16
3. Alur Penelitian.....	24
4. GOLD <i>Line Plot</i>	39
5. DXY <i>Line Plot</i>	40
6. GDP <i>Line Plot</i>	40
7. CPI <i>Line Plot</i>	41
8. FEDFUNDS <i>Line Plot</i>	41
9. UNRATE <i>Line Plot</i>	41
10. <i>Correlation Heatmap</i>	42
11. <i>Box Plot</i>	45
12. <i>Data Splitting</i>	53
13. Visualisasi Hasil Prediksi Data Latih Model TFT ₁	63
14. Visualisasi Hasil Prediksi Data Latih Model TFT ₂	64
15. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₁	65
16. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₂	66
17. Visualisasi Hasil Prediksi Data Latih Model TFT ₃	67
18. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₃	68
19. Visualisasi Hasil Prediksi Data Latih Model TFT ₄	69
20. Visualisasi Hasil Prediksi Data Latih Model TFT ₅	70
21. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₄	71
22. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₅	72
23. Visualisasi Hasil Prediksi Data Latih Model TFT ₆	73
24. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₆	74
25. Visualisasi Hasil Prediksi Data Latih Model TFT ₇	75

26. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₇	76
27. Visualisasi Hasil Prediksi Data Latih Model TFT ₈	77
28. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₈	78
29. Visualisasi Hasil Prediksi Data Latih Model TFT ₉	79
30. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₉	80
31. Visualisasi Hasil Prediksi Data Latih Model TFT ₁₀	81
32. Visualisasi Hasil Prediksi Data Latih Model N-BEATS ₁₀	82
33. Visualisasi Hasil Prediksi Data Uji Model TFT ₁	84
34. Visualisasi Hasil Prediksi Data Uji Model TFT ₂	84
35. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₁	85
36. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₂	85
37. Visualisasi Hasil Prediksi Data Uji Model TFT ₃	86
38. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₃	86
39. Visualisasi Hasil Prediksi Data Uji Model TFT ₄	87
40. Visualisasi Hasil Prediksi Data Uji Model TFT ₅	87
41. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₄	88
42. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₅	88
43. Visualisasi Hasil Prediksi Data Uji Model TFT ₆	89
44. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₆	89
45. Visualisasi Hasil Prediksi Data Uji Model TFT ₇	90
46. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₇	90
47. Visualisasi Hasil Prediksi Data Uji Model TFT ₈	91
48. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₈	91
49. Visualisasi Hasil Prediksi Data Uji Model TFT ₉	92
50. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₉	92
51. Visualisasi Hasil Prediksi Data Uji Model TFT ₁₀	93
52. Visualisasi Hasil Prediksi Data Uji Model N-BEATS ₁₀	93

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu.....	6
2. <i>Hyperparameter</i> untuk Model TFT	31
3. <i>Hyperparameter</i> untuk Model N-BEATS	32
4. Rangkuman <i>Dataset</i>	37
5. <i>Gold Closing Price Raw Data</i>	38
6. <i>CPI Raw Data</i>	38
7. Statistik Deskriptif	43
8. <i>Missing Values</i>	44
9. Uji Stasioneritas	46
10. Evaluasi Kebutuhan <i>Scaling</i>	46
11. Sampel Data Sebelum dan Sesudah Interpolasi	48
12. Sampel Data Hasil Integrasi.....	49
13. Sampel Data Hasil <i>Min-Max Scaling</i>	50
14. Sampel Data Hasil Transformasi Logaritma Natural (ln)	51
15. Sampel Final <i>Dataset</i> Hasil RFE	52
16. Ringkasan Skenario Eksperimen	56
17. <i>Hyperparameter Tuning</i> Model TFT ₁	58
18. <i>Hyperparameter Tuning</i> Model N-BEATS ₁	60
19. Konfigurasi <i>Hyperparameter</i> Terbaik Model TFT	61
20. Konfigurasi <i>Hyperparameter</i> Terbaik Model N-BEATS	62
21. Evaluasi Kinerja Model TFT ₁ pada Data Latih.....	63
22. Evaluasi Kinerja Model TFT ₂ pada Data Latih.....	65
23. Evaluasi Kinerja Model N-BEATS ₁ Pada Data Latih	66
24. Evaluasi Kinerja Model N-BEATS ₂ pada Data Latih	67
25. Evaluasi Kinerja Model TFT ₃ pada Data Latih.....	68

26. Evaluasi Kinerja Model N-BEATS ₃ pada Data Latih	69
27. Evaluasi Kinerja Model TFT ₄ pada Data Latih.....	70
28. Evaluasi Kinerja Model TFT ₅ pada Data Latih.....	71
29. Evaluasi Kinerja Model N-BEATS ₄ pada Data Latih	72
30. Evaluasi Kinerja Model N-BEATS ₅ pada Data Latih	73
31. Evaluasi Kinerja Model TFT ₆ pada Data Latih.....	74
32. Evaluasi Kinerja Model N-BEATS ₆ pada Data Latih	75
33. Evaluasi Kinerja Model TFT ₇ pada Data Latih.....	76
34. Evaluasi Kinerja Model N-BEATS ₇ pada Data Latih	77
35. Evaluasi Kinerja Model TFT ₈ pada Data Latih.....	78
36. Evaluasi Kinerja Model N-BEATS ₈ pada Data Latih	79
37. Evaluasi Kinerja Model TFT ₉ pada Data Latih.....	80
38. Evaluasi Kinerja Model N-BEATS ₉ pada Data Latih	81
39. Evaluasi Kinerja Model TFT ₁₀ pada Data Latih	82
40. Evaluasi Kinerja Model N-BEATS ₁₀ pada Data Latih.....	83
41. Evaluasi Kinerja Model pada Data Uji	94
42. Perbandingan Kinerja Model Berdasarkan Evaluasi Data Uji.....	95
43. Perbandingan Kinerja Model terhadap Penelitian Terdahulu	100

I. PENDAHULUAN

1.1 Latar Belakang

Emas telah lama dianggap sebagai salah satu instrumen investasi paling populer dan penting di berbagai negara, termasuk Indonesia. Selain berfungsi sebagai alat investasi dan pelindung nilai, emas juga sering digunakan sebagai instrumen lindung nilai terhadap inflasi dan ketidakstabilan ekonomi (Liang *et al.*, 2021). Sebagai komoditas bernilai tinggi, harga emas dipengaruhi oleh berbagai faktor ekonomi global, seperti kebijakan moneter, tingkat inflasi, suku bunga, dan indikator ekonomi lainnya. Fluktuasi harga emas yang dinamis dan sulit diprediksi menuntut adanya pendekatan analitis yang mampu menghasilkan prediksi dengan tingkat akurasi tinggi. Oleh karena itu, diperlukan pendekatan berbasis data yang dapat menggabungkan berbagai faktor tersebut untuk memprediksi pergerakan harga emas secara akurat.

Faktor-faktor makroekonomi memainkan peran penting dalam memengaruhi harga emas, terutama indikator-indikator dari perekonomian Amerika Serikat. Mengingat emas diperdagangkan dalam denominasi dolar AS, perubahan nilai tukar dolar dapat secara langsung memengaruhi harga emas di pasar internasional (Fang *et al.*, 2018). Beberapa indikator utama yang sering digunakan dalam analisis harga emas meliputi tingkat inflasi, suku bunga, produk domestik bruto (GDP), tingkat pengangguran, dan indeks dolar AS (DXY). Misalnya, kenaikan tingkat inflasi cenderung meningkatkan harga emas karena investor mencari aset aman yang mampu melindungi nilai investasi terhadap inflasi. Di sisi lain, kenaikan suku bunga umumnya menekan harga emas karena membuatnya kurang menarik bagi investor yang mengharapkan imbal hasil tetap (Yurtsever, 2021).

Salah satu metode prediksi yang populer adalah pendekatan berbasis model *time-series*. Dalam hal ini, model *deep learning* telah terbukti unggul dalam menangkap pola kompleks dari data deret waktu dibandingkan model statistik tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) (Salim & Djunaidy, 2024). Model seperti *Temporal Fusion Transformer* (TFT) dan *Neural Basis Expansion Analysis for Time Series* (N-BEATS) terbukti sebagai solusi mutakhir untuk prediksi *time-series* karena kemampuannya menangkap pola temporal yang kompleks dan hubungan antar fitur data secara efektif (Lim *et al.*, 2021; Oreshkin *et al.*, 2020).

TFT dirancang khusus untuk menangani data *time-series* multivariat dengan mekanisme *attention* yang memungkinkan model memprioritaskan variabel yang paling relevan, termasuk data makroekonomi. Model ini unggul dalam menangkap hubungan jangka panjang sekaligus memberikan interpretasi mendalam tentang pentingnya setiap fitur input (Lim *et al.*, 2021). Di sisi lain, N-BEATS menggunakan pendekatan *basis expansion* untuk menangkap pola tren dan musiman. Meskipun lebih sederhana, N-BEATS telah menunjukkan performa luar biasa dalam prediksi *time-series* tanpa bergantung pada arsitektur RNN atau *transformer* (Oreshkin *et al.*, 2020).

Baik TFT maupun N-BEATS memiliki keunggulan masing-masing. TFT unggul dalam interpretabilitas, terutama untuk data multivariat dengan fitur kompleks, sementara N-BEATS lebih efisien dalam hal komputasi dan cocok untuk menangkap pola data jangka pendek dan musiman (Xu *et al.*, 2024). Namun, perbandingan performa kedua model ini dalam konteks prediksi harga emas dengan inkorporasi fitur makroekonomi masih memerlukan penelitian lebih lanjut untuk menentukan model mana yang lebih unggul dalam menghasilkan prediksi yang akurat.

Penggabungan data makroekonomi dengan model *deep learning* memberikan pendekatan yang lebih komprehensif dalam prediksi harga emas. Dengan menambahkan data makroekonomi sebagai fitur, prediksi yang dihasilkan diharapkan dapat mencerminkan pengaruh kondisi ekonomi global secara lebih akurat. Namun, penelitian mengenai pengaruh langsung penambahan fitur makroekonomi terhadap akurasi model prediksi harga emas masih terbatas. Sebagian besar studi terdahulu, seperti penelitian Fang *et al.* (2018), hanya menyoroti hubungan antara variabel makroekonomi dengan volatilitas atau tren harga emas tanpa secara spesifik membahas bagaimana variabel-variabel tersebut memengaruhi akurasi model prediktif berbasis *deep learning*.

Dalam studi ini, peneliti bertujuan untuk melakukan analisis perbandingan kinerja model *Temporal Fusion Transformer* (TFT) dan *Neural Basis Expansion Analysis for Time Series* (N-BEATS) dalam memprediksi harga emas dengan inkorporasi fitur-fitur makroekonomi. Penelitian ini mencoba mengevaluasi kinerja kedua model dalam hal akurasi prediksi dan efektivitas dalam menangani data makroekonomi. Selain itu, penelitian ini juga bertujuan untuk menjawab pertanyaan apakah penambahan data makroekonomi sebagai fitur tambahan mampu meningkatkan akurasi prediksi pada kedua model, serta model mana yang menunjukkan performa lebih baik dalam menghasilkan prediksi harga emas yang andal.

Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode prediksi harga emas berbasis *deep learning*, khususnya dalam konteks pemanfaatan data makroekonomi sebagai fitur tambahan. Hasil penelitian ini diharapkan tidak hanya memberikan wawasan bagi para peneliti di bidang ilmu komputer dan keuangan, tetapi juga bagi para pelaku pasar yang memerlukan prediksi harga emas yang akurat sebagai dasar dalam pengambilan keputusan investasi.

1.2 Rumusan Masalah

Dalam prediksi harga emas berbasis data deret waktu, model *deep learning* seperti TFT dan N-BEATS telah menunjukkan kemampuan yang kuat dalam menangkap pola temporal dan hubungan antar variabel. Namun, sejauh ini belum banyak penelitian yang mengeksplorasi bagaimana kedua model ini dapat diterapkan secara khusus untuk prediksi harga emas dengan mempertimbangkan variabel makroekonomi, seperti tingkat inflasi, suku bunga, dan indeks dolar AS. Berdasarkan hal ini, penelitian ini merumuskan masalah sebagai berikut:

1. Bagaimana membangun model TFT dan N-BEATS untuk prediksi harga emas?
2. Bagaimana teknik yang digunakan untuk mengintegrasikan fitur makroekonomi ke dalam model prediksi harga emas?
3. Bagaimana kinerja model TFT dan N-BEATS dengan inkorporasi fitur makroekonomi?
4. Model manakah yang menunjukkan kinerja lebih unggul dalam konteks tingkat kesalahan prediksi?

1.3 Batasan Masalah

Penelitian ini memiliki beberapa batasan yang perlu diperhatikan untuk memfokuskan ruang lingkup dan menghindari perluasan yang tidak diperlukan. Batasan-batasan tersebut adalah sebagai berikut:

1. Penelitian ini hanya menggunakan dua model prediksi, yaitu *Temporal Fusion Transformer* (TFT) dan *Neural Basis Expansion Analysis for Time Series* (N-BEATS).
2. Variabel makroekonomi yang digunakan sebagai fitur dalam model prediksi terbatas pada data dari perekonomian Amerika Serikat, meliputi inflasi, tingkat suku bunga, GDP, tingkat pengangguran, dan indeks dolar AS.
3. Data yang digunakan mencakup rentang waktu dari Januari 2014 hingga April 2018. Seluruh *dataset* diperoleh melalui API dari *Yahoo Finance* (YFinance) dan *Federal Reserve Economic Data* (FRED).

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mengevaluasi kinerja model TFT dan N-BEATS dalam memprediksi harga emas dengan penambahan fitur makroekonomi, serta membandingkan kedua model dalam hal performa. Selain itu, penelitian ini juga bertujuan untuk menentukan apakah inkorporasi data makroekonomi sebagai fitur tambahan dapat meningkatkan akurasi prediksi model.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi harga emas yang lebih akurat dan andal, khususnya dengan memanfaatkan variabel-variabel makroekonomi sebagai fitur tambahan. Bagi akademisi, penelitian ini diharapkan dapat menjadi referensi dalam studi terkait prediksi harga komoditas berbasis *deep learning*. Bagi para investor dan pelaku pasar, penelitian ini diharapkan dapat menjadi dasar pertimbangan dalam pengambilan keputusan investasi, terutama dalam konteks kondisi ekonomi yang dinamis.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini dilandaskan oleh beberapa studi terkait prediksi harga emas dan penggunaan model prediktif berbasis *time-series* yang telah dilakukan oleh peneliti sebelumnya. Rangkuman dari beberapa penelitian terdahulu yang menjadi acuan dalam studi ini dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu

Penulis (Tahun)	Judul Penelitian	Metode	Hasil
Livieris et al. (2020)	<i>A CNN-LSTM model for gold price time-series forecasting</i>	CNN-LSTM (hybrid model combining Convolutional Neural Networks and LSTM)	MAE: 0.0079 RMSE: 0.0082
Farooq et al. (2024)	<i>Interpretable multi-horizon time series forecasting of cryptocurrencies by leverage temporal fusion transformer</i>	ADE-TFT (Temporal Fusion Transformer dengan Adaptive Differential Evolution)	RMSE: 167.12 MAPE: 23.1734% MSE: 178.68
Oreshkin et al. (2020)	<i>N-BEATS: Neural Basis Expansion Analysis for Interpretable Time Series Forecasting</i>	N-BEATS (Generic and Interpretable)	sMAPE: 11.168 OWA: 0.797

Penelitian yang dilakukan oleh Livieris et al. (2020) mengusulkan model *hybrid deep learning* bernama CNN-LSTM untuk memprediksi harga emas dan pergerakannya berdasarkan data deret waktu. Model ini menggabungkan keunggulan *Convolutional Neural Networks* (CNN) dalam mengekstraksi fitur dari data deret waktu dan *Long Short-Term Memory* (LSTM) dalam menangkap dependensi jangka pendek dan panjang. *Dataset* yang digunakan adalah harga emas harian dalam USD dari *Yahoo Finance* yang mencakup periode Januari 2014 hingga April 2018, dengan pembagian data menjadi set pelatihan (Januari 2014 -

Desember 2017) dan set pengujian (Januari 2018 - April 2018). Model CNN-LSTM terdiri dari dua versi, yaitu CNN-LSTM₁ dan CNN-LSTM₂, yang berbeda dalam jumlah filter pada lapisan konvolusional dan unit LSTM. Evaluasi dilakukan terhadap model LSTM, *Support Vector Regression* (SVR), dan *Feed-Forward Neural Network* (FFNN) menggunakan metrik *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) untuk masalah regresi (prediksi harga emas), serta *akurasi*, *AUC*, *sensitivity*, dan *specificity* untuk masalah klasifikasi (prediksi arah pergerakan harga emas). Hasil penelitian menunjukkan bahwa CNN-LSTM₂ memberikan performa terbaik dalam prediksi harga emas dengan MAE terendah sebesar 0.0079 dan RMSE sebesar 0.0082 untuk horizon peramalan 4 hari, sementara CNN-LSTM₁ menunjukkan performa terbaik dalam prediksi arah pergerakan harga emas dengan akurasi 56.81% dan AUC sebesar 0.577 untuk horizon peramalan 6 hari. Penelitian ini menyimpulkan bahwa kombinasi CNN dan LSTM memberikan peningkatan signifikan dalam performa prediksi dibandingkan dengan model LSTM standalone atau model *machine learning* tradisional seperti SVR dan FFNN.

Penelitian yang dilakukan oleh Farooq *et al.* (2024) mengusulkan model *Deep Learning-Enhanced Temporal Fusion Transformer* (ADE-TFT) untuk memprediksi pergerakan harga *Bitcoin* dengan memanfaatkan data deret waktu dan analisis sentimen pasar. *Dataset* yang digunakan dalam penelitian ini mencakup data transaksi harian *Bitcoin* dari periode 17 September 2014 hingga 25 November 2022, yang terdiri dari 4.857.377 catatan dengan berbagai atribut seperti harga, volume, dan waktu. Data tersebut dibagi menjadi set pelatihan (2014-2019), validasi (2020-2022), dan pengujian (2022). Metode yang digunakan adalah *Temporal Fusion Transformer* (TFT) yang dikombinasikan dengan *Adaptive Differential Evolution* (ADE) untuk optimasi hiperparameter. Model ini dirancang untuk menangkap ketergantungan temporal jangka pendek dan panjang dengan memanfaatkan mekanisme *attention* dan *gated residual network*. Hasil evaluasi menunjukkan bahwa model ADE-TFT dengan konfigurasi *hidden layer* 8 ($h=8$) menghasilkan performa terbaik dengan RMSE sebesar 167.12, MAPE sebesar 23.1734%, dan MSE sebesar 178.68, mengungguli model-model tradisional seperti ARIMA, LSTM, dan GRU. Penelitian ini juga menyoroti

pentingnya analisis sentimen dan normalisasi data dalam meningkatkan akurasi prediksi, meskipun kompleksitas model dan ketersediaan data yang terbatas menjadi tantangan utama.

Penelitian yang dilakukan oleh Oreshkin *et al.* (2020) mengusulkan model *Neural Basis Expansion Analysis for Interpretable Time Series Forecasting* (N-BEATS) untuk memprediksi deret waktu univariat. *Dataset* yang digunakan dalam penelitian ini mencakup tiga *dataset* utama, yaitu M4, M3, dan *tourism*. *Dataset* M4 terdiri dari 100.000 deret waktu dengan berbagai frekuensi (tahunan, triwulanan, bulanan, mingguan, harian, dan per jam) yang berasal dari berbagai domain seperti keuangan, industri, dan makroekonomi. *Dataset* M3 terdiri dari 3.003 deret waktu dengan frekuensi serupa, sedangkan *dataset tourism* terdiri dari 1.311 deret waktu dengan frekuensi tahunan, triwulanan, dan bulanan. Metode yang digunakan adalah N-BEATS, yang dirancang dengan arsitektur *deep neural network* berbasis *residual links* dan *fully-connected layers*. Model ini memiliki dua konfigurasi: *generic* (N-BEATS-G) yang tidak menggunakan komponen khusus deret waktu, dan *interpretable* (N-BEATS-I) yang dirancang untuk menghasilkan output yang dapat diinterpretasi seperti tren dan musiman. Hasil evaluasi menunjukkan bahwa N-BEATS mengungguli model-model statistik dan hibrid sebelumnya, dengan peningkatan akurasi sebesar 11% dibandingkan *benchmark* statistik dan 3% dibandingkan pemenang kompetisi M4. Metrik evaluasi yang digunakan adalah sMAPE dan OWA, di mana N-BEATS-G mencapai sMAPE sebesar 11.168 dan OWA sebesar 0.797 pada *dataset* M4, sementara N-BEATS-I mencapai sMAPE sebesar 11.174 dan OWA sebesar 0.798. Penelitian ini menyimpulkan bahwa arsitektur *DL* murni seperti N-BEATS dapat menghasilkan performa yang sangat baik tanpa memerlukan komponen khusus deret waktu atau rekayasa fitur, serta dapat diadaptasi untuk menghasilkan output yang interpretabel tanpa kehilangan akurasi yang signifikan.

2.2 Emas

Emas telah lama dianggap sebagai salah satu aset paling berharga dalam sejarah manusia. Sejak zaman kuno, emas digunakan sebagai alat tukar dan simbol

kekayaan. Pada abad ke-19, sistem standar emas (*gold standard*) menjadi dasar sistem moneter internasional, di mana nilai mata uang suatu negara dijamin oleh cadangan emas. Meskipun sistem ini telah ditinggalkan sejak 1970-an, emas tetap memainkan peran penting dalam ekonomi global, terutama sebagai instrumen investasi dan lindung nilai terhadap inflasi (Beckmann & Czudaj, 2013).

Harga emas dipengaruhi oleh berbagai faktor, baik fundamental maupun non-fundamental. Faktor fundamental mencakup permintaan dan penawaran emas, suku bunga, dan inflasi. Di sisi lain, faktor non-fundamental seperti sentimen pasar dan kondisi geopolitik juga memiliki dampak signifikan terhadap harga emas. Misalnya, selama krisis keuangan global 2007 dan pandemi COVID-19, harga emas mengalami lonjakan signifikan karena investor berbondong-bondong membeli emas sebagai *safe haven asset* (Salim & Djunaidy, 2024).

Karakteristik harga emas yang unik, seperti volatilitas tinggi dan pola musiman, membuat prediksi harganya menjadi tantangan yang kompleks. Misalnya, harga emas cenderung meningkat selama periode ketidakpastian ekonomi, seperti resesi atau konflik geopolitik. Selain itu, permintaan emas untuk perhiasan juga menunjukkan pola musiman, dengan peningkatan signifikan selama musim pernikahan di India dan China (Zhang et al., 2015). Oleh karena itu, pemahaman mendalam tentang faktor-faktor yang memengaruhi harga emas sangat penting untuk melakukan prediksi yang akurat.

2.3 Makroekonomi

Variabel makroekonomi memainkan peran penting dalam memengaruhi harga emas. Faktor-faktor seperti inflasi, suku bunga, GDP, tingkat pengangguran, dan nilai tukar mata uang dapat menyebabkan fluktuasi harga emas yang signifikan. Pemahaman tentang hubungan antara variabel makroekonomi dan harga emas sangat penting untuk mengembangkan model prediksi yang akurat.

2.3.1 *Inflation*

Inflasi adalah salah satu faktor utama yang memengaruhi harga emas. Emas sering dianggap sebagai *hedge* terhadap inflasi karena nilainya cenderung meningkat ketika daya beli mata uang menurun. Misalnya, selama periode inflasi tinggi pada 1970-an, harga emas mengalami kenaikan signifikan karena investor mencari perlindungan dari penurunan nilai mata uang (Ghosh *et al.*, 2004). Selain itu, emas juga dianggap sebagai aset yang relatif stabil dalam menghadapi gejolak ekonomi, sehingga sering menjadi pilihan utama investor selama periode ketidakpastian (Beckmann *et al.*, 2015).

2.3.2 *Interest Rate*

Suku bunga memiliki hubungan negatif dengan harga emas. Ketika suku bunga naik, investor cenderung mengalihkan dana mereka ke instrumen yang memberikan imbal hasil lebih tinggi, seperti obligasi atau deposito. Sebaliknya, ketika suku bunga turun, emas menjadi lebih menarik karena tidak ada alternatif investasi berbunga tinggi yang lebih menguntungkan (Yurtsever, 2021). Selain itu, kebijakan moneter yang longgar (*quantitative easing*) oleh bank sentral juga dapat mendorong kenaikan harga emas karena meningkatkan likuiditas di pasar (Ghosh *et al.*, 2004).

2.3.3 *Gross Domestic Product (GDP)*

Pertumbuhan ekonomi yang tinggi, yang tercermin dari peningkatan GDP, dapat mengurangi permintaan emas sebagai *safe haven asset*. Namun, pertumbuhan ekonomi yang terlalu cepat juga dapat memicu inflasi, yang pada gilirannya mendorong kenaikan harga emas (Chirwa & Odhiambo, 2020). Misalnya, selama periode pertumbuhan ekonomi yang pesat di China pada awal 2000-an, permintaan emas untuk industri dan investasi meningkat secara signifikan, sehingga mendorong kenaikan harga global (Zhang *et al.*, 2015).

2.3.4 *Unemployment Rate*

Tingkat pengangguran yang tinggi sering kali menjadi indikator ketidakstabilan ekonomi, yang dapat meningkatkan permintaan emas sebagai aset *safe haven*. Misalnya, selama resesi ekonomi, investor cenderung beralih ke emas untuk melindungi kekayaan mereka (Beckmann & Czudaj, 2013). Selain itu, tingkat pengangguran yang tinggi juga dapat mengurangi daya beli masyarakat, sehingga mengurangi permintaan emas untuk perhiasan. Namun, dalam jangka panjang, ketidakstabilan ekonomi cenderung mendorong kenaikan harga emas karena investor mencari perlindungan dari risiko inflasi dan gejolak pasar (Fang *et al.*, 2018).

2.3.5 *US Dollar Index*

Indeks Dolar AS (DXY) memiliki hubungan terbalik dengan harga emas. Ketika nilai dolar AS menguat, harga emas cenderung turun karena emas menjadi lebih mahal bagi pemegang mata uang lain. Sebaliknya, ketika dolar AS melemah, harga emas cenderung naik (Baiardi *et al.*, 2020). Misalnya, selama periode pelemahan dolar AS pada 2020, harga emas mencapai rekor tertinggi karena investor global mencari alternatif investasi selain dolar AS. Selain itu, dolar AS yang kuat juga dapat mengurangi daya saing ekspor emas dari negara-negara penghasil utama, sehingga memengaruhi pasokan global (Salim & Djunaidy, 2024).

2.4 *Time-Series*

Data *time-series* adalah kumpulan data yang direkam dalam interval waktu tertentu, seperti harian, bulanan, atau tahunan. Data *time-series* memiliki karakteristik unik, seperti tren, musiman, dan stasioneritas, yang perlu diperhatikan dalam analisis dan pemodelan. Misalnya, data harga emas sering kali menunjukkan pola musiman, dengan peningkatan permintaan selama musim pernikahan di India dan China (Zhang *et al.*, 2015).

Teknik *preprocessing* data *time-series*, seperti normalisasi dan *differencing*, sering digunakan untuk mempersiapkan data sebelum dimasukkan ke dalam model. Normalisasi *min-max* atau *z-score* dapat menyamakan skala data, sementara *differencing* membantu menghilangkan tren dalam data yang tidak stasioner (Athanasopoulos *et al.*, 2011). Selain itu, teknik seperti dekomposisi *time-series* juga dapat digunakan untuk memisahkan komponen tren, musiman, dan *residual* dalam data.

2.5 Interpolation

Interpolation adalah teknik yang digunakan untuk mengisi data yang hilang dalam *dataset*. Dalam konteks data *time-series*, *interpolation* sangat penting karena data yang hilang dapat mengganggu analisis dan pemodelan.

2.5.1 Linear Interpolation

Linear interpolation adalah metode sederhana yang mengisi data yang hilang dengan membuat garis lurus antara dua titik data yang diketahui. Misalnya, jika harga emas pada hari Senin adalah \$1.800 dan pada hari Rabu adalah \$1.850, *linear interpolation* dapat digunakan untuk mengestimasi harga emas pada hari Selasa sebagai \$1.825 (Lepot *et al.*, 2017). Lengkapnya rumus *linear interpolation* dapat didefinisikan sebagai berikut.

$$y = y_1 + \frac{(x - x_1)}{(x_2 - x_1)} \times (y_2 - y_1)$$

Pada rumus *linear interpolation* diatas terdapat x sebagai posisi (*index*) yang ingin dihitung, x_1 sebagai posisi awal, x_2 sebagai posisi akhir, y_1 sebagai nilai awal, y_2 sebagai nilai akhir, dan y merupakan nilai yang ingin dihitung.

Meskipun metode ini sederhana dan mudah diimplementasikan, *linear interpolation* memiliki keterbatasan karena mengasumsikan hubungan linear antara titik data, yang mungkin tidak selalu sesuai dengan realitas.

2.5.2 Spline Interpolation

Spline Interpolation merupakan metode interpolasi yang menggunakan fungsi polinomial bertingkat (*piecewise polynomial*) untuk menghubungkan titik-titik data secara halus (Lepot *et al.*, 2017). Tidak seperti *linear interpolation* yang hanya menggunakan garis lurus antar dua titik, *spline interpolation* membagi seluruh rentang data menjadi beberapa segmen dan masing-masing segmen diinterpolasi menggunakan polinomial, biasanya derajat tiga (*cubic spline*). Hal ini memungkinkan hasil interpolasi menjadi lebih mulus dan realistis, terutama pada data yang memiliki perubahan tren atau fluktuasi yang kompleks.

Sebagai contoh, jika diketahui nilai inflasi pada bulan Januari, Maret, dan Mei, maka *spline interpolation* dapat digunakan untuk mengestimasi nilai inflasi pada bulan Februari dan April dengan mempertimbangkan kelengkungan alami dari data, bukan sekadar garis lurus. Rumus umum dari *cubic spline interpolation* adalah sebagai berikut:

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3$$

Dengan keterangan $S_i(x)$ sebagai nilai hasil interpolasi pada segmen ke- i , x_i titik awal dari segmen ke- i , a_i nilai fungsi pada x_i , serta b_i , c_i , dan d_i merupakan koefisien *spline* yang ditentukan berdasarkan sistem persamaan dari nilai dan turunan pada titik-titik data. Koefisien ini dihitung sedemikian rupa agar fungsi *spline* dapat melewati seluruh titik data (*continuity*) serta memiliki turunan pertama dan kedua yang kontinu antar segmen.

Spline interpolation banyak digunakan pada kasus *time-series* karena mampu mempertahankan bentuk alami data dan menghindari ketidaktepatan estimasi akibat perubahan mendadak yang tidak wajar. Dengan demikian, metode ini cocok digunakan untuk interpolasi data makroekonomi seperti suku bunga atau tingkat pengangguran yang cenderung berubah secara non-linear.

2.6 Deep Learning

Deep learning adalah cabang dari *machine learning* yang menggunakan jaringan saraf tiruan (*neural networks*) untuk mempelajari pola kompleks dalam data. *Deep learning* telah menunjukkan performa yang sangat baik dalam berbagai aplikasi, termasuk pengenalan gambar, pemrosesan bahasa alami, dan prediksi *time-series* (Schmidhuber, 2015).

Salah satu keunggulan *deep learning* adalah kemampuannya untuk menangkap hubungan non-linear dalam data. Misalnya, model *deep learning* seperti LSTM (*Long Short-Term Memory*) dan GRU (*Gated Recurrent Unit*) telah digunakan secara luas dalam prediksi *time-series* karena kemampuannya untuk mempelajari ketergantungan jangka panjang dalam data (Greff *et al.*, 2017). Selain itu, model *deep learning* juga dapat mengintegrasikan berbagai jenis data, seperti data numerik dan kategorikal, sehingga cocok untuk prediksi harga emas yang dipengaruhi oleh banyak faktor (Lim *et al.*, 2021).

2.7 Transformer


Transformer adalah model *deep learning* yang awalnya dikembangkan untuk tugas pemrosesan bahasa alami (NLP), tetapi kini telah diadaptasi untuk berbagai aplikasi, termasuk prediksi *time-series*. Model ini menggunakan mekanisme *attention* untuk menangkap hubungan antar fitur dalam data, sehingga sangat efektif dalam menangani data dengan ketergantungan jangka panjang (Vaswani *et al.*, 2017).

2.7.1 Temporal Fusion Transformer

Temporal Fusion Transformer (TFT) adalah varian *transformer* yang dirancang khusus untuk prediksi *time-series* multivariabel. Model ini menggabungkan mekanisme *multi-head attention* dengan kemampuan untuk mengintegrasikan variabel statis, seperti data makroekonomi, sehingga sangat cocok untuk prediksi harga emas yang dipengaruhi oleh banyak faktor (Lim *et al.*, 2021).

Salah satu keunggulan TFT adalah kemampuannya untuk menangkap pola temporal yang kompleks dalam data *time-series*. Misalnya, TFT dapat mengidentifikasi bahwa perubahan suku bunga memiliki dampak lebih besar terhadap harga emas daripada variabel lain seperti tingkat pengangguran. Selain itu, TFT juga memberikan interpretabilitas yang tinggi, sehingga memungkinkan analisis mendalam tentang faktor-faktor yang memengaruhi prediksi (Lim *et al.*, 2021).

Arsitektur TFT terdiri dari tiga komponen utama yaitu *encoder*, *decoder*, dan *static covariates*. *Encoder* bertugas menangkap pola temporal dalam data historis, sementara *decoder* menghasilkan prediksi berdasarkan informasi yang dipelajari oleh *encoder*. *Static covariates* memungkinkan TFT untuk mengintegrasikan variabel makroekonomi seperti suku bunga dan inflasi, yang sangat penting dalam prediksi harga emas (Lim *et al.*, 2021). Arsitektur TFT dapat dilihat pada Gambar 1.




Gambar 1. Arsitektur TFT (Lim *et al.*, 2021).

2.8 N-BEATS

N-BEATS (*Neural Basis Expansion Analysis for Time Series*) adalah model *deep learning* yang dirancang khusus untuk prediksi *time-series*. Berbeda dengan model lain yang menggunakan arsitektur RNN atau *transformer*, N-BEATS menggunakan pendekatan berbasis blok (*block-based architecture*) yang memungkinkan model untuk mempelajari pola tren dan musiman secara terpisah (Oreshkin *et al.*, 2020).

Salah satu keunggulan N-BEATS adalah kemampuannya untuk menangani data univariat dan multivariat dengan efisiensi komputasi yang tinggi. Misalnya, N-BEATS dapat memprediksi harga emas dengan akurasi yang lebih baik dibandingkan model tradisional seperti ARIMA dan LSTM, terutama pada *dataset* dengan variabilitas tinggi (Oreshkin *et al.*, 2020).

Arsitektur N-BEATS terdiri dari beberapa blok yang saling terhubung, di mana setiap blok bertanggung jawab untuk mempelajari pola tertentu dalam data, seperti tren atau musiman. Setiap blok terdiri dari dua bagian utama: *backcast* dan *forecast*. *Backcast* bertugas menganalisis pola historis, sementara *forecast* menghasilkan prediksi masa depan (Oreshkin *et al.*, 2020). Arsitektur N-BEATS dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur N-BEATS (Oreshkin *et al.*, 2020).

2.9 Time-Series Cross Validation

Cross validation adalah teknik yang digunakan untuk mengevaluasi performa model dengan membagi *dataset* menjadi beberapa subset. Teknik ini sangat penting untuk memastikan bahwa model tidak *overfitting* terhadap *data training*.

Time-Series Cross Validation (TSCV) adalah varian *cross validation* yang dirancang khusus untuk data *time-series*. Teknik ini membagi *dataset* secara berurutan, sehingga model dievaluasi pada data masa depan yang tidak digunakan selama pelatihan (Ramos & Oliveira, 2016). Misalnya, jika *dataset* terdiri dari data harga emas dari 2010 hingga 2020, *time-series cross validation* dapat membagi *dataset* menjadi beberapa periode, seperti 2010-2015 untuk *training* dan 2016-2020 untuk validasi.

2.10 Feature Engineering

Feature engineering adalah proses mengubah data mentah menjadi fitur yang lebih bermakna dan relevan untuk digunakan dalam model *machine learning*. Tahap ini sangat krusial dalam meningkatkan kinerja model, terutama dalam prediksi *time-series* di mana pola historis dan hubungan antar variabel sangat kompleks. Secara umum, *feature engineering* dapat dibagi menjadi tiga kategori utama, yaitu *feature extraction*, *feature transformation*, dan *feature selection*.

Feature extraction adalah proses menciptakan fitur baru dari data mentah yang ada dengan tujuan untuk menonjolkan informasi penting. Teknik ini biasanya dilakukan untuk menyaring representasi data menjadi lebih informatif tanpa mengubah maknanya. Contoh dari *feature extraction* adalah penggunaan *Principal Component Analysis* (PCA) untuk mengurangi dimensi data sambil mempertahankan variabilitas utamanya.

Feature transformation merupakan proses mengubah skala atau format data agar lebih sesuai dengan kebutuhan algoritma pembelajaran mesin. Transformasi ini bertujuan memperbaiki distribusi data atau mengurangi pengaruh *outlier*. Salah satu contoh teknik ini adalah normalisasi data menggunakan metode *Robust Scaling*, yang efektif dalam menangani data dengan *outlier* ekstrem.

Feature selection adalah proses memilih subset fitur yang paling relevan dari seluruh fitur yang tersedia, dengan menghilangkan fitur yang tidak signifikan atau redundan. Tujuan dari *feature selection* adalah untuk menyederhanakan model, mengurangi *overfitting*, dan mempercepat waktu pelatihan. Salah satu metode *feature selection* yang populer adalah *Recursive Feature Elimination* (RFE), yang bekerja dengan mengeliminasi fitur kurang penting berdasarkan bobot kontribusinya terhadap model.

Dengan menerapkan teknik-teknik ini secara tepat, *feature engineering* dapat secara signifikan meningkatkan akurasi dan efisiensi model prediksi, terutama dalam konteks data deret waktu seperti harga emas dengan inkorporasi variabel makroekonomi.

2.10.1 Recursive Feature Elimination (RFE)

Recursive Feature Elimination (RFE) adalah teknik *feature selection* yang digunakan untuk mengidentifikasi fitur yang paling penting dalam *dataset*. RFE bekerja dengan melatih model pada subset fitur yang semakin kecil secara rekursif, menghapus fitur yang paling tidak penting pada setiap iterasi, hingga mencapai jumlah fitur yang diinginkan (Ramezan, 2022). Teknik ini sangat cocok untuk data deret waktu karena dapat mempertimbangkan interaksi antar fitur dan dinamika waktu dalam data.

2.11 Hyperparameter

Hyperparameter adalah parameter yang ditentukan sebelum pelatihan model dan memengaruhi performa model. Pemilihan *hyperparameter* yang tepat sangat penting untuk mencapai performa optimal.

2.11.1 Epoch

Epoch adalah jumlah iterasi yang dilakukan model selama pelatihan. Misalnya, jika *epoch* diatur ke 100, model akan melewati seluruh *dataset* sebanyak 100

kali. Pemilihan jumlah *epoch* yang tepat dapat mencegah *overfitting* atau *underfitting* (Abadi *et al.*, 2016).

2.11.2 *Batch Size*

Batch size adalah jumlah sampel yang diproses oleh model dalam satu iterasi. *Batch size* yang lebih kecil dapat meningkatkan akurasi model, tetapi juga memerlukan waktu pelatihan yang lebih lama (Abadi *et al.*, 2016).

2.11.3 *Optimizer*

Optimizer adalah algoritma yang digunakan untuk memperbarui parameter model selama pelatihan. Beberapa *optimizer* populer termasuk SGD (*Stochastic Gradient Descent*), *Adam*, dan *RMSprop*. *Adam* adalah *optimizer* yang paling umum digunakan karena kemampuannya untuk menyesuaikan *learning rate* secara otomatis (Kingma & Ba, 2015).

2.11.4 *Learning Rate*

Learning rate adalah parameter yang mengontrol seberapa besar perubahan parameter model selama pelatihan. *Learning rate* yang terlalu tinggi dapat menyebabkan model tidak konvergen, sementara *learning rate* yang terlalu rendah dapat memperlambat proses pelatihan (Abadi *et al.*, 2016).

2.11.5 *Input dan Output Chunk Length*

Dalam pemodelan deret waktu menggunakan *library Darts*, parameter *input chunk length* dan *output chunk length* menjadi bagian penting dalam menentukan bagaimana data diproses oleh model sebelum dan saat melakukan prediksi. *Input chunk length* adalah panjang urutan data historis yang digunakan sebagai masukan untuk model, sedangkan *output chunk length* adalah jumlah langkah waktu ke depan yang diprediksi sekaligus dalam satu *forward pass* (Johnsen *et al.*, 2024). Konfigurasi dua parameter ini sangat memengaruhi

performa model karena menentukan seberapa luas konteks temporal yang dianalisis serta cakupan horizon prediksi yang dihasilkan.

Penelitian oleh Peik *et al.* (2024) yang mengimplementasikan model *Temporal Fusion Transformer* (TFT) dalam *library Darts* menunjukkan bahwa pemilihan *chunk length* yang tepat dapat meningkatkan kualitas prediksi, khususnya dalam tugas *multivariate time-series forecasting*. Pengaturan ini juga berfungsi sebagai representasi eksplisit dari *windowing mechanism*, yaitu bagaimana data historis dan target masa depan dibagi dalam *batch* pelatihan secara sistematis. Oleh karena itu, dalam penelitian ini, pemilihan panjang *input* dan *output chunk* ditentukan melalui eksperimen berdasarkan karakteristik data dan horizon prediksi yang dituju.

2.11.6 Dropout

Dropout adalah teknik untuk menonaktifkan sebagian neuron secara acak selama pelatihan untuk mencegah model terlalu bergantung pada fitur tertentu (Srivastava *et al.*, 2014).

2.12 Metrik Evaluasi

Metrik evaluasi digunakan untuk mengukur seberapa baik model dalam memprediksi nilai aktual. Pemilihan metrik yang tepat sangat penting untuk mengevaluasi performa model secara akurat.

2.12.1 Symmetric Mean Absolute Percentage Error (sMAPE)

SMAPE adalah metrik evaluasi yang mengukur kesalahan relatif antara nilai prediksi dan nilai aktual. Metrik ini simetris, artinya tidak bias terhadap *overprediction* atau *underprediction*. SMAPE sangat cocok untuk data dengan skala yang bervariasi, seperti harga emas (Hyndman & Koehler, 2006). Rumus sMAPE dapat didefinisikan sebagai berikut.

$$\text{SMAPE} = \frac{100}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{(|A_t| + |F_t|)/2}$$

Rumus tersebut terdapat A_t yang merupakan nilai aktual dan F_t nilai prediksi.

2.12.2 Root Mean Squared Error (RMSE)

RMSE adalah metrik evaluasi yang mengukur rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual. Metrik ini sangat sensitif terhadap *outlier*, sehingga cocok untuk mengevaluasi model yang perlu meminimalkan kesalahan besar (Hyndman & Koehler, 2006). Rumus RMSE dapat didefinisikan sebagai berikut.

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2}$$

RMSE merupakan akar dari *Mean Squared Error* (MSE), dengan A_t merupakan nilai aktual dan F_t merupakan nilai prediksi.

2.12.3 Mean Absolute Error (MAE)

MAE adalah metrik evaluasi yang mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Metrik ini tidak sensitif terhadap *outlier*, sehingga cocok untuk data dengan variabilitas tinggi (Hyndman & Koehler, 2006). Rumus MAE dapat didefinisikan sebagai berikut.

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

Pada rumus MAE terdapat A_t merupakan nilai aktual dan F_t merupakan nilai prediksi pada waktu ke- t .

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Waktu dan tempat penelitian akan dilaksanakan sebagai berikut:

3.1.1 Waktu Penelitian

Penelitian dilaksanakan pada bulan Desember tahun ajaran 2024/2025 sampai dengan bulan Juni tahun ajaran 2024/2025.

3.1.2 Tempat Penelitian

Penelitian ini dilakukan di Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Lampung, Kota Bandar Lampung, Provinsi Lampung.

3.2 Alat dan Bahan

Alat dan bahan yang digunakan dalam penelitian ini adalah sebagai berikut:

3.2.1 Alat Penelitian

Penelitian ini memerlukan peralatan yang mendukung selama proses penelitian dilaksanakan. Alat yang diperlukan, yaitu perangkat lunak (*software*) dan perangkat keras (*hardware*).

3.2.1.1 Perangkat Lunak (*Software*)

Perangkat lunak pendukung yang digunakan dalam prediksi harga emas dengan inkorporasi fitur makroekonomi adalah sistem operasi *Windows 11 64-bit*, *Google Colab*, dan *Google Drive*.

3.2.1.2 Perangkat Keras (*Hardware*)


Perangkat keras pendukung yang digunakan dalam prediksi harga emas dengan inkorporasi fitur makroekonomi adalah laptop ACER SWIFT 3 SF314-43 dengan spesifikasi RAM 16 GB, SSD M.2 NVMe 512 GB dan *processor* AMD Ryzen 5 5500U with *Radeon Graphics* (12 CPUs) 2.1 GHz.

3.2.2 Bahan Penelitian

Penelitian ini memanfaatkan *dataset* yang terdiri dari 1127 baris dan 6 kolom yang mencakup harga emas harian serta berbagai indikator makroekonomi, termasuk suku bunga, indeks harga konsumen (CPI), tingkat pengangguran, produk domestik bruto (GDP), dan indeks dolar Amerika Serikat. Data yang digunakan mencakup rentang waktu dari 2 Januari 2014 hingga 27 April 2018. Seluruh *dataset* diperoleh melalui API dari *Yahoo Finance* (YFinance) dan *Federal Reserve Economic Data* (FRED).

3.3 Metode

Berikut ini adalah alur penelitian yang akan dilakukan untuk membandingkan kinerja model TFT dan N-BEATS dalam prediksi harga emas dengan inkorporasi fitur makroekonomi. Alur penelitian dapat dilihat pada Gambar 3.



Gambar 3. Alur Penelitian.

Tahapan yang akan dilakukan pada penelitian ini yaitu *Data Collecting*, *Exploratory Data Analysis*, *Data Preprocessing*, *Data Splitting*, *Model Building*, *Model Evaluating*, dan *Model Comparing*. Penjelasan lengkap alur penelitian adalah sebagai berikut:

3.3.1 Data Collecting

Pengumpulan data merupakan langkah awal dalam penelitian ini. Data yang digunakan dalam penelitian ini terdiri dari harga emas harian dan variabel makroekonomi yang berpengaruh terhadap harga emas. Data dikumpulkan melalui dua sumber utama yaitu *Yahoo Finance* (YFinance API) dan *Federal Reserve Economic Data* (FRED API). Kedua sumber data ini dipilih karena menyediakan data historis yang kredibel dan telah banyak digunakan dalam berbagai penelitian ilmiah.

3.3.1.1 YFinance API

Yahoo Finance (YFinance API) digunakan untuk memperoleh dua jenis data:

1. Harga emas harian dalam satuan USD *per troy ounce* dengan kode simbol GC=F, yang mewakili harga emas berjangka (*Gold Futures*).
2. Indeks Dolar AS (DXY) dengan kode simbol DX-Y.NYB, yang digunakan untuk mengukur kekuatan dolar AS terhadap sekeranjang mata uang utama dunia.

Data dikumpulkan dalam bentuk *time-series* dari tanggal 2 Januari 2014 hingga 27 April 2018. Data ini diperoleh dalam resolusi harian dan akan menjadi acuan utama dalam membentuk target variabel dan salah satu fitur penting dalam model prediksi.

3.3.1.2 FRED API

Federal Reserve Economic Data (FRED API) digunakan untuk memperoleh data makroekonomi lainnya, yang mencerminkan kondisi ekonomi makro Amerika Serikat. Variabel yang diambil antara lain:

1. *Federal Funds Effective Rate* (FEDFUNDS) untuk mewakili suku bunga.
2. *Consumer Price Index* (CPILFESL) untuk mewakili tingkat inflasi.
3. *Unemployment Rate* (UNRATE) untuk tingkat pengangguran.
4. *Gross Domestic Product* (GDP) sebagai ukuran output ekonomi nasional.

Data yang diperoleh memiliki frekuensi bulanan atau kuartalan. Oleh karena itu, sebelum digunakan dalam model, dilakukan penyesuaian frekuensi agar selaras dengan data harian harga emas.

3.3.2 Exploratory Data Analysis (EDA)

Analisis eksplorasi data (EDA) dilakukan untuk memahami karakteristik awal dari *dataset* sebelum memasuki tahapan *preprocessing* dan pemodelan. EDA bertujuan untuk memperoleh wawasan awal mengenai pola data, hubungan antar variabel, potensi masalah kualitas data, serta kebutuhan transformasi data. Beberapa tujuan utama EDA dalam penelitian ini adalah:

1. Mengidentifikasi tren dan pola temporal harga emas serta variabel makroekonomi.
2. Menganalisis distribusi data dan mendeteksi keberadaan *outlier* atau nilai ekstrem.
3. Mengukur tingkat korelasi antar fitur untuk memahami keterkaitan antar variabel.
4. Mengidentifikasi *missing values* yang perlu ditangani pada tahap *data cleaning*.
5. Melakukan uji stasioneritas untuk menilai kestabilan statistik waktu pada setiap variabel.
6. Menganalisis kebutuhan *scaling* berdasarkan *skewness* dan rasio nilai maksimum terhadap minimum.

Visualisasi digunakan sebagai alat bantu utama dalam EDA. Beberapa jenis visualisasi dan analisis statistik yang digunakan antara lain:

1. *Line Plot*
Visualisasi *time-series* untuk masing-masing variabel digunakan untuk melihat tren umum dan pola musiman. Grafik ini memberikan gambaran perubahan nilai dari waktu ke waktu.
2. *Correlation Heatmap*
Matriks korelasi dihitung dan divisualisasikan dalam bentuk *heatmap* untuk menilai kekuatan hubungan linier antar variabel. Korelasi yang kuat dapat menjadi indikasi relevansi fitur terhadap target prediksi.
3. Statistik Deskriptif dan Analisis *Missing Values*
Statistik deskriptif (seperti rata-rata, standar deviasi, maksimum, dan minimum) dihitung untuk seluruh variabel, serta dilakukan pengecekan

terhadap keberadaan nilai hilang (*missing values*) sebagai dasar untuk tahap *data cleaning*.

4. *Box Plot*

Digunakan untuk mengidentifikasi *outlier* dan menganalisis penyebaran data masing-masing fitur. Kehadiran *outlier* yang ekstrem dapat memengaruhi performa model.

5. Uji Stasioneritas

Uji *Augmented Dickey-Fuller* (ADF) dilakukan untuk menilai apakah setiap variabel bersifat stasioner atau tidak. Variabel dikatakan stasioner jika $p\text{-value} \leq 0.05$, yang berarti tidak diperlukan transformasi lebih lanjut untuk stabilitas statistiknya.

6. Analisis Kebutuhan *Scaling*

Skewness dan rasio antara nilai maksimum dan minimum dianalisis untuk menentukan apakah suatu fitur perlu dinormalisasi. *Scaling* direkomendasikan apabila distribusi suatu variabel sangat miring (*skewed*) atau memiliki rentang nilai yang terlalu besar.

Dengan melakukan EDA secara komprehensif, peneliti memperoleh dasar yang kuat untuk menentukan strategi *preprocessing*, pemilihan fitur, dan konfigurasi model.

3.3.3 *Data Preprocessing*

Tahap pra-pemrosesan data dilakukan untuk memastikan bahwa data yang digunakan dalam model prediksi bersih, terstruktur, dan sesuai dengan kebutuhan model *deep learning*. Beberapa langkah *preprocessing* yang dilakukan dalam penelitian ini meliputi *data cleaning*, *data integration*, *scaling*, dan *feature engineering*.

3.3.3.1 *Data Cleaning*

Data makroekonomi yang diperoleh dari FRED memiliki frekuensi yang berbeda dengan data harga emas yang bersifat harian. Oleh karena itu,

terdapat kekosongan nilai (*missing values*) pada beberapa titik waktu. Untuk mengatasi hal tersebut, digunakan metode interpolasi linier (*linear interpolation*) yang mengisi nilai-nilai kosong dengan estimasi berdasarkan tren lokal dan metode interpolasi *spline* yang menggunakan fungsi polinomial bertingkat (*piecewise polynomial*) untuk menghubungkan titik-titik data secara halus. Metode ini dipilih karena mampu mempertahankan kontinuitas dan kestabilan data *time-series*.

3.3.3.2 Data Integration

Integrasi data dilakukan dengan pendekatan *inner join* berdasarkan kolom tanggal (*Date*) sebagai kunci utama. Teknik ini memastikan bahwa hanya baris dengan tanggal yang memiliki nilai lengkap di semua variabel (harga emas dan indikator makroekonomi) yang akan dipertahankan. Hasil dari integrasi ini adalah satu *dataset* multivariat yang siap untuk dilatih menggunakan model *deep learning*.

3.3.3.3 Scaling

Proses penskalaan data (*scaling*) direncanakan untuk menyamakan skala antar fitur agar model tidak bias terhadap fitur dengan nilai numerik lebih besar. Ketidakseimbangan skala antar fitur dapat menyebabkan bobot pembelajaran menjadi tidak seimbang, terutama dalam algoritma berbasis *gradient descent* seperti *deep learning*.

Pemilihan metode *scaling* dalam penelitian ini akan ditentukan berdasarkan hasil analisis pada tahap *Exploratory Data Analysis* (EDA), khususnya melalui uji stasionaritas dan analisis distribusi (seperti nilai *skewness* dan rasio maksimum terhadap minimum). Jika fitur menunjukkan distribusi dengan *skewness* tinggi atau terdapat *outlier* signifikan, maka akan digunakan metode *Robust Scaling* karena metode ini tahan terhadap pengaruh nilai ekstrem. Sebaliknya, jika distribusi data relatif simetris dan tidak memiliki *outlier* besar, maka dapat dipertimbangkan penggunaan

metode lain seperti *Min-Max Scaling* dan transformasi Logaritma Natural (ln).

Dengan pendekatan ini, proses *scaling* tidak hanya mengikuti praktik umum, tetapi juga mempertimbangkan karakteristik statistik dari masing-masing fitur dalam *dataset* untuk menjaga kestabilan proses pelatihan model prediktif.

3.3.3.4 Feature Engineering

Feature engineering merupakan proses penting dalam pemodelan data yang bertujuan untuk meningkatkan kualitas input model dengan cara memilih, merepresentasikan ulang, atau merekayasa fitur yang paling relevan. Dalam konteks penelitian ini, *feature engineering* dilakukan melalui teknik *feature selection*, yaitu pemilihan fitur yang paling berkontribusi terhadap performa prediksi.

Metode *Recursive Feature Elimination* (RFE) digunakan untuk memilih subset fitur terbaik. RFE bekerja dengan melatih model secara berulang, kemudian secara bertahap menghapus fitur yang memiliki kontribusi paling kecil terhadap hasil prediksi. Teknik ini dipilih karena mampu mengurangi kompleksitas model, menurunkan risiko *overfitting*, dan meningkatkan efisiensi pelatihan. Dengan hanya menyertakan fitur-fitur yang paling penting, model dapat mencapai performa yang lebih stabil dan akurat dalam memprediksi harga emas dengan inkorporasi fitur data makroekonomi.

3.3.4 Data Splitting

Dataset yang telah melalui tahap *preprocessing* dibagi menjadi dua bagian utama, yaitu data pelatihan-validasi dan data pengujian. Pembagian dilakukan dengan mempertimbangkan urutan kronologis data *time-series*, di mana sekitar 90% data digunakan sebagai *train-validation set* dan sekitar 10% sisanya sebagai *test set*. Proporsi ini sejalan dengan pendekatan pada jurnal acuan oleh Livieris *et al.* (2020) dengan data pelatihan mencakup periode dari Januari 2014

hingga Desember 2017, sedangkan data pengujian mencakup periode Januari 2018 hingga April 2018. Data pengujian dipisahkan sepenuhnya dan tidak dilibatkan dalam proses pelatihan maupun validasi model, guna menjaga objektivitas evaluasi performa model pada data yang benar-benar belum pernah dilihat sebelumnya.

3.3.5 Model Building

Model prediksi harga emas dalam penelitian ini dibangun menggunakan dua arsitektur *deep learning* berbasis *time-series*, yaitu *Temporal Fusion Transformer* (TFT) dan N-BEATS. Masing-masing model diterapkan secara terpisah untuk kemudian dibandingkan hasil performanya. Selain itu, dilakukan juga proses penyesuaian *hyperparameter* (*hyperparameter tuning*) untuk mencari konfigurasi terbaik dari masing-masing model dan pelatihan model menggunakan *Time-Series Cross Validation* (TSCV) untuk memastikan kestabilan parameter terbaik yang digunakan.

3.3.5.1 TFT

TFT dibangun menggunakan pustaka *darts* yang menyediakan antarmuka pemodelan *time-series* multivariabel. Input data terdiri dari variabel makroekonomi sebagai fitur dan harga emas sebagai target prediksi. TFT dirancang untuk menangkap dependensi jangka panjang maupun pendek serta memberikan interpretasi terhadap kontributor utama dari prediksi.

3.3.5.2 N-BEATS

N-BEATS juga diimplementasikan menggunakan pustaka *darts*, dengan pendekatan *basis expansion block*. Model ini bekerja dengan prinsip memproyeksikan input *time-series* ke dalam komponen *backcast* dan *forecast*. Dalam penelitian ini, N-BEATS digunakan dalam konfigurasi *multivariate forecasting*, sehingga dapat mengakomodasi input dari variabel makroekonomi.

3.3.5.3 Hyperparameter Tuning

Proses *tuning hyperparameter* dilakukan untuk mengoptimalkan performa model prediktif dengan menyesuaikan nilai parameter yang memengaruhi proses pelatihan. Dalam penelitian ini, *tuning* dilakukan secara terpisah untuk model *Temporal Fusion Transformer* (TFT) dan N-BEATS, karena masing-masing memiliki arsitektur dan parameter khusus yang tidak saling kompatibel.

Pemilihan kombinasi *hyperparameter* dilakukan menggunakan pendekatan *Random Search* dengan total 50 kombinasi acak dari seluruh ruang pencarian parameter. Teknik ini digunakan karena lebih efisien dibanding *grid search*, terutama pada ruang pencarian parameter yang luas (Bergstra & Bengio, 2012). Penelusuran kombinasi terbaik dilakukan menggunakan nilai sMAPE sebagai acuan evaluasi utama. Untuk menjamin replikasi dan konsistensi hasil, *seed* acak diatur ke 42. Seluruh model dilatih selama 20 *epoch* untuk setiap kombinasi parameter.

Berikut adalah daftar *hyperparameter* dan rentang nilainya yang digunakan dalam *tuning* untuk masing-masing model. Tabel 2 menyajikan konfigurasi *hyperparameter* untuk model TFT, sedangkan Tabel 3 merinci konfigurasi yang digunakan pada model N-BEATS.

Tabel 2. *Hyperparameter* untuk Model TFT

Parameter	Nilai	Alasan
<i>Input Chunk Length</i>	4, 6, 9	Menyesuaikan data historis yang digunakan berdasarkan jurnal acuan oleh Livieris <i>et al.</i> (2020)
<i>Output Chunk Length</i>	1	Sesuai dengan horizon prediksi yang digunakan berdasarkan jurnal acuan
<i>Hidden Size</i>	16, 32, 64	Mewakili kompleksitas representasi internal
<i>LSTM Layers</i>	1, 2	Mengontrol kedalaman memo jangka panjang
<i>Num Attention Heads</i>	2, 4	Jumlah <i>head attention</i> untuk meningkatkan kapasitas interpretasi multivariabel

Parameter	Nilai	Alasan
<i>Dropout</i>	0.0, 0.1, 0.2, 0.3	Regularisasi untuk menghindari <i>overfitting</i>
<i>Batch Size</i>	8, 16, 32	Disesuaikan dengan ukuran <i>dataset</i> dan memori
<i>Learning Rate</i>	0.001, 0.0005, 0,0001	Rentang umum untuk kestabilan optimisasi

Secara umum, *hyperparameter* pada N-BEATS difokuskan pada arsitektur blok dan kedalaman *stack* yang khas. Rincian lengkapnya ditunjukkan pada Tabel 3 berikut.

Tabel 3. *Hyperparameter* untuk Model N-BEATS

Parameter	Nilai	Alasan
<i>Input Chunk Length</i>	4, 6, 9	Mengontrol banyaknya data historis yang diproses
<i>Output Chunk Length</i>	1	Sesuai dengan horizon prediksi yang digunakan berdasarkan jurnal acuan
<i>Layer Widths</i>	64, 128, 256	Lebar layer memengaruhi kapasitas representasi basis
<i>Num Stacks</i>	2, 4, 8, 16	Mewakili kedalaman blok dalam model
<i>Generic Architecture</i>	<i>True</i>	Mengaktifkan arsitektur generik untuk fleksibilitas basis
<i>Dropout</i>	0.0, 0.1, 0.2, 0.3	Mengurangi risiko <i>overfitting</i>
<i>Batch Size</i>	8, 16, 32	Menyesuaikan dengan ukuran <i>dataset</i> dan kapasitas memori
<i>Learning Rate</i>	0.001, 0.0005, 0,0001	Rentang umum untuk kestabilan optimisasi

Optimisasi dilakukan menggunakan *Adam Optimizer* karena telah terbukti stabil dan efektif untuk berbagai *task time-series*, serta merupakan *default optimizer* dalam pustaka *Darts* yang digunakan dalam penelitian ini. Setelah dilakukan pencarian kombinasi *hyperparameter* terbaik menggunakan *random search*, model dengan parameter optimal kemudian dilatih ulang dalam TSCV dengan jumlah *epoch* sebanyak 100. Pemilihan jumlah *epoch* ini bertujuan untuk memberikan waktu pelatihan yang cukup agar model

dapat mencapai konvergensi secara stabil, dengan memanfaatkan kombinasi parameter terbaik yang telah ditemukan sebelumnya.

3.3.5.4 Time-Series Cross Validation (TSCV)

Validasi performa model dilakukan menggunakan pendekatan *Time-Series Cross Validation* (TSCV) dengan 5 *folds*. Teknik ini dipilih karena mampu menjaga urutan kronologis data *time-series* dan mencegah kebocoran data dari masa depan ke masa lalu. Pada TSCV, data pelatihan digunakan dengan metode *expanding window*, di mana setiap *fold* memiliki ukuran *training* yang bertambah seiring waktu, sedangkan ukuran *validation set* tetap konstan (*fixed window*). Pendekatan ini memberikan gambaran evaluasi yang lebih realistis terhadap performa model di skenario prediksi masa depan, sehingga hasil validasi lebih representatif terhadap kondisi dunia nyata.

TSCV difokuskan untuk proses *cross validation* pada data pelatihan dan validasi, bukan untuk evaluasi akhir pada data uji (*test set*). Oleh karena itu, setelah kombinasi *hyperparameter* terbaik divalidasi menggunakan TSCV, model perlu dilatih ulang menggunakan seluruh data *train-validation* secara penuh. Model yang telah dilatih ulang inilah yang kemudian digunakan untuk melakukan prediksi pada *test set*, guna memastikan evaluasi akhir dilakukan pada data yang benar-benar belum pernah dilihat oleh model selama pelatihan maupun validasi.

3.3.6 Model Evaluating

Evaluasi model dilakukan untuk mengukur seberapa baik model dalam melakukan prediksi harga emas berdasarkan data historis dan variabel makroekonomi yang telah diinkorporasikan. Tiga metrik evaluasi yang digunakan dalam penelitian ini adalah *Symmetric Mean Absolute Percentage Error* (sMAPE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE). Pemilihan ketiga metrik ini tidak dilakukan secara sembarangan,

melainkan mengacu pada rekomendasi dari studi Hyndman dan Koehler (2006), yang secara luas diakui dalam bidang peramalan deret waktu.

Secara khusus, penggunaan metrik sMAPE didasarkan pada penelitian Oreshkin *et al.* (2020) yang mengusulkan N-BEATS, sementara RMSE dan MAE dipilih berdasarkan studi yang dilakukan oleh Livieris *et al.* (2020) dan Farooq *et al.* (2024). Karena penelitian ini juga menggunakan *dataset* yang merujuk pada Livieris *et al.*, maka penggunaan metrik yang sama sangat penting untuk mendukung proses komparasi hasil.

3.3.6.1 SMAPE

SMAPE merupakan metrik yang mengukur persentase kesalahan prediksi secara simetris, sehingga dapat menghindari bias terhadap nilai aktual atau nilai prediksi yang sangat kecil. Rumus sMAPE memberikan nilai kesalahan dalam skala 0%–100%, yang memudahkan interpretasi performa model. Metrik ini sangat umum digunakan dalam berbagai penelitian peramalan deret waktu, termasuk dalam pengembangan model N-BEATS oleh Oreshkin *et al.* (2020).

3.3.6.2 RMSE

RMSE digunakan untuk mengukur besarnya rata-rata galat kuadrat dari prediksi terhadap nilai aktual. Metrik ini sensitif terhadap nilai ekstrem (*outlier*) sehingga sangat cocok digunakan dalam kasus prediksi harga yang rentan terhadap fluktuasi besar. Dalam penelitian Livieris *et al.* (2020) dan Farooq *et al.* (2024), RMSE digunakan sebagai metrik utama dalam mengevaluasi model *deep learning* untuk peramalan harga, termasuk harga emas.

3.3.6.3 MAE

MAE merupakan metrik evaluasi yang menghitung rata-rata dari selisih absolut antara nilai aktual dan hasil prediksi. Metrik ini lebih stabil terhadap

outlier jika dibandingkan dengan RMSE, sehingga memberikan gambaran kesalahan prediksi yang lebih moderat. Livieris *et al.* (2020) menggunakan MAE sebagai pelengkap RMSE untuk memperoleh perspektif evaluasi yang lebih komprehensif terhadap performa model prediktif.

3.3.7 Model Comparing

Langkah terakhir dalam alur penelitian ini adalah melakukan proses perbandingan (*comparing*) terhadap performa dua model yang dikembangkan, yaitu *Temporal Fusion Transformer* (TFT) dan N-BEATS. Proses ini bertujuan untuk mengetahui model mana yang memiliki kinerja lebih unggul dalam memprediksi harga emas berdasarkan data historis serta fitur-fitur makroekonomi yang telah diinkorporasikan sebelumnya.

Perbandingan dilakukan dengan mengacu pada hasil evaluasi yang diperoleh dari tiga metrik utama, yaitu sMAPE, RMSE, dan MAE. Tak hanya membandingkan performa antar model, penelitian ini juga akan membandingkan kinerja model yang dilatih dengan fitur makroekonomi dengan model yang hanya menggunakan data harga emas sebagai input. Tujuannya adalah untuk menjawab pertanyaan apakah inkorporasi fitur makroekonomi benar-benar meningkatkan akurasi prediksi dibandingkan pendekatan univariat.

Hasil evaluasi dari penelitian ini juga akan dibandingkan dengan hasil dari penelitian terdahulu, khususnya studi oleh Livieris *et al.* (2020), yang menjadi acuan utama dalam penggunaan *dataset*. Dengan membandingkan metrik yang serupa, evaluasi ini diharapkan mampu memberikan pemahaman lebih mendalam tentang keunggulan model dan metode yang digunakan serta kontribusi penelitian terhadap pengembangan sistem prediksi harga emas berbasis *deep learning*.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini berhasil membangun dua model *deep learning*, yaitu *Temporal Fusion Transformer* (TFT) dan N-BEATS, untuk melakukan prediksi harga emas berbasis data deret waktu. Seluruh model dikembangkan menggunakan pustaka *Darts* dan dilatih dengan strategi *time-series cross-validation*, serta diuji secara *out-of-sample* menggunakan data yang terpisah. Proses pengembangan mencakup pemilihan *hyperparameter* optimal, desain skenario eksperimen yang melibatkan berbagai teknik *preprocessing*, dan konfigurasi fitur baik secara *univariate* maupun *multivariate*.

Integrasi fitur makroekonomi dilakukan melalui proses interpolasi (*linear* dan *spline*), menggabungkan data dengan *inner join*, transformasi (*MinMax* dan logaritma natural), serta seleksi fitur menggunakan metode *Recursive Feature Elimination* (RFE). Inkorporasi variabel makroekonomi seperti GDP, CPI, UNRATE, DXY, dan FEDFUNDS ke dalam *dataset multivariate* berhasil menghasilkan data yang lebih informatif dan mendalam untuk keperluan pelatihan model.

Hasil eksperimen menunjukkan bahwa model N-BEATS dengan pendekatan *multivariate*, interpolasi linear, *scaling MinMax*, dan seleksi fitur RFE (N-BEATS₁) merupakan model dengan kinerja terbaik secara keseluruhan pada data uji, dengan nilai sMAPE sebesar 0.5322, RMSE sebesar 9.4337, dan MAE sebesar 7.0903. Sementara itu, beberapa model TFT juga menunjukkan kinerja yang kompetitif, meskipun secara umum N-BEATS cenderung lebih stabil dalam menghasilkan galat yang rendah.

Dengan demikian, dapat disimpulkan bahwa model N-BEATS lebih unggul dibandingkan TFT dalam konteks akurasi prediksi harga emas pada eksperimen ini. Selain itu, penggunaan fitur makroekonomi terbukti memberikan kontribusi positif terhadap kinerja model dalam banyak skenario, khususnya saat dilakukan seleksi fitur yang tepat. Penelitian ini sekaligus memberikan jawaban terhadap seluruh rumusan masalah yang diajukan, mulai dari proses pembangunan model, teknik integrasi fitur, evaluasi kinerja, hingga perbandingan model secara kuantitatif.

5.2 Saran

Berdasarkan temuan dan keterbatasan yang ada, beberapa saran dapat diberikan untuk pengembangan penelitian selanjutnya. Pertama, disarankan untuk mengeksplorasi *time frame* yang berbeda seperti data mingguan (*weekly*), bulanan (*monthly*), atau tahunan (*annual*) guna menguji konsistensi model dalam skala waktu yang lebih luas. Hal ini juga dapat membantu meningkatkan generalisasi model terhadap pola-pola musiman dan tren jangka panjang.

Kedua, model yang dikembangkan dalam penelitian ini masih terbatas pada periode data tertentu dan belum diuji terhadap peristiwa ekonomi besar seperti krisis global atau pandemi. Oleh karena itu, generalisasi model perlu diperluas dengan cara memperpanjang rentang data dan mengujinya pada berbagai kondisi ekonomi yang berbeda. Ini akan memberikan gambaran yang lebih menyeluruh terhadap ketangguhan model dalam menghadapi dinamika pasar.

Ketiga, penelitian selanjutnya dapat mengeksplorasi teknik *preprocessing* lain yang lebih kompleks atau adaptif. Misalnya, interpolasi berbasis *spline* non-linear tingkat tinggi, transformasi distribusi lain seperti *Box-Cox* atau *PowerTransformer*, serta pendekatan *feature engineering* berbasis *domain knowledge* atau metode otomatis seperti *AutoML*.

Terakhir, akan sangat bermanfaat jika penelitian selanjutnya mempertimbangkan penambahan variabel multivariat lain yang relevan, seperti harga minyak mentah (*US Oil*), indeks saham global, atau indikator geopolitik. Penambahan fitur-fitur ini

berpotensi memperkaya konteks makroekonomi dan meningkatkan kapasitas prediktif model terhadap harga emas.

DAFTAR PUSTAKA

- Abadi, M., McMahan, H. B., Chu, A., Mironov, I., Zhang, L., Goodfellow, I., & Talwar, K. (2016). Deep learning with differential privacy. *Proceedings of the ACM Conference on Computer and Communications Security*, 24-28-Octo, 308–318. <https://doi.org/10.1145/2976749.2978318>
- Athanasopoulos, G., Hyndman, R. J., Song, H., & Wu, D. C. (2011). The tourism forecasting competition. *International Journal of Forecasting*, 27(3), 822–844. <https://doi.org/10.1016/j.ijforecast.2010.04.009>
- Baiardi, L. C., Costabile, M., De Giovanni, D., Lamantia, F., Leccadito, A., Massabó, I., Menzietti, M., Pirra, M., Russo, E., & Staino, A. (2020). The dynamics of the S&P 500 under a crisis context: Insights from a three-regime switching model. In *Risks* (Vol. 8, Issue 3, pp. 1–15). <https://doi.org/10.3390/risks8030071>
- Beckmann, J., Berger, T., & Czudaj, R. (2015). Does gold act as a hedge or a safe haven for stocks? A smooth transition approach. *Economic Modelling*, 48, 16–24. <https://doi.org/10.1016/j.econmod.2014.10.044>
- Beckmann, J., & Czudaj, R. (2013). Gold as an inflation hedge in a time-varying coefficient framework. *North American Journal of Economics and Finance*, 24(1), 208–222. <https://doi.org/10.1016/j.najef.2012.10.007>
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *The Journal of Machine Learning Research*. <https://doi.org/10.5555/2188385.2188395>
- Chirwa, T. G., & Odhiambo, N. M. (2020). Determinants of gold price movements: An empirical investigation in the presence of multiple structural breaks. *Resources Policy*, 69, 101818.

<https://doi.org/10.1016/j.resourpol.2020.101818>

- Fang, L., Yu, H., & Xiao, W. (2018). Forecasting gold futures market volatility using macroeconomic variables in the United States. *Economic Modelling*, 72, 249–259. <https://doi.org/https://doi.org/10.1016/j.econmod.2018.02.003>
- Farooq, A., Irfan Uddin, M., Adnan, M., Alarood, A. A., Alsolami, E., & Habibullah, S. (2024). Interpretable multi-horizon time series forecasting of cryptocurrencies by leverage temporal fusion transformer. *Heliyon*, 10(22), e40142. <https://doi.org/10.1016/j.heliyon.2024.e40142>
- Ghosh, D., Levin, E. J., Macmillan, P., & Wright, R. E. (2004). Gold as an Inflation Hedge? *Studies in Economics and Finance*, 22(1), 1–25. <https://doi.org/10.1108/eb043380>
- Greff, K., Srivastava, R. K., Koutnik, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222–2232. <https://doi.org/10.1109/TNNLS.2016.2582924>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Johnsen, P. V., Bøhn, E., Eidnes, S., Remonato, F., & ... (2024). Recency-Weighted Temporally-Segmented Ensemble for Time-Series Modeling. *ArXiv Preprint ArXiv* <https://arxiv.org/abs/2403.02150>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <https://arxiv.org/abs/1412.6980>
- Lepot, M., Aubin, J. B., & Clemens, F. H. L. R. (2017). Interpolation in time series: An introductive overview of existing methods, their performance criteria and uncertainty assessment. In *Water (Switzerland)* (Vol. 9, Issue 10). mdpi.com. <https://doi.org/10.3390/w9100796>
- Liang, Q., Sun, W., Li, W., & Yu, F. (2021). Media effects matter: Macroeconomic

- announcements in the gold futures market. *Economic Modelling*, 96, 1–12.
<https://doi.org/https://doi.org/10.1016/j.econmod.2020.12.018>
- Lim, B., Arik, S., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. In *International Journal of Forecasting* (Vol. 37, Issue 4, pp. 1748–1764). Elsevier.
<https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23), 17351–17360. <https://doi.org/10.1007/s00521-020-04867-x>
- Oreshkin, B. N., Carпов, D., Chapados, N., & Bengio, Y. (2020). N-Beats: Neural Basis Expansion Analysis for Interpretable Time Series Forecasting. *8th International Conference on Learning Representations, ICLR 2020*.
<https://arxiv.org/abs/1905.10437>
- Peik, A., Chahooki, M. A. Z., Fard, A. M., & Sarram, M. A. (2024). Leveraging Time Series Categorization and Temporal Fusion Transformers to Improve Cryptocurrency Price Forecasting. *ArXiv Preprint ArXiv*
<http://arxiv.org/abs/2412.14529>
- Ramezan, C. A. (2022). Transferability of Recursive Feature Elimination (RFE)-Derived Feature Sets for Support Vector Machine Land Cover Classification. In *Remote Sensing* (Vol. 14, Issue 24). mdpi.com.
<https://doi.org/10.3390/rs14246218>
- Ramos, P., & Oliveira, J. M. (2016). A Procedure for Identification of Appropriate State Space and ARIMA Models Based on Time-Series Cross-Validation. In *Algorithms* (Vol. 9, Issue 4). <https://doi.org/10.3390/a9040076>
- Salim, M., & Djunaidy, A. (2024). Development of a CNN-LSTM Approach with Images as Time-Series Data Representation for Predicting Gold Prices. *Procedia Computer Science*, 234, 333–340.
<https://doi.org/https://doi.org/10.1016/j.procs.2024.03.007>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural*

Networks, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958. <https://doi.org/10.5555/2627435.2670313>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 2017-Decem, 5999–6009. <https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>

Xu, K., Zhang, J., Huang, J., Tan, H., Jing, X., & Zheng, T. (2024). Forecasting Visitor Arrivals at Tourist Attractions: A Time Series Framework with the N-BEATS for Sustainable Tourism. In *Sustainability (Switzerland)* (Vol. 16, Issue 18). <https://doi.org/10.3390/su16188227>

Yurtsever, M. (2021). Gold Price Forecasting Using LSTM, Bi-LSTM and GRU TT - LSTM, Bi-LSTM ve GRU ile Altın Fiyatı Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 31, 341–347. <https://doi.org/10.31590/ejosat.959405>

Zhang, R., Pian, H., Santosh, M., & Zhang, S. (2015). The history and economics of gold mining in China. *Ore Geology Reviews*, 65(P3), 718–727. <https://doi.org/10.1016/j.oregeorev.2014.03.004>