

**PENERAPAN METODE N-BEATS UNTUK FORECASTING INFLASI
INDONESIA**

SKRIPSI

Oleh :
LAKSAMANA SULTHAN ALAM S
NIM. 19650098



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**PENERAPAN METODE N-BEATS UNTUK FORECASTING INFLASI
INDONESIA**

SKRIPSI

Diajukan kepada:

Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :

LAKSAMANA SULTHAN ALAM .S

NIM. 19650098

**JURUSAN TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

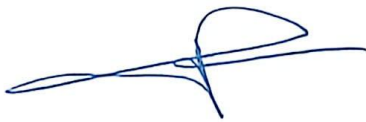
**PENERAPAN METODE N-BEATS UNTUK FORECASTING INFLASI
INDONESIA**

SKRIPSI

**Oleh :
LAKSAMANA SULTHAN ALAM .S
NIM. 19650098**

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 28 April 2026

Pembimbing I,



Dr. Fachrul Kurniawan., M.MT ., IPU
NIP. 19771020 200912 1 001

Pembimbing II,



Dr. M. Imamudin Lc, MA
NIP. 19740602 200901 1 010

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M. Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

PENERAPAN METODE N-BEATS UNTUK FORECASTING INFLASI INDONESIA

SKRIPSI

Oleh :
LAKSAMANA SULTHAN ALAM .S
NIM. 19650098

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 28 April 2026

Susunan Dewan Penguji

Ketua Penguji : Dr. Ir. Yunifa Miftachul Arif, S.ST.,
M.T., SMIEEE
NIP. 19830616 201101 1 004

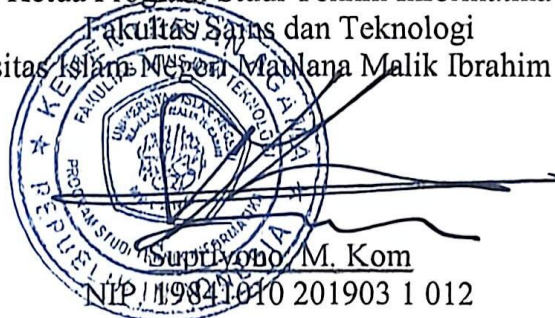
Anggota Penguji I : Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004

Anggota Penguji II : Dr. Fachrul Kurniawan, M.MT, IPU
NIP. 19771020 200912 1 001

Anggota Penguji III : Dr. M. Imamudin Lc, MA
NIP. 19740602 200901 1 010



Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Mepono Maulana Malik Ibrahim Malang



Supriyono, M. Kom
NIP. 119841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Laksamana Sulthan Alam .S

NIM : 19650098

Fakultas / Jurusan : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Penerapan Metode N-BEATS untuk Forecasting Inflasi Indonesia.

Menyatakan dengan sebenarnya bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 28 April 2026
Yang membuat pernyataan,



Laksamana Sulthan Alam .S
NIM.19650098

MOTTO

... Grinding, Grinding, and Grinding. But.. Sometimes.. you need rest too ...

HALAMAN PERSEMBAHAN

Karya ini dipersembahkan untuk Ibu, Ayah, Adik, dan Sahabat-Sahabat yang selalu mendukung penulis.

KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah S.W.T tuhan semesta alam, dengan rahmat dan nikmat-Nya, penulis mampu menyelesaikan studi sarjana nya di Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Selanjutnya, penulis mengucapkan banyak terimakasih beserta doa dan harapan kepada pihak yang telah membantu penulis dalam proses penyelesaian skripsi ini. Ucapan terimakasih ini penulis sampaikan kepada :

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si. Selaku Rektor Univeristas Islam Negeri Maulana Malik Ibrahim Malang
2. Prof. Dr. H. Agus Mulyono, S.Pd., M.Kes, Selaku Dekan Fakultas Sains dan Teknologi, Univeristas Islam Negeri Maulana Malik Ibrahim Malang
3. Supriyono, M. Kom, selaku ketua Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang,
4. Dr. Fachrul Kurniawan, M.MT, IPU, dan Dr. M. Imamudin Lc, MA, selaku pembimbing pertama dan pembimbing kedua yang senantiasa memberikan arahan, dukungan, dan dorongan kepada penulis.
5. Segenap Civitas Akademika Program Studi Teknik Informatika
6. Kedua Orang Tua, Ayah dan Ibu, yang sennatiasa memberikan dukungan moral dan material kepada penulis, sehingga penulis mampu sampai pada tahap saat ini.

7. Kedua adik penulis, Satria dan Yazid, yang turut andil dalam memberikan dorongan dan kekuatan moril kepada penulis
8. Sahabat-sahabat penulis yang senantiasa menemani penulis dalam proses pengerjaan skripsi ini hingga selesai.

Malang, 28 April 2026

Laksamana Sulthan Alam S

DAFTAR ISI

HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xi
DAFTAR TABEL	xii
ABSTRAK	xiii
ABSTRACT	xiv
المخلص	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 <i>N-BEATS (Neural Basis Expansion Analysis for Interpretable Time Series)</i>	13
2.3 <i>N-BEATS multivariate / N-BEATSx</i>	20
2.4 <i>Forecasting</i>	21
2.5 <i>Time Series</i>	23
2.6 <i>Inflasi</i>	26
2.7 <i>Evaluation Metrik</i>	29
2.8 <i>SMAPE (Symetric Mean Absolute Percentage Error)</i>	30
BAB III METODE PENELITIAN	31
3.1 Desain Penelitian	31
3.2 Pengumpulan Data	32
3.3 Desain Sistem	35
BAB IV HASIL DAN PEMBAHASAN	40
4.1 Persiapan <i>Dataset</i>	40
4.2 <i>Preprocessing</i>	46
4.3 Hasil dan Analisis Ujicoba	51
4.4 Integrasi Islam Dalam Penelitian	77
BAB V KESIMPULAN	81
5.1 Kesimpulan	81
5.2. Saran	81
5.3. Penutup	82
DAFTAR PUSTAKA	83
LAMPIRAN	86
<i>Dataset</i> Penelitian	86

DAFTAR GAMBAR

Gambar 2. 1 Arsitektur <i>N-BEATS</i>	14
Gambar 2. 2 <i>Trend Pattern Time Series</i>	24
Gambar 2. 3 <i>Seasonal Pattern Time Series</i>	25
Gambar 2. 4 <i>Cyclic Pattern Time Series</i>	25
Gambar 2. 5 <i>Horizontal Pattern Time Series</i>	26
Gambar 3. 1 Desain Penelitian	31
Gambar 3. 2 Desain Sistem	35
Gambar 4. 1 Grafik Inflasi Indonesia	42
Gambar 4. 2 Grafik USD-IDR Exchange Rate	44
Gambar 4. 3 Grafik <i>ExogeneousInfoRecord</i>	46
Gambar 4. 4 Visualisasi Split <i>Dataset Training-Test</i>	52
Gambar 4. 5 Hasil <i>Forecasting</i> Skenario S1	54
Gambar 4. 6 Hasil <i>Forecasting</i> Skenario S2	55
Gambar 4. 7 Hasil <i>Forecasting</i> Skenario S3	55
Gambar 4. 8 Hasil <i>Forecasting</i> Skenario S4	56
Gambar 4. 9 Hasil <i>Forecasting</i> Skenario S5	57
Gambar 4. 10 Hasil <i>Forecasting</i> Skenario S6	57
Gambar 4. 11 Hasil <i>Forecasting</i> Skenario S7	58
Gambar 4. 12 Hasil <i>Forecasting</i> Skenario S8	58
Gambar 4. 13 Hasil <i>Forecasting</i> Skenario S9	59
Gambar 4. 14 Hasil <i>Forecasting</i> Skenario S10	60
Gambar 4. 15 Visualisasi Forecast vs Actual 80% <i>Train</i> 20% <i>Test</i>	62
Gambar 4. 16 Residual <i>Visualization N-BEATS</i> 80% <i>Train</i> 20% <i>Test</i>	65
Gambar 4. 17 <i>Training Error per Point Visualization N-BEATS</i> 80% <i>Train</i> 20% <i>Test</i>	65
Gambar 4. 18 Visualisasi Forecast vs Actual 70% <i>Train</i> 30% <i>Test</i>	66
Gambar 4. 19 Residual <i>Visualization N-BEATS</i> 70% <i>Train</i> 30% <i>Test</i>	70
Gambar 4. 20 <i>Training Error per Point Visualization N-BEATS</i> 70% <i>Train</i> 30% <i>Test</i>	70
Gambar 4. 21 Visualisasi Forecast vs Actual 60% <i>Train</i> 40% <i>Test</i>	71
Gambar 4. 22 Residual <i>Visualization N-BEATS</i> 60% <i>Train</i> 40% <i>Test</i>	76
Gambar 4. 23 <i>Training Error per Point Visualization N-BEATS</i> 60% <i>Train</i> 40% <i>Test</i>	76

DAFTAR TABEL

Tabel 2 1 Studi Literatur	11
Tabel 3 1 Data Inflasi BI	34
Tabel 3 2 Data Nilai Tukar USD-IDR Yahoo Finance	34
Tabel 3 3 Data Kenaikan Harga Minyak Indonesia	34
Tabel 4 1 <i>InflationRecord</i> data structure	40
Tabel 4 2 <i>InflationRecord</i> data example	41
Tabel 4 3. <i>USDIDRExchangeRecord</i> data structure	43
Tabel 4 4 <i>USDIDRExchangeRecord</i> data example	43
Tabel 4 5 <i>ExogeneousInfoRecord</i> data structure	44
Tabel 4 6 <i>ExogeneousInfoRecord</i> data example	45
Tabel 4 7 <i>Dataframe after Data Type Mapping and Conversion</i>	46
Tabel 4 8 <i>Mapping and Conversion of Dataframe</i>	47
Tabel 4 9 <i>Frequency Normalization of Dataframe</i>	47
Tabel 4 10 <i>Multivariate Merging of Dataframe</i>	48
Tabel 4 11 <i>Exogeneous Feature Lagging of Dataframe</i>	49
Tabel 4 12 <i>Fill Missing Values of Dataframe</i>	50
Tabel 4 13 <i>Example of Dataframe with broken value</i>	51
Tabel 4 14 <i>Final Dataframe after cleaning</i>	51
Tabel 4 15 <i>Skenario Hyperparameter</i>	52
Tabel 4 16 <i>N-BEATSx Hyperparameter</i>	60
Tabel 4 17 <i>Metrik N-BEATS 80% Train 20% Test</i>	62
Tabel 4 18 <i>Actual vs Forecast Table split 80% Train 20% Test</i>	63
Tabel 4 19 <i>Metrik N-BEATS 70% Train 30% Test</i>	67
Tabel 4 20 <i>Actual vs Forecast Table split 70% Train 30% Test</i>	67
Tabel 4 21 <i>Metrik N-BEATS 80% Train 20% Test</i>	72
Tabel 4 22 <i>Actual vs Forecast Table split 60% Train 40% Test</i>	72
Tabel 4 23 <i>Komparasi ujicoba N-BEATS</i>	76

ABSTRAK

Alam .S, Laksamana Sulthan. 2026. **Penerapan Metode *N-BEATS* untuk forecasting Inflasi Indonesia. Skripsi.** Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Fachrul Kurniawan ST., M.MT ., IPU (II) Dr. M. Imamudin Lc, MA.

Kata kunci: *N-BEATS, Forecasting, Inflasi Indonesia, Deep Learning, Time Series Analysis*

Salah satu tantangan ekonomi adalah inflasi, dan ini merupakan indikator pertumbuhan dan ketahanan ekonomi sebuah bangsa terhadap pengaruh negara lain. Indonesia merupakan salah satu kekuatan ekonomi dunia, turut mengalami fluktuasi inflasi. Inflasi ini seringkali sulit diprediksi dengan akurasi tinggi jika menggunakan metode konvensional. Ketersediaan data yang akurat dan terpolo memungkinkan adanya proyeksi yang akurat. Penelitian ini bertujuan untuk menerapkan algoritma Deep Learning yaitu *Neural Basis Expansion Analysis for Interpretable Time Series (N-BEATS) multivariate* untuk memprediksi nilai inflasi Indonesia di masa mendatang. Metode penelitian diawali dengan pengumpulan data histori inflasi, tahap *pre-processing*, perancangan arsitektur *N-BEATS* yang terdiri dari *stack* dan *block* untuk menangkap tren dan *seasonality*, dilanjutkan dengan tahap pengujian model. Untuk evaluasi model akan menggunakan *MAE*, *RMSE*, *MAPE*, dan *SMAPE* sebagai metrik penunjang. Pengujian Model *N-BEATS* dilakukan dengan 3 skema. Hasil dari penelitian ini menunjukkan bahwa nilai inflasi dapat diprediksi menggunakan *N-BEATS*. Melalui proses pengujian model, skema 80% *Train* 20% *Test* menunjukkan hasil terbaik dengan nilai *MAE* sebesar 0.297, *RMSE* sebesar 0.473, *MAPE* sebesar 9.42 %, *SMAPE* sebesar 10.00%

ABSTRACT

Alam S, Laksamana Sulthan. 2026. **Application of the *N-BEATS* method for forecasting Indonesian inflation.** Thesis. Informatics Engineering Study Program Faculty of Science and Technology Maulana Malik Ibrahim State Islamic University Malang. Advisor: (I) Dr. Fachrul Kurniawan ST., M.MT ., IPU (II) Dr. M. Imamudin Lc, MA.

One of the economic challenges is inflation, and this is an indicator of a nation's economic growth and resilience to the influence of other countries. Indonesia, as one of the world's economic powers, also experiences inflation fluctuations. This inflation is often difficult to predict with high accuracy using conventional methods. The availability of accurate and patterned data allows for accurate projections. This study aims to apply the Deep Learning algorithm, namely the multivariate Neural Basis Expansion Analysis for Interpretable Time Series (N-BEATS), to predict Indonesia's future inflation rate. The research method begins with collecting historical inflation data, the pre-processing stage, designing the N-BEATS architecture consisting of stacks and blocks to capture trends and seasonality, followed by the model testing stage. For model evaluation, MAE RMSE, MAPE, and SMAPE will be used as supporting metrics. The N-BEATS model testing was carried out with three schemes. The results of this study indicate that inflation rates can be predicted using N-BEATS. Through the model testing process, the 80% Train 20% Test scheme showed the best results with an MAE value of 0.297, RMSE of 0.473, MAPE of 9.42%, SMAPE of 10.00%.

Key words: *N-BEATS, Forecasting, Indonesia Inflation, Deep Learning, Time Series Analysis*

الملخص

عالم، لقمان سلطان (2026) تطبيق طريقة *N-BEATS* للتنبؤ بالتضخم في إندونيسيا. رسالة جامعية، قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم مالانج الإسلامية الحكومية. المشرف: (الدكتور فخر الكورنياوان، ماجستير؛ الثاني) الدكتور محمد إمام الدين، ماجستير.

الكلمات المفتاحية: *N-BEATS*، التنبؤ، التضخم في إندونيسيا، التعلم العميق، تحليل السلاسل الزمنية.

يُعد التضخم أحد التحديات الاقتصادية، وهو مؤشر على النمو الاقتصادي للدولة وقدرتها على الصمود في وجه تأثيرات الدول الأخرى. وتشهد إندونيسيا، باعتبارها إحدى القوى الاقتصادية العالمية، تقلبات تضخمية. وغالبًا ما يصعب التنبؤ بهذا التضخم بدقة عالية باستخدام الأساليب التقليدية. إلا أن توفر بيانات دقيقة ومنظمة يُتيح إمكانية إجراء توقعات دقيقة. تهدف هذه الدراسة إلى تطبيق خوارزمية التعلم العميق، وتحديدًا تحليل التوسع الأساسي العصبي متعدد المتغيرات للسلاسل الزمنية القابلة للتفسير (*N-BEATS*)، للتنبؤ بمعدل التضخم المستقبلي في إندونيسيا. تبدأ منهجية البحث بجمع بيانات التضخم التاريخية، ثم مرحلة المعالجة المسبقة، وتصميم بنية *N-BEATS* التي تتكون من طبقات وكتل لرصد الاتجاهات والموسمية، تليها مرحلة اختبار النموذج. ولتقييم النموذج، سيتم استخدام مقاييس *MAE* و *RMSE* و *MAPE* و *SMAPE* كمؤشرات داعمة. وقد أُجري اختبار نموذج *N-BEATS* بثلاثة مخططات. وتشير نتائج هذه الدراسة إلى إمكانية التنبؤ بمعدلات التضخم باستخدام *N-BEATS* من خلال عملية اختبار النموذج، أظهر مخطط التدريب بنسبة 80% والاختبار بنسبة 20% أفضل النتائج بقيمة *MAE* تبلغ 0.297، و *RMSE* تبلغ 0.473، و *MAPE* تبلغ 9.42%، و *SMAPE* تبلغ 10.00%..

BAB I

PENDAHULUAN

1.1 Latar Belakang

Ekonomi adalah bidang ilmu sosial yang mempelajari proses berjalannya produksi hingga distribusi barang atau jasa. Proses di dalam ekonomi melibatkan analisis mengenai bagaimana individu, organisasi, pemerintah, bisnis maupun subjek terkait yang secara kolektif memanfaatkan sumber daya yang ada demi memenuhi kebutuhan yang ada. Ekonomi didefinisikan oleh Kenton (2023) sebagai system kompleks berelasi satu sama lain dengan produksi, konsumsi, dan aktivitas terkait bagaimana sumber daya dapat dialokasikan kepada semua partisipan.

Ekonomi menjadi salah satu pilar utama keberlangsungan negara Indonesia. Ekonomi Indonesia didasarkan pada Ideologi Pancasila dimana kebijakan dan semangat gotong royong menjadi salah satu poin penting yang menjadi ciri Ekonomi Indonesia. Karakteristik ekonomi Indonesia dijelaskan dengan Konstitusi Ayat 33 UUD 1945 yang kemudian diamandemen pada 10 Agustus 2022. Terdapat 5 paragraf yang secara garis besar menjelaskan prinsip gotong royong, sumber daya alam vital dikelola negara, sumber daya alam dikelola negara untuk kepentingan masyarakat, ekonomi berlandaskan prinsip demokrasi dan keberlanjutan dari implementasi ayat ini akan diawasi oleh hukum (Eunike, 2015).

Prinsip distribusi dalam Ekonomi Indonesia juga dijelaskan di dalam Al-Quran QS Al-Hasyr ayat 7, yang berbunyi :

مَا آفَاءَ اللَّهِ عَلَى رَسُولِهِ مِنْ أَهْلِ الْقُرَى فَلِلَّهِ وَلِلرَّسُولِ وَلِذِي الْقُرْبَىٰ وَالْيَتَامَىٰ وَالْمَسْكِينِ وَابْنِ السَّبِيلِ كَيْ لَا يَكُونَ دُولَةً ۗ بَيْنَ الْأَغْنِيَاءِ مِنْكُمْ ۚ وَمَا آتَاكُمُ الرَّسُولُ فَخُذُوهُ وَمَا نَهَاكُمْ عَنْهُ فَانْتَهُوا ۚ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ

“Apa saja (harta yang diperoleh tanpa peperangan) yang dianugerahkan Allah kepada Rasul-Nya dari penduduk beberapa negeri adalah untuk Allah, Rasul, kerabat (Rasul), anak yatim, orang miskin, dan orang yang dalam perjalanan. (Demikian) agar harta itu tidak hanya beredar di antara orang-orang kaya saja di antara kamu. Apa yang diberikan Rasul kepadamu terimalah. Apa yang dilarangnya bagimu tinggalkanlah. Bertakwalah kepada Allah. Sesungguhnya Allah sangat keras hukuman-Nya.” (QS Al-Hasyr : 7).

Ayat ini ditafsirkan oleh Wahbah Az-Zuhaili dalam kitab *Tafsir Al-Munir Fi Al-'Aqidah wa al-Syari'ah wa al-Manhaj* sebagai proses distribusi harta yang bersumber dari rampasan perang. Potongan Tafsir Al-Munir menjelaskan terkait hal ini :

“Harta rampasan fai” Yang diberikan Allah kepada Rasul-Nya (yang berasal) dari penduduk beberapa negeri, adalah untuk Allah, Rasul, kerabat (Rasul), anak-anak yatim, orang-orang miskin dan untuk orang-orang yang dalam perjalanan”

Berdasarkan tafsir dari Az-Zuhaili, pokok pembahasan dalam ayat ini membahas terkait pendistribusian kekayaan dan pihak-pihak yang masuk kedalam ketentuan sebagai penerima harta fai. Pemanfaatan harta *Fai* ini bertujuan agar perputaran kekayaan tidak hanya terbatas pada orang kaya saja, namun juga berputar didalam masyarakat, ini yang kemudian disebut sebagai prinsip pemerataan kekayaan yang menjadi likuiditas bagi semua. (Az-Zuhaili sebagaimana dikutip dalam Ananda.,dkk 2025)

Sumber atau portofolio ekonomi Indonesia sangat bervariasi. Terdapat 3 sumber pendapatan negara, yang Pertama adalah Pajak, kedua adalah PNPB atau Penerimaan Negara Bukan Pajak, sektor ini meliputi pemanfaatan Sumber Daya Alam, Pengelolaan Barang Milik Negara dan lain-lain, ketiga adalah hibah atau bantuan tertentu (Adrian Sutedi, 2022).

Dalam perekonomian, inflasi dapat disebabkan beberapa faktor seperti naiknya biaya produksi sebuah komoditas, kelangkaan produk, dan ekspektasi inflasi (Prihadyatama & Kurniawan, 2022). Inflasi yang rendah dan stabil menjadi keuntungan bagi masyarakat. Inflasi yang tidak stabil dan tidak dapat dikendalikan dapat menjadi beberapa masalah diantaranya adalah standar hidup masyarakat yang menurun dan pendapatan riil masyarakat akan terus menurun (Priyono & Handayani, 2021).

Salah satu poin dalam Al-Quran yang dapat menjadi salah satu tindakan preventif penekan inflasi yang dapat dimulai dari Individu, diantaranya adalah melakukan investasi yang produktif dan *asset* nyata, dan menghindari pasar investasi spekulatif. Seperti yang disampaikan melalui Surat An-Nisa ayat 29 yang berbunyi.

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ وَلَا تَقْتُلُوا أَنْفُسَكُمْ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

“Wahai orang-orang yang beriman, janganlah kamu memakan harta sesamamu dengan cara yang batil (tidak benar), kecuali berupa perniagaan atas dasar suka sama suka di antara kamu. Janganlah kamu membunuh dirimu. Sesungguhnya Allah adalah Maha Penyayang kepadamu.” (QS Annisa : 29).

Wahbah Az-Zuhaili dalam menafsirkan ayat tersebut sebagai peringatan untuk jangan mengambil harta dengan cara yang haram dalam proses jual beli, merampas, dan menipu. Akan tetapi diperbolehkan untuk mengambil harta selainmu dengan cara dagang yang lahir dari konsensus dan persetujuan kedua belah pihak. Kesepakatan dan *Taradhi* (saling rela) merupakan prinsip fundamental dari ekonomi yang sehat (Az-Zuhaili, 1997, sebagaimana dikutip dalam Taufiq, 2018)

Tiap tahunnya Indonesia memiliki target penetapan inflasi. Koordinasi ini dilakukan dalam perjanjian kerjasama antara Bank Indonesia dengan Kementerian Keuangan (PMK No 101/PMK010/2021) tentang sasaran Inflasi Indonesia di masa mendatang. Proses *forecasting* atau prediksi dapat digunakan untuk meramal *trajectory* dari sasaran Inflasi Indonesia ke depan. Dalam penelitian ini penulis menggunakan metode *N-BEATS* untuk melakukan *forecasting* inflasi Indonesia ke depannya.

N-BEATS adalah algoritma *deep neural* berbasis *backward* dan *forward residual links* dan *stack* di dalam yang terkoneksi secara penuh satu sama lain (Binte Habib, 2022). *N-BEATS* merupakan algoritma berbasis *deep learning* murni dimana arsitektur ini dibangun dengan tujuan mengeksplorasi potensial *deep learning* murni untuk proses *forecasting* data *time-series*.

Keunggulan yang sekaligus menjadi alasan utama penggunaan algoritma *N-BEATS* untuk *forecasting* data Inflasi adalah Arsitektur yang tergolong baru, karena menggunakan *deep learning* murni sebagai basisnya. Hal ini memungkinkan adanya eksplorasi terkait tentang algoritma baru ini. Kedua adalah

akurasi peramalan yang lebih baik dari *Hybrid LSTM* dan *Holt-Winters Statistical* sebesar 3%. Diharapkan penelitian ini mampu memberikan gambaran tentang bagaimana implementasi metode *N-BEATS* untuk prediksi angka inflasi Indonesia.

1.2 Pernyataan Masalah

Berdasarkan latar belakang yang telah dikemukakan, identifikasi masalah di dalam penelitian ini adalah bagaimana implementasi metode *N-BEATS* dalam melakukan *forecasting* inflasi Indonesia dalam analisis data *time-series*.

1.3 Batasan Masalah

Dari Uraian yang telah disampaikan sebelumnya. Berikut adalah batasan masalah yang digunakan di dalam penelitian ini :

1. Data yang digunakan adalah data inflasi Indonesia dari Januari 2003 - Maret 2024, yang diambil website Bank Indonesia. Kemudian *USD-IDR Exchange Rate* yang diambil dari *Yahoo finance* dan *Monthly Indonesian Oil Price Marker* yang diambil dari riset pribadi penulis
2. Model *forecasting* yang digunakan dalam penelitian ini hanya berfokus pada metode *N-BEATS multivariate* atau *N-BEATSx* dan tidak mempertimbangkan pendekatan regresi antar variabel dalam penentuan inflasi.
3. Parameter dalam *forecasting* menggunakan data timeline inflasi tiap bulannya.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah mengetahui implementasi metode *N-BEATS* dalam melakukan *forecasting* inflasi Indonesia dalam analisis data *time-series*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan pemahaman tentang penerapan metode *N-BEATS* dalam *forecasting* inflasi Indonesia berbasis data *time-series*. Dengan demikian, hasil penelitian ini dapat digunakan untuk mengevaluasi tingkat akurasi prediksi inflasi, serta memberikan wawasan bagi peneliti dan praktisi ekonomi dalam mengoptimalkan model *forecasting*. Selain itu, penelitian ini juga dapat menjadi referensi dalam pengembangan metode prediksi yang lebih akurat dan mendukung pengambilan keputusan dalam kebijakan moneter di Indonesia.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Terdapat beberapa studi sebelumnya yang menunjukkan pengaplikasian Algoritma *N-BEATS* dalam melakukan *forecasting*.

Bulatov (2020) melakukan penelitian mengenai *forecasting* harga Bitcoin dengan menggunakan *N-BEATS. Dataset* yang digunakan didalam penelitian ini berasal dari Bitstamp Exchange dengan rentang waktu September 2012 – Oktober 2020. Terdapat 3 model ujicoba dalam penelitian, yaitu model dengan *dataset* per jam, *dataset* per hari, dan *dataset* per menit. Penelitian ini menghasilkan parameter model terbaik dengan menggunakan data lampau 3 hari sebelumnya, dan batas *forecasting* di 1 hari. *N-BEATS* kemudian dibandingkan dengan metode lain seperti *LSTM* dan *ARIMA*. Hasil dari *N-BEATS* dan perbandingan metode *forecasting* lain kemudian di presentasikan dengan tabel perbandingan. Hasil dari evaluasi model *RMSE* dan *MAPE* dari ketiga algoritma *forecasting* tersebut menunjukkan bahwa *N-BEATS* hamper unggul di semua jenis ujicoba, dengan nilai *RMSE* dan *MAPE* di data per-hari sebesar 308.859 & 2.261 %, di data per-jam sebesar 59.303 dan 0.388%; kalah dengan *ARIMA*, di per-menit 13.678 & 0.096%

Singh & Alam (2024) mengaplikasikan algoritma *N-BEATS* untuk melakukan *forecasting* jangka pendek di dalam Smart Grid Environment. Penelitian ini bertujuan untuk melakukan *forecasting* meliputi 5 *dataset* yaitu : *Smart Grid Load, Electricity Price, Solar Photovoltaic, Wind-Turbine based*

power generation, yang merupakan bagian dari Smart Grid Environment. Proses *forecasting* menggunakan *dataset* dari 3 sumber, meliputi Canadian Website Provinsi Ontario untuk data *Electricity Price*, *WT*, dan *load demand*, PLTS Uluru Australia untuk Solar PV Generation, dan IEEE website untuk *EV charging* data wilayah London. *pipeline* Model *N-BEATS* dilakukan *hyperparameter* dengan 5000 *epoch*, 512 *neurons*, 4 *layers*, dan 30 *stacks*. *Pipeline* yang digunakan *N-BEATS* ini sama untuk *dataset multivariate* dan *univariate*. Pengaturan *hyperparameter* ini disesuaikan dengan kebutuhan *dataset* untuk dapat memberikan hasil yang lebih akurat. Selanjutnya dilakukan studi komparasi dengan metode lain yaitu, *ANN*, *SVM*, *CNN*, *LSTM*, *ARIMA*, *MC-LSTM*, *RF*. Evaluasi model kemudian menggunakan *MAPE*, *MAE*, *RMSE*. Hasil dari evaluasi Model menunjukkan untuk *N-BEATS* hampir unggul di *setiap* metrik. Berikut adalah hasil *MAPE*, *MAE*, *RMSE* untuk *datasets* yang di *forecast* dengan menggunakan *N-BEATS* secara berurutan, *Load Demand* dengan hasil 0.92 %, 142.79 & 199.68, *Wind Speed* dengan Hasil 11.93%, 1.40, 2.12, *Electricity Price* dengan 16.6%, 3.18, 4.46.

Liu et al., (2023) melakukan penelitian tentang prediksi harga indeks saham S&P 500. Penelitian ini menggunakan *dataset* dari sejumlah 500 stok S&P dari Google Finance API, data berasal dari April 2017 hingga Agustus 2017, Algoritma *N-BEATS* kemudian dibandingkan dengan algoritma *Forecasting* lainnya, meliputi *CNN*, *TCN*, *RNN*, *LSTM*, *GRU*, *ViT*, dan *MLP*. Metrik Evaluasi yang digunakan ada empat, meliputi *COR*, *R2*, *MAPE*, *RMSE*. Dari pengujian

tersebut *N-BEATS* memberikan hasil *forecasting* yang paling akurat, dengan nilai *COR* 0.9998, *R2* 0,9996, *MAPE* 0.02%, dan *RMSE* 0.8242.

Bhatti et al. (2023) A. Bhatti et al., (2023). Melakukan penelitian untuk memprediksi kondisi vital pasien dengan menggunakan *N-BEATS*. Deteksi sepsis atau kondisi darurat dari pasien sangat krusial untuk dapat memberikan hasil yang terbaik. Peran *forecasting* disini dapat memberikan *insight* kepada para dokter untuk melakukan tindakan. Proses *forecasting* ini akan menggunakan *dataset* dari *eICU collaborative research* dari St. Mary Hospital Seoul, kemudian membandingkan dengan data actual untuk lebih memahami kondisi pasien dan efek obat bagi pasien. Metrik evaluasi yang digunakan dalam penelitian ini adalah *MSE*, *MAPE* dan *DTW*, dengan hasil terbaik $18.52e^{-4}$, 7.60, dan 17.63e. Hasil penelitian ini adalah tingkat kematian jauh lebih besar (92%) apabila dari actual dan data *forecasting* mendekati satu sama lain, berbanding terbalik ketika data tidak mendekati (81%).

Jossou et al. (2022) melakukan penelitian untuk prediksi sinyal *EHG* untuk proses kelahiran dalam masa kehamilan penuh. Penelitian ini bertujuan untuk menggunakan *N-BEATS* sebagai algoritma *forecasting* untuk memprediksi sinyal *EHG*. *EHG* adalah atau Electorhystogram adalah sinyal yang merepresentasikan kontraksi otot uterus, dimana di beberapa penelitian *EHG* menjadi salah satu indikator kondisi pasien dalam proses melahirkan. *N-BEATS* digunakan untuk melakukan *forecasting* pada kontraksi *EHG* pada pasien. *Dataset* yang digunakan untuk *training* menggunakan database *TPEHG* milik Physiobank. Metrik evaluasi menggunakan *SMAPE*. Hasil *Forecasting* dari *N-BEATS* kemudian akan diekstrak

dan akan dimasukkan ke algoritma klasifikasi demi mendapatkan hasil *EHG* yang lebih akurat. Hasil penelitian ini menunjukkan bahwa, hasil *forecasting N-BEATS* yang kemudian diklasifikasikan oleh *XGBoost* dapat memberikan hasil akurasi sebesar 99%.

Prasad et al. (2022) melakukan penelitian untuk memprediksi gelombang panas laut dengan menggunakan *N-BEATS*. Dalam studi ini *dataset* yang digunakan berasal dari NOAA OISST v2.1, data yang di *forecasting* adalah suhu permukaan laut. Studi komparasi menggunakan *Random Forest* untuk perbandingan dengan algoritma *N-BEATS*. Adapun untuk metrik evaluasi yang digunakan adalah *RMSE* dan *MAE*. Region yang digunakan sebagai uji *forecasting* meliputi 4 bagian, yaitu daerah semenanjung Alaskan dan Laut Bering (AL), Timur Laut Pasifik (NEP), Pantai Barat Australia (WA), dan Laut China Selatan (ECS). Hasil dari penelitian ini menunjukkan bahwa kedua model memberikan hasil yang akurat, dengan kedua model secara seimbang mengungguli satu sama lain. Proses penghitungan akurasi dilakukan dengan menghitung rata-rata akurasi dalam periode 12 bulan. Hasil akurasi menunjukkan bahwa *N-BEATS* dan *Random Forest* untuk Region AL memiliki akurasi 88.00 dan 88.01, untuk region NEP memiliki akurasi 90.34 dan 90.31, untuk region WA memiliki akurasi 86.92 dan 86.33, untuk region ECS memiliki akurasi 85.70 dan 85.67.

Serta, Hasanah (2023) melakukan penelitian tentang peramalan BI Rate di Indonesia dengan menggunakan model *ARIMA (Autoregressive Integrated Moving Average)*. Penelitian ini menggunakan data historis BI Rate bulanan

periode Januari 2014 hingga September 2023, yang dinormalisasi menggunakan metode *Min-Max Normalization*, lalu dianalisis menggunakan pengujian *Augmented Dickey Fuller (ADF)* untuk menentukan tingkat *kestasioneran* data. Berdasarkan pengujian statistik *AIC*, *SIC*, dan *HQC*, dipilihlah model *ARIMA* (1,1,0) yang menghasilkan prediksi BI Rate periode Desember 2023 sampai April 2024 dengan tren penurunan secara konsisten.

Dan juga, Zein et al. (2024) melakukan penelitian tentang prediksi harga saham PT Bank Central Asia Tbk menggunakan metode *Neural Basis Expansion Analysis for Interpretable Time Series (N-BEATS)*. Arsitektur *N-BEATS* terdiri atas beberapa *stack*, di mana masing-masing *stack* memiliki sejumlah blok dasar yang terdiri dari jaringan *Fully Connected (FC)* berlapis dengan fungsi aktivasi *ReLU*, menghasilkan dua *output* berupa *backcast* untuk merekonstruksi pola data masa lalu dan *forecast* sebagai prediksi nilai di masa depan; setiap blok secara bertahap memperbaiki prediksi melalui mekanisme *residual stacking*. Model *N-BEATS* menghasilkan prediksi yang lebih akurat dengan *Mean Absolute Percentage Error (MAPE)* sebesar 1,05%, sehingga direkomendasikan sebagai metode unggul dalam meramalkan harga saham di pasar Indonesia.

Dari studi yang menerapkan algoritma *N-BEATS* tersebut, dapat kita petakan ke dalam Tabel 2.1

Tabel 2 1 Studi Literatur

No	Peneliti dan Judul	Metodologi	Hasil
1	Bulatov (2020) <i>Forecasting Bitcoin Prices Using N-BEATS Deep Learning Architecture</i>	<i>Dataset</i> yang digunakan di dalam penelitian ini berasal dari Bitstamp Exchange dengan rentang waktu September 2012 – Oktober 2020.	Hasil <i>forecasting</i> menunjukkan bahwa <i>N-BEATS</i> hampir unggul di semua jenis ujicoba, dengan nilai <i>RMSE</i> dan <i>MAPE</i> di data per-hari sebesar 308.859 & 2.261 %, di data

			per-jam sebesar 59.303 dan 0.388%; kalah dengan <i>ARIMA</i> , di per-menit 13.678 & 0.096%
2	Singh & Alam (2024) <i>Short-Term Forecasting in Smart Grid Environment using N-BEATS</i>	Proses <i>forecasting</i> menggunakan <i>dataset</i> dari 3 sumber, meliputi Canadian Website Provinsi Ontario untuk data harga listrik, <i>WT</i> , dan <i>load demand</i> , PLTS Uluru Australia untuk <i>Solar PV Generation</i> , dan IEEE website untuk <i>EV charging</i> data wilayah London	Berikut adalah hasil <i>MAPE</i> , <i>MAE</i> , <i>RMSE</i> untuk <i>datasets</i> yang di <i>forecast</i> dengan menggunakan <i>N-BEATS</i> secara berurutan, <i>Load Demand</i> dengan hasil 0.92 %, 142.79 & 199.68, <i>Wind Speed</i> dengan Hasil 11.93%, 1.40, 2.12, <i>Electricity Price</i> dengan 16.6%, 3.18, 4.46.
3	Liu et al. (2023) <i>The S&P Index Prediction Based on N-BEATS</i>	Penelitian ini menggunakan <i>dataset</i> dari sejumlah 500 stok S&P dari Google Finance API, data berasal dari April 2017 hingga Agustus 2017	Metrik Evaluasi yang digunakan ada empat, meliputi <i>COR</i> , <i>R2</i> , <i>MAPE</i> , <i>RMSE</i> . Dari pengujian tersebut <i>N-BEATS</i> memberikan hasil <i>forecasting</i> yang paling akurat, dengan nilai <i>COR</i> 0.9998, <i>R2</i> 0,9996, <i>MAPE</i> 0.02%, dan <i>RMSE</i> 0.8242.
4	Bhatti et al. (2023) <i>Interpreted Forecasted Vital Signs Using N-BEATS in Sepsis Patients</i>	Proses <i>forecasting</i> ini akan menggunakan <i>dataset</i> dari <i>eICU collaborative research</i> dari St. Mary Hospital Seoul	Metrik evaluasi yang digunakan dalam penelitian ini adalah <i>MSE</i> , <i>MAPE</i> dan <i>DTW</i> , dengan hasil terbaik 18.52e~4, 7.60, dan 17.63e
5	Jossou et al. (2022) <i>N-Beats as an EHG Signal Forecasting Method for Labour Prediction in Full Term Pregnancy</i>	<i>Dataset</i> yang digunakan untuk <i>training</i> menggunakan database <i>TPEHG</i> milik Phsyiobank	Hasil <i>Forecasting</i> dari <i>N-BEATS</i> kemudian akan diekstrak dan akan dimasukan ke algoritma klasifikasi demi mendapatkan hasil <i>EHG</i> yang lebih akurat. Hasil penelitian ini menunjukkan bahwa, hasil <i>Forecasting N-BEATS</i> yang kemudian diklasifikasikan oleh <i>XGBoost</i> dapat memberikan hasil akurasi sebesar 99%.
6	Prasad et al. (2022) <i>Forecasting Marine Heatwaves using Machine Learning</i>	Dalam studi ini <i>dataset</i> yang digunakan berasal dari <i>NOAA OISST v2.1</i> , dan data yang di <i>forecasting</i> adalah suhu permukaan laut	Hasil akurasi menunjukkan bahwa <i>N-BEATS</i> dan Random Forest untuk Region AL memiliki akurasi 88.00 dan 88.01, untuk region NEP memiliki akurasi 90.34 dan 90.31, untuk region WA memiliki akurasi 86.92 dan 86.33, untuk region ECS memiliki akurasi 85.70 dan 85.67.
7	Hasanah (2023) <i>Peramalan BI Rate Di Indonesia Dengan Metode Time Series Model</i>	Metodologi penelitian ini menggunakan model <i>ARIMA</i> dengan tahap identifikasi <i>kestasioneran</i> data melalui uji <i>Augmented Dickey Fuller</i>	Hasil penelitian menunjukkan bahwa model terbaik untuk peramalan BI Rate adalah <i>ARIMA</i> (1,1,0). <i>Forecasting</i> dengan model ini

	<i>Arima</i>	(<i>ADF</i>), diikuti penentuan model terbaik berdasarkan nilai <i>AIC</i> , <i>SIC</i> , dan <i>HQC</i> . Selanjutnya, dilakukan pemeriksaan diagnostik <i>residual</i> untuk memastikan model memenuhi syarat <i>white noise</i> sebelum digunakan untuk peramalan nilai BI Rate.	memperlihatkan tren penurunan nilai BI Rate dari Desember 2023 hingga April 2024.
8	Zein et al. (2024) <i>Indonesian Stock Price Prediction Using Neural Basis Expansion Analysis for Interpretable Time Series Method</i>	Penelitian ini menggunakan metode deep learning <i>Neural Basis Expansion Analysis for Interpretable Time Series (N-BEATS)</i> untuk meramalkan harga saham PT Bank Central Asia Tbk berdasarkan data historis 10 tahun yang dinormalisasi dengan min-max normalization. Akurasi prediksi <i>N-BEATS</i> dibandingkan dengan model <i>LSTM</i> menggunakan parameter <i>Mean Absolute Percentage Error (MAPE)</i> .	Hasil penelitian menunjukkan bahwa model <i>N-BEATS</i> memberikan hasil prediksi harga saham yang lebih baik dibandingkan <i>LSTM</i> dengan nilai <i>Mean Absolute Percentage Error (MAPE)</i> sebesar 1,05%. Dengan demikian, <i>N-BEATS</i> direkomendasikan sebagai metode yang lebih akurat dan interpretatif dalam memprediksi pergerakan harga saham di pasar Indonesia

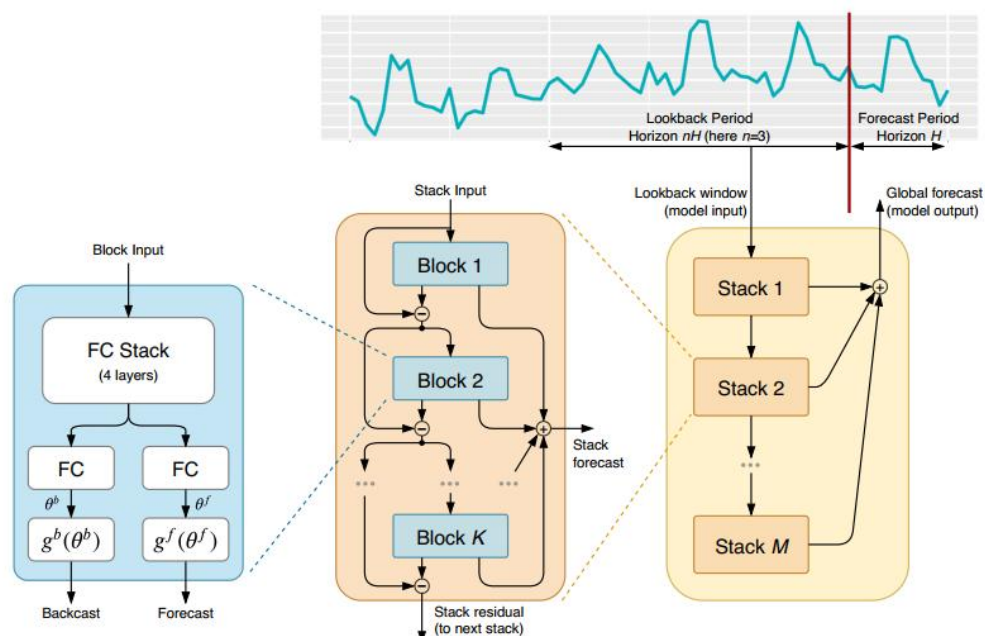
2.2 *N-BEATS (Neural Basis Expansion Analysis for Interpretable Time Series)*

N-BEATS merupakan singkatan dari *Neural Basis Expansion Analysis for Interpretable Time Series*. *N-BEATS* hadir sebagai aspirasi untuk menghadirkan algoritma *Deep Learning* murni untuk proses *Forecasting* (Oreshkin, Carпов, Chapados, & Bengio, 2019). *Deep Learning* murni pada umumnya unggul di bidang *computer vision* dan *NLP (Natural Language Processing)*, Namun (Petropoulos dkk., 2022) menyebutkan bahwa pendekatan klasik statistikal untuk *Forecasting data Time-Series* masih jauh lebih unggul bila dibandingkan dengan *ML* dan *DL* (Oreshkin dkk., 2019). *N-BEATS* kemudian muncul sebagai *proof-of-concept* untuk pembuktian bahwa penggunaan *ML* murni mampu melakukan *forecasting data* yang akurat. Hal ini dibuktikan dengan *N-BEATS* berhasil mengalahkan pemenang *M4; Markidaris Competition*, merupakan kompetisi

terbuka untuk membandingkan akurasi metode-metode *forecasting*, yang menggunakan *Hybrid LSTM-Holt-Winters*, dengan peningkatan akurasi 11% untuk proses *benchmark* statistik dan 3% lebih baik dari pemenang *M4* (Oreshkin et al., 2019).

Oreshkin et al. (2019) menjelaskan bahwa di dalam arsitektur *N-BEATS* terdapat beberapa prinsip yang menjadi kunci dari model ini. Pertama adalah arsitektur dasar yang harus sederhana, umum namun tetap ekspresif. Kedua adalah arsitektur tidak boleh dependen dengan fitur spesifik *time series* atau *input* scaling. Terakhir adalah arsitektur harus bisa untuk di *extendable* agar hasil dapat lebih mudah di interpretasikan.

Arsitektur *N-BEATS* dapat di representasikan dengan menggunakan diagram berikut.



Gambar 2. 1 Arsitektur *N-BEATS*
Sumber: (Zein dkk., 2024)

Dari gambar tersebut dapat ditelaah secara lebih lanjut untuk arsitektur dan bagaimana proses-proses yang berjalan di dalam algoritma *N-BEATS*..

2.2.1. *Basic Block Building*

Block pada *N-BEATS* memiliki *2-layer* yang terkoneksi penuh satu sama lain (Nayak dkk., 2024). Simbol ℓ kita asumsikan sebagai urutan ke n , *l-block* nantinya akan menerima sebuah *input* x_l dan 2 *output vector*, yaitu *backcast* x_l dan *forecast* y_l . Data yang masuk ke *block* yang paling pertama adalah garis besar model *input* yang akan digunakan, contohnya adalah *dataset* inflasi. Data pertama dari x akan berupa ditentukan berdasarkan nilai *forecast Horizon* (H), apabila nilai $H = 5$ atau *5 steps*; *steps* ini akan bergantung pada konteks *dataset*, apabila *input* data yang digunakan adalah *monthly*, nilai *step* dapat diinterpretasikan sebagai bulan, maka nilai *inputnya* apabila disesuaikan dengan standar adalah $2H$ (10 Step) hingga $7H$ (35 Step). *Input* dari x_l selanjutnya adalah menggunakan *output residual* dari *block* sebelumnya (Oreshkin dkk., 2019). Dua *vector output* dari x_l , adalah y_l , yang merupakan hasil *forecast* dari length H , dan x_l , merupakan hasil *backcast* atau prediksi nilai lampau.

Secara garis besar, *basic building block* terbagi menjadi 2 bagian. Bagian pertama adalah *fully-connected-network* yang menghasilkan masing-masing *omegab* dan *omegaf*. *FC stack* berisi *neuron layer* yang terkoneksi secara penuh, bagian ini bertugas untuk melakukan ekstraksi data yang akan digunakan. Setiap *neuron* melakukan *linear transformation* pada *input*, kemudian dilanjutkan dengan aktivasi non-linear seperti *ReLU*.

Jumlah *layer neuron*, dan jumlah *neuron* itu sendiri dapat diatur melalui *hyperparameter N-BEATS*. Proses dilanjutkan dengan partisi *FC stack* menjadi 2, satu kemudian menghasilkan *omega f* dan satu menghasilkan *omega b*. *Omega f* berisi *sequence* dari *FC stack* yang bertugas menangkap *Temporal Dependencies* dan pola di masa lampau, untuk melakukan estimasi dan rekonstruksi nilai masa lampau. *Omega b* berisi *sequence* dari *FC stack* yang bertugas untuk menangkap pola dan *trend* untuk memprediksi nilai masa depan. Bagian kedua adalah *backward gb(omega b)* yang berasal dari *omega b*, dan *forward gf(omega f)* yang berasal dari *omega f*. Dari keduanya kemudian digunakan sebagai *backcast xl* dan *forecast yl*.

Operasi yang berjalan pada bagian pertama dari *l-block* dapat di representasikan dengan persamaan berikut :

$$\begin{aligned} \mathbf{h}_{\ell,1} &= \text{FC}_{\ell,1}(\mathbf{x}_{\ell}), \quad \mathbf{h}_{\ell,2} = \text{FC}_{\ell,2}(\mathbf{h}_{\ell,1}), \quad \mathbf{h}_{\ell,3} = \text{FC}_{\ell,3}(\mathbf{h}_{\ell,2}), \quad \mathbf{h}_{\ell,4} = \text{FC}_{\ell,4}(\mathbf{h}_{\ell,3}) \\ \theta_{\ell}^b &= \text{LINEAR}_{\ell}^b(\mathbf{h}_{\ell,4}), \quad \theta_{\ell}^f = \text{LINEAR}_{\ell}^f(\mathbf{h}_{\ell,4}). \end{aligned} \quad (2.1)$$

l-block kemudian akan disusun secara hirarkis seperti tabel. 2.1 dan *input* dari *l-block* adalah *stack residual* yang merupakan subtraksi dari *backcast l-2 block* dengan *l-1 block*. Susunan hirarkial ini yang kemudian disebut sebagai *stack*.

2.2.2. *Doubly Residual Stacking*

He et al. (2016) menjelaskan di dalam *paper* (Oreshkin dkk., 2019) bahwa klasikal *residual network* menambah *input* ke dalam *stack layer* ke dalam *outputnya* sebelum digunakan oleh *stack* selanjutnya. Kelemahan

dari klasikal *residual* method adalah hasilnya yang sulit untuk di interpretasikan. *N-BEATS* kemudian memberikan solusi berupa *doubly residual stack*. Solusi ini dapat dilihat di tabel 2.1. di gambar bagian tengah dan kanan. Arsitektur *N-BEATS* memiliki 2 cabang *residual*, yang pertama adalah *backcast* dan yang kedua adalah *forecast*, yang kemudian berjalan pada tiap *stack*-nya (Oreshkin dkk., 2019) . Berikut adalah persamaan dari proses *doubly residual stacking*.

$$\mathbf{x}_\ell = \mathbf{x}_{\ell-1} - \widehat{\mathbf{x}}_{\ell-1}, \quad \widehat{\mathbf{y}} = \sum_{\ell} \widehat{\mathbf{y}}_{\ell}. \quad (2. 2)$$

Pada *stack N-BEATS*, data pertama yang masuk adalah data yang akan didasarkan pada nilai *Horizon* H dan pengaturan *input* yang umumnya menggunakan 2H hingga 7H. Untuk data selanjutnya di dalam *block*, akan menggunakan hasil subtraksi dari *x_{l-1}* *block* dengan *x_{l-2}* sebagai *input* dari *x_l* *block*. Hal ini berguna untuk menghapus beberapa bagian dari nilai *x_{l-1}* sehingga dapat meningkatkan proses aproksimasi, dan membuat *forecast block* yang ada dibawahnya semakin mudah (Oreshkin dkk., 2019). *Block-block* ini akan membentuk *stack*, dan proses ini akan berjalan hingga ke level hierarki antar *stack* dengan *input* dari *stack* sebelumnya. Struktur seperti ini membuat proses *backpropagation* lebih *fluid* (Oreshkin dkk., 2019). Untuk *output forecast* *y_l* dari *block* akan diagregat di level *block*. Selanjutnya hasil agregat *forecast* dari tiap *block* akan diagregat di level *stack*. Keuntungan dari arsitektur ini adalah adalah *hierarchical decomposition* (Oreshkin dkk., 2019). Dari penjelasan tersebut, dapat disimpulkan bahwa arsitektur *N-BEATS* terdiri dari susunan *block*

secara hierarki yang akan memberikan *input* kepada *block* dibawahnya. Proses ini kemudian akan dikelompokkan ke dalam *Stack*. Dan *Stack* akan melakukan proses yang sama dan akan memberikan *input* kepada *stack* dibawahnya.

2.2.3. Interpretability

Ada 2 konfigurasi yang ditawarkan oleh *N-BEATS*. Pertama adalah *Generic Deep Learning*, yang kedua adalah *Interpretable Architecture*.

Arsitektur *Generic DL* membuat *gb* dan *gf* menjadi proyeksi linear dari *output layer* sebelumnya. Output *1-block* dari arsitektur ini adalah sebagai berikut:

$$\hat{\mathbf{y}}_{\ell} = \mathbf{V}_{\ell}^f \boldsymbol{\theta}_{\ell}^f + \mathbf{b}_{\ell}^f, \quad \hat{\mathbf{x}}_{\ell} = \mathbf{V}_{\ell}^b \boldsymbol{\theta}_{\ell}^b + \mathbf{b}_{\ell}^b. \quad (2.3)$$

Interpretasi dari model ini adalah *FC Layers*; seperti yang dipresentasikan di Tabel 2.1, akan mempelajari predictive decomposition dari nilai partial *forecast* y_l dalam basis *vector* V_f yang dipelajari oleh jaringan (Oreshkin dkk., 2019).

Arsitektur kedua adalah *Interpretable Architecture*. Arsitektur ini merupakan ekspansi dari arsitektur normal dengan menambahkan struktur basis *layer* pada *stack level* (Oreshkin dkk., 2019) . Desain dari *Interpretable Architecture* kemudian dibagi menjadi untuk mempermudah proses interpretasi *output*, yaitu *Trend Model* dan *Seasonality Model*.

Trend Model adalah model dari *Interpretable Architecture* yang memiliki karakteristik fungsi *monotonic* dan fungsi variasi yang rendah.

Konstrain polinomial p dari gbsl dan gfsl digunakan untuk meniru karakteristik dari model ini. Berikut adalah persamaanya :

$$\hat{y}_{s,\ell} = \sum_{i=0}^p \theta_{s,\ell,i}^f t^i. \quad (2.4)$$

Vektor waktu dari $t = [0,1,2 \dots H-2, H-1]$ didefinisikan sebagai *grid* diskret yang berjalan dari 0 hingga $(H-1)/H$, *forecasting* H kedepan.

Seasonality Model, memiliki karakteristik yang regular, memiliki fluktuasi, berulang. Sehingga untuk *seasonality* model, gbsl dan gfsl akan menjadi milik kelas dari fungsi periodic; contoh : $y_t = y_t - \text{segitiga}$. Segitiga ekuivalen dengan nilai periode *seasonal*. Berikut adalah persamaan dari *Seasonality* Model:

$$\hat{y}_{s,\ell} = \sum_{i=0}^{\lfloor H/2-1 \rfloor} \theta_{s,\ell,i}^f \cos(2\pi it) + \theta_{s,\ell,i+\lfloor H/2 \rfloor}^f \sin(2\pi it), \quad (2.5)$$

Secara garis besar *Interpretable Architecture* berisi dua *stack*, yaitu *Trend Stack* dan *Seasonality Stack*. (Oreshkin dkk., 2019) menjelaskan 2 kesimpulan dari penggunaan *Doubly Residual Stacking* yang dikombinasikan dengan prinsip *backcast* dan *forecast*. Pertama adalah *trend* komponen dihapus dari *input* x sebelum dimasukkan kedalam komponen *seasonality*. Kedua adalah *partial forecasting* dari masing-masing *stack* tersedia secara terpisah.

2.3 *N-BEATS multivariate / N-BEATSx*

N-BEATS memiliki varian *multivariate*, yaitu *N-BEATSx*. Dimana varian ini menggunakan arsitektur yang sama dengan *N-BEATS* namun dengan peningkatan dapat menggunakan variabel lain untuk mendukung variabel utama. Variabel lain ini disebut sebagai *Exogenous Feature*, yang dilambangkan dengan tanda x pada *N-BEATSx*. Olivares et al. (2023) menjelaskan bahwa arsitektur *N-BEATS* merupakan improvisasi dari arsitektur *N-BEATS* dengan memanfaatkan *Exogeneous Feature* yang memiliki dependensi terhadap waktu. Dependensi ini mengarah kepada rentang waktu dari variabel utama. Olivares et al, juga menjelaskan bahwa keunggulan dari model ini adalah mengintegrasikan variabel pendukung dengan variabel utama tanpa mengorbankan aspek interpretabilitas model.

Integrasi *Exogeneous Feature* kedalam *N-BEATS* dilakukan dengan mengembangkan substruktur khusus menggunakan metode *convolution*. Dengan metode ini, model dapat membersihkan dan melakukan *encode* pada variabel penunjang, dengan tetap memperhatikan dependensi waktu. Peningkatan ini secara signifikan meningkatkan akurasi metode *N-BEATS* serta meningkatkan kemampuan interpretabilitasnya (Olivares et al, 2023).

Model ini menggabungkan kekuatan dari transformasi non-linear dari neural network dengan fleksibilitas dalam memodelkan pola didalam data. Secara bersamaan, model ini mampu untuk memperhitungkan efek interaksi seperti hari libur dan berbagai variabel penunjang lainnya. Arsitektur *N-BEATSx* memungkinkan dekomposisi prediksi kedalam *level*, *trend* dan *seasonality* serta

mengidentifikasi pengaruh dari *Exogeneous Feature* secara spesifik (Olivares et al, 2023).

2.4 *Forecasting*

Forecasting atau peramalan didefinisikan oleh Heizer & Render (2015) sebagai suatu seni dalam memprediksi suatu peristiwa dimasa mendatang. *Forecasting* bertujuan untuk memprediksi sebuah nilai dimasa mendatang dengan berbasis data historis. Petropoulos et al. (2022) memaparkan teorinya tentang *forecasting*, premis utama dalam teori ini adalah data sekarang dan data di masa lampau dapat digunakan untuk melakukan prediksi data yang akan muncul dimasa mendatang. Dalam data berbasis *time-series* atau deret waktu, diyakini menjadi salah satu sumber utama prediksi nilai masa depan apabila mampu mengidentifikasi pola pada data lampau. Namun proses *forecasting* berkuat kepada aproksimasi, sehingga nilai *absolute* prediksi tidak menjadi perhatian utama. Nilai Aproksimasi dapat berupa poin value, prediction interval, percentile, dan prediksi distribusi total (Petropoulos dkk., 2022). Prosedur *forecasting* akan lebih akurat apabila dilakukan secara aktif, kemudian teori akan muncul sebagai pendukung penjelesan terhadap proses yang terjadi.

Forecasting dapat diklasifikasikan menjadi beberapa bagian, hal ini berdasarkan pengelompokan yang berbeda. Klasifikasi *forecasting* didasarkan pada *horizon* waktu berjumlah tiga. Berikut adalah klasifikasinya menurut (Heizer & Render, 2015).

1. *Forecasting* Jangka Pendek

Forecasting Jangka Pendek memiliki interval waktu hingga 1 tahun, namun pada umumnya dapat memiliki interval < 4 bulan.

2. *Forecasting* Jangka Menengah

Forecasting Jangka Menengah memiliki interval waktu maksimal 3 tahun.

3. *Forecasting* Jangka Panjang

Forecasting Jangka Panjang memiliki Interval waktu 3 tahun bahkan lebih.

Heizer & Render (2015) juga mengklasifikasikan metode *forecasting* menjadi 2 kategori yaitu metode kualitatif dan metode kuantitatif. Metode kualitatif berisi metode eksploratif dan normatif, sedangkan metode Kuantitatif berisi metode *time-series* dan metode kasual (Syakura, Hendaryani, & Ramadhan, 2016).

1. Metode Kualitatif

Metode Kualitatif adalah metode yang dilakukan dengan pendekatan logika. Metode ini digunakan apabila terjadi dispersi informasi yang akan digunakan. Contohnya adalah data di masa lampau tidak bisa digunakan sebagai alat peramalan karena terdapat variabel baru yang membuat data historis menjadi tidak relevan. Teknik yang digunakan di dalam metode ini adalah eksploratif dan normatif

2. Metode Kuantitatif

Metode Kuantitatif adalah metode yang dilakukan dengan asumsi bahwa data historis yang ada dapat diramalkan dengan mencari pola yang ada di

dalamnya. *Forecasting* berjalan dengan analisi data histori kemudian melakukan proyeksi data masa depan (Samudra dkk., 2024). Teknik yang digunakan didalam metode ini adalah Time-series dan Kasual.

Forecasting dapat diaplikasikan. Petropoulos et al. (2022) telah melakukan identifikasi bidang-bidang yang mendapatkan benefit dari *forecasting*. Beberapa bidang yang dapat ditunjang oleh *forecasting* diantaranya adalah operasi dan suplai rantai pasok (*Chain Management*), ekonomi dan finansial, energi, lingkungan, kebutuhan sosial dan demografi, sistem dan manusia, dan lain-lain.

2.5 Time Series


Time Series atau deret waktu adalah kumpulan data sekuensial yang tercatat dalam interval waktu tertentu. *Time Series* dapat diartikan sebagai sekumpulan data yang diamati dalam waktu tertentu, berdasarkan waktu frekuensi pengumpulan yang sama (Rahayu, 2020)

Cochrane (1997) mendefinisikan *time-series* sebagai *vector* dari $x(t), t = 0, 1, 2, \dots$ dimana t merepresentasikan waktu yang berlalu. Variabel $x(t)$ di anggap sebagai variabel *random*. Data pada *time-series* yang berisi satu variabel disebut sebagai *univariate*, sedangkan data yang memiliki lebih dari satu variabel disebut *multivariate*.

Hyndman & Athanasopoulos (2018) menjelaskan bahwa terdapat tiga pola dari *time series*, yaitu *Trend*, *Seasonal*, *Cyclic*. Markiadris (1992) juga mendefinisikan pola *time series*, dengan tambahan adanya pola *Horizontal*.

1. Trend


Trend terjadi ketika ada peningkatan atau penurunan nilai secara berjangka Panjang didalam sebuah data. *Trend* seringkali diartikan sebagai “arah yang berubah” ketika data bergerak dari *trend* peningkatan menjadi *trend* penurunan. Data *trend* tidak selamanya linear, namun terdapat pola yang mengindikasikan adanya proses perubahan data berjangka secara stabil.



Gambar 2. 2 *Trend Pattern Time Series*
Sumber: (Black, 2020)

2. *Seasonal*


Data *Seasonal* terjadi ketika data *time-series* dipengaruhi oleh variabel tertentu yang berjalan dalam waktu tertentu. Contohnya adalah peningkatan jumlah pengunjung tempat wisata pada hari minggu. *Trend Seasonal* selalu konstan dalam waktu tertentu dan frekuensi dalam data yang dapat diidentifikasi.



Gambar 2. 3 *Seasonal Pattern Time Series*
 Sumber: (Bharath, 2021)

3. *Cyclic*

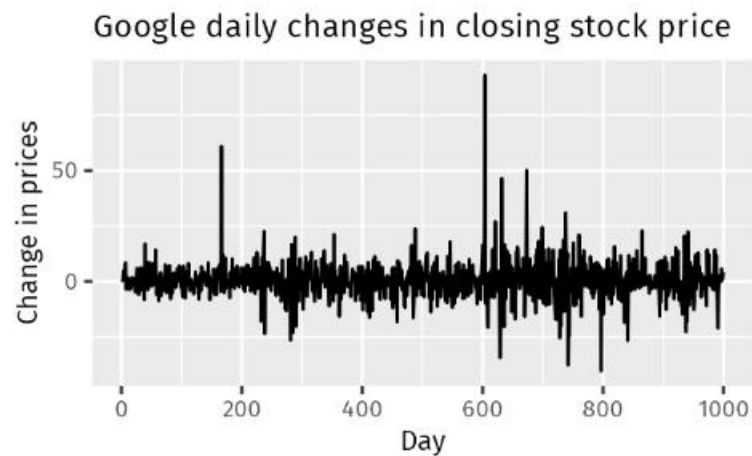
Cyclic terjadi ketika terdapat peningkatan dan penurunan data yang tidak terjadi dalam frekuensi yang tetap. Data ini biasanya mengalami fluktuasi dan secara general, *cyclic* mengalami waktu yang lebih lama dibandingkan dengan data *seasonal*.



Gambar 2. 4 *Cyclic Pattern Time Series*
 Sumber: (Bharath, 2021)

4. *Horizontal*

Markiadris (1992) mendefinisikan pola data ini sebagai pola data yang memiliki fluktuasi. Dan biasanya memiliki nilai *random*.



Gambar 2. 5 *Horizontal Pattern Time Series*
Sumber: (Bharath, 2021)

2.6 Inflasi

Inflasi secara sederhana dapat didefinisikan sebagai peningkatan harga secara umum dan berkelanjutan (Simanungkalit, 2020). Inflasi dapat diidentifikasi dengan peningkatan harga secara massif dan meluas, dan bukan hanya harga daripada beberapa barang saja. (Andrian, 2019) menyebutkan bahwa terdapat 3 aspek dari inflasi. Aspek pertama adalah tendensi, atau kecenderungan peningkatan harga yang terjadi secara umum, Aspek kedua adalah *sustained*, dimana proses peningkatan harga tidak hanya terjadi sekali saja, namun berjalan dalam jangka waktu yang panjang. Aspek ketiga adalah *General Level of Prices*, dimana peningkatan harga ini mencakup harga-harga barang pada umumnya, bukan satu atau dua barang saja.

Peningkatan harga barang secara umum yang menyebabkan inflasi, dapat disebabkan oleh suatu hal. Berikut adalah beberapa teorinya.

1. Teori Kuantitas

Pada teori ini, inflasi disebabkan oleh jumlah uang yang beredar di masyarakat. Harga kemudian akan naik apabila peredaran uang lebih tinggi. Apabila jumlah dari barang tetap, namun uang yang beredar berjumlah 2x lipat, maka lambat laun harga barang akan naik juga 2x lipat (Simanungkalit, 2020) . Hubungan antara jumlah uang yang beredar dengan tingkat harga dilakukan dengan 3 pendekatan, yaitu *Equilibrium of Exchange*, *Cash Balance Equation by Cambridge*, *Income Equation by Cambridge* (Sutawijaya, 2012).

2. Teori Keynes

Teori berpendapat bahwa inflasi terjadi jika masyarakat ingin hidup dengan memanfaatkan sumberdaya secara berlebihan. Ketika tingginya permintaan namun penawaran masih tetap, maka akan memicu meningkatnya harga. Hal yang kemudian terjadi adalah proses perebutan barang atau sumber daya, dimana *demand* jauh lebih tinggi dari *supply*. Hal ini disebut sebagai *Inflationary Gap* (Sutawijaya, 2012).

3. Teori Strukturalis

Teori ini berpendapat bahwa penyebab inflasi diakibatkan oleh kakunya struktur pendukung ekonomi (Simanungkalit, 2020) . Kakunya struktur pendukung ekonomi ini kemudian secara tidak

langsung oleh Sutawijaya (2012) , dimana penyebab inflasi dapat diakibatkan oleh 2 masalah. Pertama adalah ketidakelestisan penerimaan ekspor, dimana keterlambatan penyesuaian harga ekspor yang terjadi. Kedua adalah ketidakelestisan dari supply produksi, dimana terdapat efek domino dari kenaikan harga produksi hingga menyebabkan kenaikan harga barang.

Inflasi sendiri dibagi menjadi beberapa kategori berdasarkan sifatnya. Pertama adalah inflasi ringan, inflasi ringan (*Creeping Inflation*) ditandai dengan laju atau proses inflasi yang rendah (Sutawijaya, 2012) . Inflasi ini biasanya bernilai satu digit pertahun (dibawah 10%). Kenaikan harga pada jenis inflasi ini berjalan secara lambat dan berjalan dalam jangka waktu yang lama. Jenis inflasi yang kedua adalah inflasi menengah (*Galloping Inflation*), inflasi ini ditandai dengan kenaikan harga yang cukup besar dengan presentasi inflasi antara 10% - 30% pertahun (Sutawijaya, 2012) . Kenaikan pada harga kadang berjalan relatif pendek dan mempunyai akselerasi. Terakhir adalah inflasi tinggi (*Hyper Inflation*), merupakan inflasi yang paling parah. Kenaikan harga pada tingkat inflasi bisa melebihi 30%. Masyarakat tidak berkeinginan untuk menyimpan uang (Sutawijaya, 2012).

Inflasi tidak selalu memberikan dampak negatif kepada perekonomian, contoh dalam hal ini adalah inflasi ringan. Inflasi ringan mampu mendorong pergerakan ekonomi (Simanungkalit, 2020) . Pemilik usaha akan menggenjot proses produksi karena kenaikan harga, yang kemudian meningkatkan lapangan

pekerjaan baru. Secara umum inflasi mampu memberikan keuntungan apabila nilainya dibawah 10% (Simanungkalit, 2020).

2.7 *Evaluation Metrik*

Evaluation Metrik dalam konteks *machine learning* adalah proses evaluasi akurasi dari sebuah model dengan menggunakan metrik tertentu. Dalam *forecasting*, *evaluation metrics* digunakan untuk mengukur deviasi nilai *forecast* dengan hasil yang sebenarnya (Baron & Karpinski, 2025).

(Botchkarev, 2019) memberikan rekomendasi untuk pemilihan *Evaluation Metrik*. Terdapat 2 poin secara eksplisit menjelaskan *pre-requisite* dalam memilih *evaluation metrics*; Botchkarev menjabarkan 4 poin dalam memilih metrik.

1. Apabila *evaluation metrics* digunakan untuk data *time-series* dengan skala yang sama dan telah dilakukan prosedur *pre-processing* pada *dataset* (*data cleaning*, deteksi anomaly), maka *Evaluation Metrik* yang disarankan adalah *MAE*, *MdAE*, dan *RMSE*.
2. Apabila *Dataset* kotor dan belum dilakukan *pre-processing*, maka disarankan untuk menggunakan *MASE*, *inRSE*. Hal ini dapat dilakukan dengan catatan : *horizon* harus cukup besar, tidak ada nilai identik, dan faktor normalisasi harus tidak sama dengan nol.

Dalam *paper N-BEATS*, (Oreshkin dkk., 2019) , menggunakan metrik *SMAPE*, *MASE* dan *OWA* untuk melakukan evaluasi model mereka. Metrik ini digunakan untuk meniru *environment* kompetisi M4, seperti yang disampaikan

oleh Oreshkin bahwa *N-BEATS* lebih unggul dari pemenang M4 dengan margin 3%.

2.8 *sMAPE (Symetric Mean Absolute Percentage Error)*

sMAPE merupakan pengembangan dari Metrik *MAPE*, yang bekerja dengan cara menghitung perbedaan relatif antara nilai prediksi dan nilai aktual. *MAPE* memiliki kelemahan pada kurangnya *penalty* pada negatif *error* daripada positif *error*, sehingga hal ini kemudian yang mendasari dibuatnya *sMAPE* oleh Amstrong (Hyndiman., 2021). Berikut adalah persamaan dari *sMAPE* :

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|) / 2} \times 100\% \quad (2.6)$$

Penjelasan:

Y_i = Nilai asli period ke- i

Y_t = Nilai estimasi period ke- i

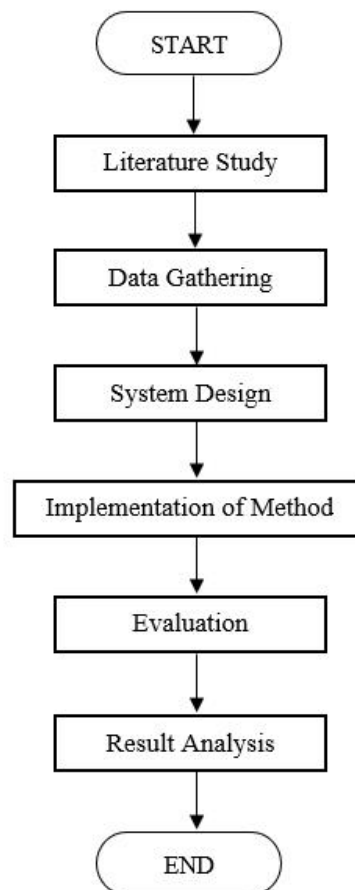
n = Jumlah periode peramalan

BAB III

METODE PENELITIAN

3.1 Desain Penelitian

Desain penelitian akan memberikan gambaran dari penelitian secara garis besar. Desain penelitian ini membahas mengenai penggunaan metode *N-BEATS multivariate* dalam melakukan *forecasting* inflasi Indonesia. Langkah-langkah penelitian yang dilakukan dapat dilihat melalui alur Flowchart pada Gambar 3.1.



Gambar 3. 1 Desain Penelitian

Gambar 3.1 menjelaskan tentang tahapan yang dilalui dalam penelitian *forecasting* inflasi dengan menggunakan metode *N-BEATS multivariate*. Tahap pertama adalah *Literature Study*, yaitu proses mengumpulkan referensi-referensi

studi terkait yang relevan dengan metode *forecasting N-BEATS multivariate*, data *time series*, dan inflasi di Indonesia. Tahap kedua adalah *Data Gathering*, yaitu proses pengumpulan data inflasi Indonesia, nilai tukar USD-IDR dan *Monthly Indonesian Oil Price Marker*, dengan rentang waktu Januari 2003 hingga Desember 2023. Tahap ketiga adalah *System Design*, yaitu proses merancang sistem secara rinci yang mencakup dua modul utama yaitu data *preprocessing* dan pelatihan serta *forecasting* menggunakan metode *N-BEATS multivariate*.

Tahap keempat adalah *Implementation of Method*, yakni implementasi dari model *N-BEATS multivariate* yang sebelumnya sudah dirancang pada tahap desain sistem, meliputi konfigurasi *hyperparameter* dan pelatihan model. Tahap kelima adalah *Evaluation*, yaitu evaluasi hasil prediksi dengan menggunakan metrik evaluasi yang meliputi *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, *Mean Absolute Percentage Error (MAPE)*, dan *Symmetric Mean Absolute Percentage Error (SMAPE)*. Terakhir, tahap keenam yaitu *Result Analysis*, tahap ini berfungsi untuk melakukan komparasi terhadap hasil prediksi inflasi yang diperoleh dari model *N-BEATS multivariate*, termasuk interpretasi dan visualisasi hasil prediksi.

3.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data historis inflasi bulanan Indonesia yang diperoleh dari website resmi Bank Indonesia, data nilai tukar USD-IDR dari *Yahoo finance* dan *Monthly Indonesian Oil Price Marker* yang diambil dari *riset pribadi penulis*.

Data inflasi Indonesia mencakup periode selama kurang lebih 21 tahun, yakni dari Januari 2003 hingga Maret 2024, dengan total sebanyak 256 sampel. Data inflasi yang digunakan berupa persentase perubahan bulanan dari Indeks Harga Konsumen (IHK), yang mencerminkan tingkat kenaikan harga barang dan jasa secara umum di Indonesia *setiap* bulannya. Pemilihan rentang waktu yang cukup panjang ini bertujuan untuk memastikan bahwa model yang dibangun mampu menangkap berbagai pola inflasi, seperti pola musiman (*seasonality*), tren jangka panjang, maupun fluktuasi jangka pendek yang terjadi di Indonesia dalam rentang waktu tersebut.

Data nilai tukar USD-IDR juga mencakup periode yang sama dengan data inflasi Indonesia. Data ini berisi pergerakan nilai tukar rupiah terhadap dollar perbulan. Data ini nantinya akan berperan sebagai variabel pendukung (*exogenous feature*) dalam proses *training* variabel utama. Data pendukung yang terakhir adalah *Monthly Indonesian Oil Price Marker* yang berisi penanda bulan dan tahun kenaikan harga minyak di Indonesia.

Sebagai langkah awal, data yang telah dikumpulkan selanjutnya dilakukan pemeriksaan awal untuk memastikan kelengkapan, konsistensi, serta akurasi data. Pemeriksaan ini mencakup pengecekan terhadap data yang hilang (*missing values*), serta validasi ulang terhadap sumber asli agar data benar-benar sesuai dan layak digunakan dalam penelitian ini. Data hasil pemeriksaan tersebut selanjutnya disusun secara sistematis ke dalam bentuk *dataset* yang siap digunakan dalam tahap pemrosesan berikutnya.

Dataset lengkap dicantumkan didalam lampiran. Berikut adalah beberapa sample dari *dataset* yang telah dikumpulkan dan disusun seperti yang dapat dilihat pada Tabel 3.3. 3.4 dan 3.5

Tabel 3 1 Data Inflasi BI

Date	Inflation
2003-01-01	8.68
2003-02-01	7.60
2003-03-01	7.17
2003-04-01	7.62
2003-05-01	7.15

Tabel 3 2 Data Nilai Tukar USD-IDR Yahoo Finance

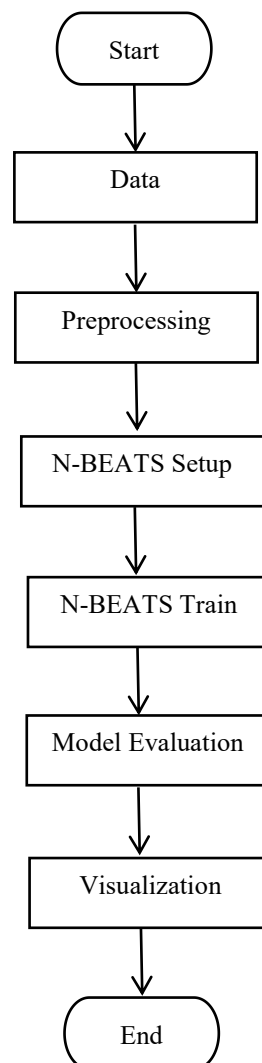
Date	Open Price	High	Low	Close	Adjusted Close
2003-01-01	8920.0000	9043.0000	8735.0000	8870.0000	8870.0000
2003-02-01	8875.0000	9085.0000	8745.0000	8883.5000	8883.5000
2003-03-01	8932.5000	9195.0000	8730.0000	8901.5000	8901.5000
2003-04-01	8900.0000	8995.0000	8590.0000	8707.5000	8707.5000
2003-05-01	8685.0000	8692.0000	8670.0000	8675.0000	8675.0000

Tabel 3 3 Data Kenaikan Harga Minyak Indonesia

Date	Is Fuel Hike
2003-01-01	False
2003-02-01	False
2003-03-01	False

2003-04-01	False
2003-05-01	7.15

3.3 Desain Sistem



Gambar 3. 2 Desain Sistem

Pada gambar 3.2 menunjukkan desain sistem yang digunakan dalam penelitian *forecasting* inflasi menggunakan metode *N-BEATS*. Secara umum,

sistem terdiri atas tahap pengumpulan data inflasi, pra-pemrosesan data, konfigurasi model *N-BEATS multivariate*, pelatihan model, evaluasi performa model, serta tahap akhir berupa *forecasting* inflasi di masa mendatang. Untuk penjelasan rinci mengenai *setiap* tahapan dapat dilihat pada penjelasan berikut ini:

A. Data Collection

Tahap pertama penelitian ini dimulai dengan mengumpulkan data yang akan digunakan didalam penelitian. Data historis inflasi bulanan Indonesia diambil melalui situs resmi Bank Indonesia (<https://www.bi.go.id/>). Data yang dikumpulkan merupakan inflasi bulanan yang dihitung berdasarkan perubahan Indeks Harga Konsumen (IHK), dengan satuan persen (%), yang menggambarkan tingkat inflasi *setiap* bulannya selama periode Januari 2003 hingga Maret 2024. Total sampel data yang berhasil dikumpulkan sebanyak 256 data bulanan yang mencakup berbagai kondisi ekonomi selama lebih dari dua dekade, sehingga dianggap representatif untuk memodelkan dan meramalkan pola inflasi di Indonesia. Kemudian untuk data historis nilai tukar USD-IDR diambil melalui Yahoo Finance (<https://finance.yahoo.com/>), data ini berisi perubahan nilai tukar antara USD dan IDR *setiap* bulannya dengan periode yang sama dengan data inflasi, yaitu Januari 2003 - Maret 2024. Sampel data yang berhasil dikumpulkan berjumlah 249 data, lebih sedikit dibandingkan dengan data inflasi sehingga data ini nantinya akan diolah terlebih dahulu didalam *preprocessing*. Terakhir adalah data *Monthly Indonesian Oil Price Marker*, data ini berasal dari riset empiris penulis,

berisi penanda atau *marker* kapan terjadinya kenaikan harga minyak di Indonesia.

B. *Data Preprocessing*

Pada tahap ini, dilakukan pengolahan awal terhadap data inflasi yang telah dikumpulkan, yang meliputi pembersihan data (*cleaning data*), yaitu proses mengidentifikasi dan menangani data hilang (*missing values*). Data yang teridentifikasi sebagai *missing values* akan ditangani melalui interpolasi atau metode penggantian nilai yang disesuaikan dengan kondisi data, agar kualitas data tetap terjaga untuk pelatihan model.

Selanjutnya, dilakukan ekstraksi fitur tambahan untuk menangkap pola musiman (*seasonality*) yang terdapat pada data inflasi, sehingga pola siklus data inflasi dapat dikenali lebih baik oleh model. Terakhir, data deret waktu inflasi yang telah diproses tersebut diubah menjadi data *supervised learning* (data dengan format *input-output*) berdasarkan ukuran *window size* tertentu.

C. *N-BEATS* Setup

Tahap ini menentukan konfigurasi detail dari model *N-BEATS multivariate* yang digunakan dalam penelitian, meliputi pemilihan *hyperparameter* seperti jumlah blok, jumlah *stack*, jumlah lapisan (*layers*) pada tiap blok, *learning rate*, jenis *optimizer* yang digunakan (umumnya Adam), *epoch* pelatihan, ukuran *window (lookback)*, *exogeneous feature*, *scaler*, *stack types* serta *horizon* prediksi. Model *N-BEATS* tersusun dari beberapa *stack*, di mana setiap *stack* terdiri atas beberapa blok yang

memiliki lapisan *Fully Connected (FC)* dengan fungsi aktivasi *Rectified Linear Unit (ReLU)* dan menghasilkan dua keluaran yaitu *backcast* dan *forecast*. Mekanisme *residual stacking* digunakan untuk memperbaiki kesalahan prediksi secara bertahap, sehingga memungkinkan model untuk menangkap pola yang lebih kompleks dalam data. Pemilihan *hyperparameter* dilakukan berdasarkan eksperimen yang telah ditentukan sebelumnya tanpa proses *tuning* iteratif, guna mendapatkan konfigurasi model yang mampu memberikan performa optimal pada data pengujian. Data tersebut akan dibagi menjadi dua *set*, yakni *dataset training* dan *test* dengan tiga skema ujicoba, yaitu 80% *train* 20% *test*, 70% *train* 30% *test* dan 60% *train* 40% *test*.

D. *N-BEATS Training*

Pada tahap ini dilakukan pelatihan model *N-BEATS multivariate* menggunakan data *training* yang telah melewati tahap *preprocessing*, meliputi normalisasi, dan ekstraksi fitur tambahan. Proses pelatihan dilaksanakan pada *environment* berbasis *Python* dengan memanfaatkan pustaka deep learning seperti *NeuralForecast*, di mana data *input* disusun dalam bentuk *supervised* dengan format *input-output* sesuai *window size* yang telah ditentukan sebelumnya. Pelatihan model *N-BEATS* menggunakan melibatkan iterasi berulang (*epoch*) hingga model mencapai konvergensi optimal berdasarkan konfigurasi *hyperparameter* yang sudah diatur. Evaluasi terhadap performa model secara berkala dilakukan selama

pelatihan, agar memastikan model mampu menghasilkan prediksi yang akurat terhadap data inflasi.

E. *Model Evaluation*

Setelah diperoleh model *N-BEATS* terbaik melalui tahap evaluasi berdasarkan nilai metrik evaluasi *SMAPE*, *MAE*, *MAPE* dan *RMSE*. Nilai ini didapat dari tingkat deviasi antara hasil peramalan dan data *test*. Semakin rendah perbedaan diantara keduanya, maka nilai matriks akan semakin rendah, menandakan bahwa model semakin akurat dalam melakukan peramalan.

F. *Visualization*

Tahap *Visualization* bertujuan untuk menampilkan hasil prediksi inflasi yang telah dihasilkan oleh model *N-BEATS* dalam bentuk grafik atau visual lainnya untuk mempermudah interpretasi dan analisis. Pada tahap ini, data prediksi dibandingkan dengan data aktual menggunakan berbagai teknik visualisasi seperti *line plot*, *scatter plot*, atau *histogram* untuk melihat pola serta tingkat akurasi model dalam memprediksi tren inflasi. Visualisasi ini dilakukan menggunakan pustaka *Python* seperti *Matplotlib* atau *Seaborn* yang memungkinkan penyajian data dalam format yang mudah dipahami. Dengan adanya visualisasi, peneliti dapat mengevaluasi sejauh mana model berhasil menangkap pola inflasi historis dan mengidentifikasi potensi penyimpangan atau error dalam hasil prediksi.

BAB IV

HASIL DAN PEMBAHASAN

Pada bagian ini penulis akan memaparkan hasil implementasi metode *N-BEAST* (*Neural Basis Expansion Analysis for Time Series*) varian *multivariate* atau *N-BEATSx* yang telah diterapkan pada *dataset* inflasi Indonesia. Pemaparan dimulai dari eksplanasi *dataset* yang digunakan, kemudian langkah-langkah *preprocessing*, dan terakhir hasil *training* dan ujicoba model *N-BEATS*.

4.1 Persiapan Dataset

Terdapat tiga *dataset* yang akan digunakan didalam ujicoba *N-BEATS*. *Dataset* pertama yang digunakan sebagai variabel utama adalah data inflasi bulanan Bank Indonesia. Data ini mencakup obervasi bulanan inflasi yang cukup panjang untuk mengungkap pola *trend* dan musiman inflasi. Analisis awal dari data inflasi indonesia mengalami variasi yang cukup signifikan dalam rentang waktu penelitian.. Kenaikan yang cukup drastis disebabkan oleh beberapa kejadian, salah satunya adalah krisis ekonomi seperti yang terjadi di tahun 2008.

Dataset tersebut kemudian kita simpan kedalam database *postgres* dengan nama *InflationRecord*. Tabel ini nantinya akan digunakan untuk menyimpan dan mengambil data inflasi untuk kemudian di *load* kedalam model. Struktur tabel yang digunakan dapat dilihat di tabel 4.1.

Tabel 4 1 *InflationRecord* data structure

Kolom	Deskripsi
Date	Waktu obeservasi inflasi dalam format DD-MM-YYYY, <i>dataset</i> dari bank indonesia tidak mencakup tanggal sehingga untuk default

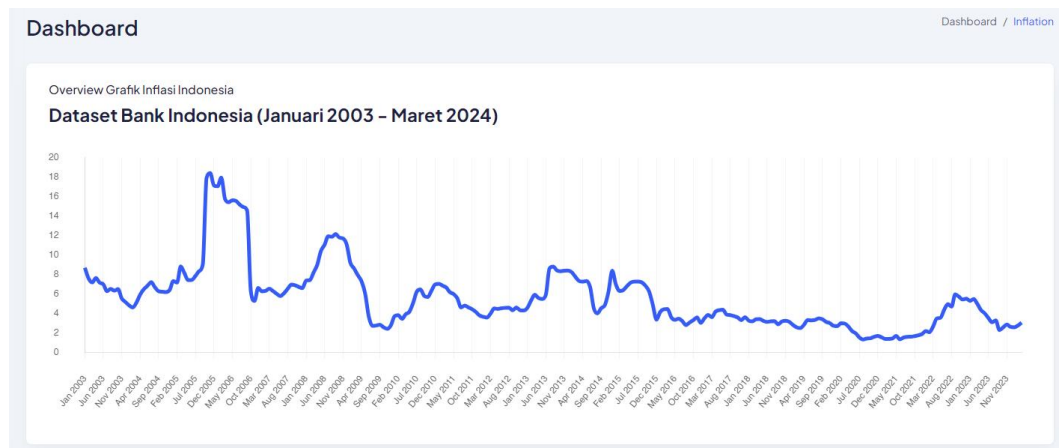
	adalah tanggal 1 untuk <i>setiap</i> bulannya
Inflation	Nilai inflasi bulanan dalam decimal. Hasil konversi percent dari data Bank Indonesia

Data didalam *postgres* diquery dengan menggunakan *Django Model ORM*. Kolom *date* memiliki tipe *Date* untuk menyimpan tanggal, tahun dan bulan. kemudian kolom *inflation* memiliki tipe *Decimal(5,2)* dengan presisi angka 5 digit dan *scale* 2 digit, contoh *valuenya* adalah 9999.99. Data-data tersebut kemudian disusun secara *ascending* berdasarkan waktu. Tabel 4.2 adalah data pada *database postgres* yang nantinya akan digunakan didalam *training* model.

Tabel 4 2 *InflationRecord data example*

Date	Inflation
2003-01-01	8.68
2003-02-01	7.60
2003-03-01	7.17
.....
2024-03-01	3.05

Kemudian berikut adalah visualisasi pada Gambar 4.1. untuk grafik pergerakan inflasi indonesia dari januari 2003 - maret 2024.



Gambar 4. 1 Grafik Inflasi Indonesia

Terdapat data lain sebagai penunjang *forecasting* inflasi indonesia. Data penunjang ini berperan sebagai *Exogeneous feature* yang dapat digunakan didalam model *N-BEATS* varian *N-BEATSx*. *N-BEATSx* memiliki kemampuan *multivariate*, sehingga memungkinkan data utama dapat dipelajari dengan data tambahan lain sehingga model dapat memiliki informasi yang cukup. Data penunjang memiliki *granularity* yang sama dengan data utama, sebanyak 256 data. Terdapat dua *dataset* penunjang yang digunakan didalam penelitian ini, yaitu nilai tukar *Monthly USD-IDR Exchange Rate* yang di scraping dari Yahoo Finance dan *Monthly Fuel Hike Price Tracker* yang dikumpulkan oleh penulis dari berbagai sumber di internet.

Monthly USD-IDR Exchange Rate Dataset di *load* kedalam tabel postgres dengan nama *USDIDRExchangeRecord*. *Exogeneous Feature* yang akan digunakan didalam model ini adalah kolom *Adjusted Closed*, dimana ini merupakan harga final yang sudah disesuaikan ketika hari berakhir. Struktur tabel *USDIDRExchangerRecord* dapat dilihat pada tabel 4.3

Tabel 4 3. *USDIDRExchangeRecord data structure*

Kolom	Deskripsi
Date	Waktu obeservasi inflasi dalam format DD-MM-YYYY, <i>dataset</i> dari bank indonesia tidak mencakup tanggal sehingga untuk default adalah tanggal 1 untuk <i>setiap</i> bulannya
Open Price	Harga pembukaan ketika pasar dibuka
High	Harga tertinggi yang sempat dicapai pada hari itu
Low	Harga terendah yang sempat dicapai pada hari itu
Close	Harga penutupan saat pasar berakhir
Adj Close	Harga penyesuaian saat pasar berakhir


Kolom *Date* memiliki tipe kemudian kolom *Open Price*, *High*, *Low*, *Close*, dan *Adjusted Cose* memiliki tipe *Decimal(14,4)* dengan prisisi angka 14 digit dan *scale* 2 digit, contoh valuenya adalah 99999999999999.9999. Data-data tersebut kemudian disusun sama dengan data *InflationRecord* yaitu secara *ascending* berdasarkan waktu. Berikut adalah tabel 4.4. yang merupakan data pada *database postgres* yang nantinya juga akan digunakan didalam *training* model.

Tabel 4 4 *USDIDRExchangeRecord data example*

Date	Open Price	High	Low	Close	Adj Close
2003-01-01	8920.0000	9043.0000	8735.0000	8870.0000	8870.0000
2003-02-01	8875.0000	9085.0000	8745.0000	8883.5000	8883.5000
2003-03-01	8932.5000	9195.0000	8730.0000	8901.5000	8901.5000

.....
2024-03-01	15704.0000	15914.5000	14784.4004	15873.0996	15873.0996

Kemudian berikut adalah gambar 4.2. yang berisi grafik visualisasi dari pergerakan nilai tukar USD-IDR perbulan.



Gambar 4. 2 Grafik USD-IDR Exchange Rate

Kemudian untuk data ketiga adalah *Monthly Fuel Hike Price Marker*. Data ini diload kedalam postgres sebagai *ExogeneousInfoRecord*. Tabel ini cukup unik karena mengandung berbagai macam *Exogeneous Feature* yang dapat digunakan untuk memperkuat *forecasting* inflasi. Namun untuk penelitian ini, penulis hanya menggunakan satu *Exogeneous Feature* dari tabel ini untuk menghindari potensi *noise* yang dapat membuat model kebingungan dalam mempelajari pola.

Tabel 4 5 *ExogeneousInfoRecord* data structure

Kolom	Deskripsi
Date	Waktu obeservasi inflasi dalam format DD-MM-YYYY, <i>dataset</i> dari bank indonesia tidak mencakup tanggal sehingga untuk default

	adalah tanggal 1 untuk <i>setiap</i> bulannya
Is Fuel Hike	Menandakan bahwa di tanggal tersebut terdapat kenaikan harga BBM

Exogeneous Feature didalam tabel 4.5 memiliki value *true* dan *false*, sebagai penanda adanya kejadian di waktu tersebut, kejadian tersebut disesuaikan dengan nama kolom, contohnya adalah kolom *is_fuel_hike*. Kolom tersebut berfungsi sebagai *marker* bahwa di tanggal tersebut terdapat kenaikan harga minyak dalam negeri. Kolom tersebut memiliki tipe boolean dengan value *true* atau *false*. Berikut adalah contoh data tabel tersebut seperti yang terlihat pada tabel 4.6.

Tabel 4 6 *ExogeneousInfoRecord data example*

Date	Is Fuel Hike
2003-01-01	False
2003-02-01	False
2003-03-01	False
.....
2024-03-01	False

Berikut adalah contoh data dari *ExogeneousInfoRecord*. Gambar 4.3 menampilkan visualisasi dari data terkait.

	Date	Is Ramadan	Is Fuel Hike
#1	2003-01-01	False	False
#2	2003-02-01	False	False
#3	2003-03-01	False	False
#4	2003-04-01	False	False
#5	2003-05-01	False	False
#6	2003-06-01	False	False
#7	2003-07-01	False	False
#8	2003-08-01	False	False
#9	2003-09-01	False	False

Gambar 4. 3 Grafik *ExogeneousInfoRecord*

4.2 *Preprocessing*

A. *Data Type Mapping and Conversion*

Data yang digunakan oleh model nantinya akan *diquery* dari *Django ORM*. *Django ORM* ini nantinya berperan sebagai abstraksi diatas tabel postgres. Data yang berhasil *diquery* langsung melalui oleh *Django ORM* tidak bisa langsung digunakan didalam *pandas dataframe*. Sehingga perlu dilakukan konversi hasil *query* dari *Django ORM* agar sesuai dengan struktur yang akan digunakan.

Selain konversi, tahap lain yang dilakukan adalah melakukan *mapping*, *renaming* dan *sorting*. Proses ini dilakukan agar *pandas dataframe* dapat di load kedalam *neuralforecast*, tempat dimana model *N-BEATS multivariate* berada. Berikut adalah tabel 4.7 dan tabel 4.8 untuk visualisasi perubahan pada tahap ini.

Tabel 4 7 *Dataframe after Data Type Mapping and Conversion*

Table	Column	<i>Dataframe mapping and Conversion</i>
InflationRecord	Date (Date)	ds (datetime)
InflationRecord	Inflation (Decimal(5,2))	y (float)
USDIDRExchangeRecord	Adj Close (Decimal(14,4))	usd (float)

ExogeneousInfoRecord	Is Fuel Hike (Boolean)	is_fuel_hike (integer)
----------------------	------------------------	------------------------

Tabel 4 8 *Mapping and Conversion of Dataframe*

ds	y
2003-01-01	8.68
2003-02-02	7.60
2003-03-15	7.17
.....
2024-03-01	3.05

B. *Frequency Normalization*

Data ekonomi kemungkinan memiliki variasi dalam pencatatan tanggal. Semisal untuk data *monthly*, bisa jadi pencatatan terjadi di akhir bulan, awal bulan, atau pertengahan bulan. Untuk menghindari adanya ketidakteraturan antar *dataset* yang digunakan didalam *forecasting*, akan dilakukan normalisasi frekuensi menjadi MS atau *Month Start*. Normalisasi ini akan membuat semua tanggal data menjadi homogen dan *start* pada awal bulan. Tabel 4.9 menunjukkan hasil *Frequency Normalization*.

Tabel 4 9 *Frequency Normalization of Dataframe*

ds	y
2003-01-01	8.68
2003-02-01	7.60
2003-03-01	7.17

.....
2024-03-01	3.05

C. Multivariate Merging

Tahapan ini akan dilakukan *setelah* semua data yang di *query* melalui *Django ORM* dan telah mengalami *Frequency Normalization*. Data yang sudah melalui 2 *pipeline* selanjutnya akan di *merge*. Proses *merging* dilakukan dengan melakukan *left join data Exogeneous* dari *USDIDRExchangeRecord* dan *ExogeneousInfoRecord* kedalam *dataframe* utama yang berisi data inflasi bulanan indonesia. Langkah ini menyatukan data menjadi satu matriks tunggal. Integrasi ini memungkinkan *N-BEATS* memanfaatkan data *Exogeneous* untuk mempelajari pola inflasi Indonesia. Berikut adalah *value* dari dari *dataframe* setelah dilakukan *merging* pada tabel 4.10.

Tabel 4 10 *Multivariate Merging of Dataframe*

ds	y	usd	Is_fuel_hike
2003-01-01	8.68	8870.0000	0
2003-02-01	7.60	8883.5000	0
2003-03-01	7.17	8901.5000	0
.....
2024-03-01	3.05	15873.0996	0

D. Exogeneous Feature Lagging

Tahapan selanjutnya adalah Lagging. Tahapan ini diaplikasikan pada data nilai tukar USD-IDR. Proses ini berjalan dengan melakukan shift data ke satu bulan sebelumnya. Hal ini dilakukan karena perubahan nilai mata uang tidak selalu berdampak pada inflasi di bulan yang sama, melainkan terjadi efek tunda atau lag yang berdampak untuk inflasi di bulan depan. Dengan cara ini model akan menggunakan nilai kurs bulan sebelumnya untuk memprediksi nilai inflasi di bulan depan. Berikut adalah visualisasi *dataframe* setelah dilakukan proses lagging pada tabel 4.11.

Tabel 4 11 *Exogeneous Feature Lagging of Dataframe*

ds	y	usd_lag1	Is_fuel_hike
NaN	NaN	8870.0000	NaN
2003-01-01	8.68	8883.5000	0
2003-02-01	7.60	8901.5000	0
2003-03-01	7.17	8707.5000	0
.....
2024-03-01	3.05	NaN	0

E. *Fill Missing Values*

Ketidaklengkapan data dapat terjadi karena sumber *dataset* yang tidak lengkap atau sudah melalui tahapan preprocessing yang membuat adanya data kosong didalamnya. Sehingga untuk mencegah data yang kurang lengkap ini masuk ke dalam model *training*, perlu dilakukan *filling* terhadap data yang hilang. Terdapat 3 teknik *filling* yang digunakan didalam proses ini. Pertama adalah

Forward Fill, yaitu *filling* dengan cara mengisi nilai yang hilang dengan nilai yang terakhir diketahui, contohnya adalah mengisi *value* terakhir dari *usd_lag1* yang kosong karena proses *lagging*. Kedua adalah *Backward Fill*, yaitu mengisi nilai kosong di awal baris *dataset*, contohnya adalah baris pertama dari kolom *ds* dan *y* yang kosong karena *lagging*. Ketiga adalah *Constant Fill*, yaitu mengisi nilai konstan di data yang kosong, hal ini dilakukan di kolom *is_fuel_hike* pada baris pertama karena datanya kosong akibat *lagging*. Berikut adalah *value dataframe* setelah dilakukan *filling* pada tabel 4.12.

Tabel 4 12 Fill Missing Values of *Dataframe*

ds	y	usd_lag1	Is_fuel_hike
2002-12-01	8.01	8870.0000	0
2003-01-01	8.68	8883.5000	0
2003-02-01	7.60	8901.5000	0
2003-03-01	7.17	8707.5000	0
.....
2024-03-01	3.05	15873.0996	0

F. *Data Cleaning*

Langkah terakhir adalah melakukan *data cleaning* dengan menghapus baris data yang memiliki tipe yang tidak sesuai. Proses dilakukan dengan mengecek apakah data sudah bertipe *float* atau *integer*. Jika terdapat simbol atau karakter yang tidak sesuai dengan tipe saat proses validasi, maka baris tersebut

akan di *drop* dari *dataset*. Contoh data hasil *data cleaning* dapat dilihat pada tabel 4.13 dan *final data* yang telah melalui *preprocessing* dapat dilihat pada tabel 4.14.

Tabel 4 13 *Example of Dataframe with broken value*

ds	y	usd_lag1	Is_fuel_hike
2003-01-01	8.68	8870.0000	0
2003-02-01	7.60	8883.5000	0
2003-03-01	7.17	8707.5000	0
2003-03-01	7.1xi	8901@d	Oi
.....
2024-03-01	3.05	15873.0996	0

Tabel 4 14 *Final Dataframe after cleaning*


ds	y	usd_lag1	Is_fuel_hike
2003-01-01	8.68	8870.0000	0
2003-02-01	7.60	8883.5000	0
2003-03-01	7.17	8707.5000	0
.....
2024-03-01	3.05	15873.0996	0

4.3 Hasil dan Analisis Ujicoba

A. Persiapan

Dalam proses eksperimen, data dibagi menjadi dua bagian yaitu *data training* dan *data testing*. Pembagian ini memungkinkan untuk model untuk mempelajari pola-pola yang ada didalam *dataset* untuk kemudian menjadi acuan

untuk peramalan. Pembagian akan dilakukan menjadi 3 skenario, yaitu 80% *train* 20% *test*, 70% *train* 30% *test*, dan 60% *train* 40% *test*. Visualisasinya dapat dijumpai pada gambar 4.4. dibawah ini.



Gambar 4. 4 Visualisasi *Split Dataset Training-Test*

B. Penentuan *Hyperparameter* Model

Model *N-BEATS multivariate* pada penelitian ini menggunakan *hyperparameter* optimal yang disesuaikan dan dikomparasi dengan *set hyperparameter* yang lain. Terdapat 10 skenario yang diujicoba untuk mendapatkan *set hyperparameter* yang optimal. Pengujian ini kemudian menghasilkan *set hyperparameter* yang kemudian akan digunakan didalam 3 skema *train-test* pada sub-bab selanjutnya. Untuk skenario pengujian untuk mendapatkan *set hyperparameter* optimal akan menggunakan skema data split *Train* 80% dan *Test* 20% sebagai baseline. Skenario dapat dilihat pada Tabel 4.15.


Tabel 4 15 Skenario *Hyperparameter*

Skenario	Input	Horizon	Learning Rate	Steps	Loss	Batch	Scaler	Exog	Stack	Ket
S1	60	12	0.0003	50	Huber	32	Robust	X	<i>Trend+Id entity</i>	Tanpa exog & seasonality

S2	24	12	0.0003	50	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Histori berkura ng
S3	48	12	0.0003	50	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Histori sangat pendek
S4	60	12	0.001	50	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Learnin g rate besar
S5	60	12	0.00001	50	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Learnin g rate kecil
S6	60	12	0.0003	20	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Steps kecil
S7	60	12	0.0003	100	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Steps beasr
S8	60	12	0.0003	50	<i>MAE</i>	32	Stand ard	✓	<i>Trend+Id entity+Se asonality</i>	Loss dan Scaler berbeda
S9	60	12	0.0003	50	Huber	32	MinM ax	✓	<i>Trend+Id entity+Se asonality</i>	Scaler berbeda
S10	60	12	0.0003	50	Huber	32	Robust	✓	<i>Trend+Id entity+Se asonality</i>	Model terbaik

Terdapat 10 skenario yang diujicoba untuk mendapatkan *set hyperparameter* yang optimal. Pengujian ini kemudian menghasilkan *set hyperparameter* yang kemudian akan digunakan didalam 3 skema *train-test* pada bagian selanjutnya. Untuk skenario pengujian untuk mendapatkan *set hyperparameter* optimal akan menggunakan skema data split *Train* 80% dan *Test* 20% sebagai baseline.

1. Skenario S1



Gambar 4.5 Hasil *Forecasting* Skenario S1

Pada Skenario S1 seperti yang terlihat pada Gambar 4.5. terlihat penurunan akurasi *forecasting* yang sangat ekstrem. Set *hyperparameter* yang digunakan diantaranya tidak menggunakan *Exogeneous Feature* dan menghilangkan *seasonality stack*. Penghilangan 2 komponen ini menyebabkan kurangnya informasi yang didapatkan oleh model untuk dipelajari dan penghilangan cara kerja internal model untuk melihat pola *seasonal* pada data.

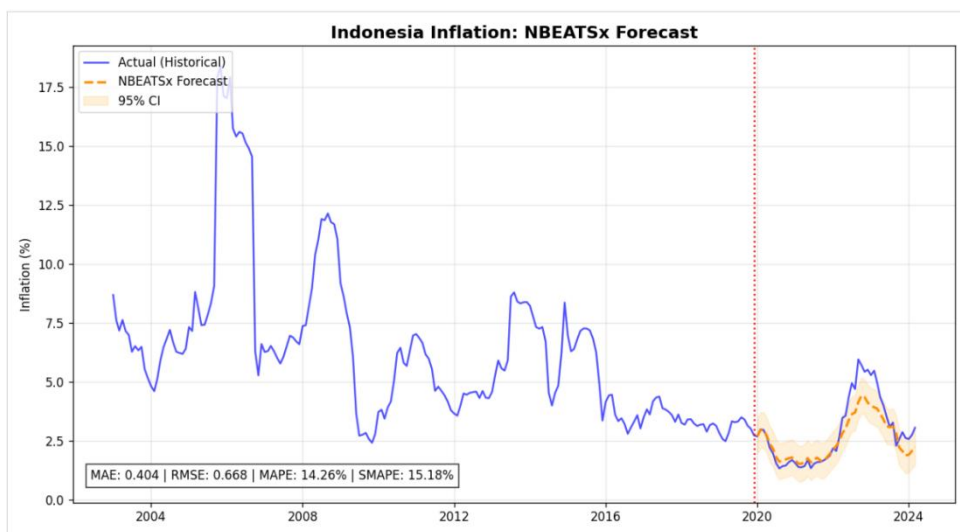
2. Skenario S2



Gambar 4. 6 Hasil *Forecasting* Skenario S2

Pada Skenario S2, model menggunakan *stack* yang lengkap yaitu *Trend+Identity+Seasonality*. Model ini juga menggunakan *Exogeneous Feature* dalam proses *training*. Didalam skenario ini, model menggunakan nilai *input* yang rendah dengan nilai 24, *set hyperparameter* ini dapat dilihat di Tabel 4.15. Hasil ujicoba skenario S2 seperti yang dapat terlihat di Gambar 4.6, terlihat bahwa *trajectory* dari *forecast* kini jauh lebih terarah. Nilai Input yang rendah menjadi penyebab utama nilai metrik masih cukup tinggi, tetapi hasil skenario ini jauh lebih baik dibandingkan dengan Skenario S1.

3. Skenario S3




Gambar 4. 7 Hasil *Forecasting* Skenario S3

Pada Skenario S3, *set hyperparameter* hampir sama dengan Skenario S2. Adapun perbedaannya terdapat pada nilai *input* yang lebih tinggi yaitu 48. Berdasarkan hasil *forecast* dari Gambar 4.7, Skenario ini menunjukkan peningkatan yang cukup signifikan berdasarkan metrik dan pergerakan grafik

peramalan. Dengan meningkatkan nilai *input* 2x lipat, membuat model mampu untuk melihat data masa lampau lebih banyak.


4. Skenario S4



Gambar 4. 8 Hasil *Forecasting* Skenario S4

Pada Skenario S4, *set hyperparameter* menggunakan value yang dengan skenario sebelumnya kecuali nilai *input* sebesar 60 dan *learning rate* sebesar 0.001. Pada skenario ini pergerakan grafik peramalan cenderung berjalan lebih datar. Hal ini dikarenakan *learning rate* terlalu tinggi menyebabkan model tidak optimal dalam menangkap pola dan berpotensi mengalami *overshoot*.


5. Skenario S5



Gambar 4. 9 Hasil *Forecasting* Skenario S5

Pada Skenario S5, *set hyperparameter* sama dengan skenario sebelumnya namun dengan nilai *Learning Rate* yang kecil yaitu 0.00001. Berdasarkan Gambar 4.9, model mendapatkan nilai metrik yang cukup tinggi dan grafik *forecasting* yang tidak terlalu datar jika dibandingkan dengan Skenario S4. Hal ini dapat dipengaruhi oleh *learning rate* yang terlalu rendah dan model yang kemungkinan mengalami *undershoot*.


6. Skenario S6



Gambar 4. 10 Hasil *Forecasting* Skenario S6

Pada Skenario S6, *Learning Rate* menggunakan nilai *default* yaitu 0.0003, namun nilai *steps* diturunkan menjadi 20. Berdasarkan hasil *forecast* dari Gambar 4.10, dapat terlihat *trajectory* peramalan berada di dalam *confidence interval*, namun masih cukup melenceng dari nilai aktual. Hal ini terjadi karena nilai *steps* yang rendah berpengaruh kepada tingkat akurasi dari model.


7. Skenario S7



Gambar 4. 11 Hasil *Forecasting* Skenario S7

Pada skenario S7, nilai dari *steps* diperbesar menjadi 100. Dalam skenario ini model terlalu *overconfident* dalam melakukan *forecasting*, hal ini dapat dilihat pada Gambar 4.11 dimana hasil *forecasting* untuk garis yang landai memberikan hasil yang lebih tinggi, sedangkan untuk *spike* tinggi memberikan hasil yang lebih rendah.


8. Skenario S8



Gambar 4. 12 Hasil *Forecasting* Skenario S8

Pada Skenario S8, *hyperparameter* loss menggunakan *MAE* dan *scaler* menggunakan *standard*. Dari perubahan kedua param tersebut, terlihat bahwa model kurang optimal untuk mempelajari lonjakan ekstrim pada *dataset*, sehingga hasil peramalan cenderung landai. Grafik dapat dilihat pada Gambar 4.12.


9. Skenario S9



Gambar 4. 13 Hasil *Forecasting* Skenario S9

Pada Skenario S9, *hyperparameter* loss dikembalikan menjadi *Huber* dan untuk *Scaler* menggunakan *MinMax*. Pada Gambar 4.13 terlihat bahwa Skenario S9 memiliki kendala yang sama dengan Skenario S8, yaitu model kurang mampu untuk menangkap lonjakan ekstrem. Grafik pada Skenario S9 lebih landai dibanding Skenario S8, sehingga hasil *forecasting* ini tidak lebih baik dari *set hyperparameter* sebelumnya.

10. Skenario S10



Gambar 4. 14 Hasil *Forecasting* Skenario S10

Pada Skenario S10, *scaler* diubah menjadi *robust*. Perubahan ini membawa hasil yang cukup signifikan, dimana model kini mampu untuk mempelajari pola yang ada didalam *dataset*. Gambar 4.14 menunjukkan grafik peramalan yang berjalan mendekati hasil peramalan.

Berdasarkan pengujian 10 skenario tersebut dapat disimpulkan bahwa Skenario S10 menunjukkan hasil paling optimal dibandingkan dengan skenario yang lain, sehingga proses selanjutnya akan menggunakan *set hyperparameter* dari Skenario S10 seperti yang dapat dilihat pada Tabel 4.16.


Tabel 4 16 *N-BEATSx Hyperparameter*.

Parameter	Nilai	Keterangan
Input_size	60	Panjang jendela <i>input</i> untuk <i>backcast horizon</i> , 60 bulan terakhir untuk memprediksi 12 bulan kedepan
<i>Horizon</i>	12	Jumlah bulan kedepan yang

		akan diprediksi
Learning_rate	0.0003	Kecepatan pembelajaran model
Max_steps	50	Nilai maksimum iterasi pelatihan
Loss	HuberLoss	Deteksi Loss
Batch_size	32	Jumlah sampel per batch
Scaler_type	Robust	Skala yang digunakan didalam normalisasi
Hist_exog_list	[usd_lag1, is_fuel_hike]	<i>Exogeneous Feature</i> yang berasal dari Data Penunjang
Stack_types	["trend", "identity", "seasonality"]	Mengatur model mengenai bagaimana proses pola pembelajaran akan dilakukan

C. Hasil *Forecasting*

Model *N-BEATS* dilatih menggunakan *dataset* inflasi bulanan indonesia yang telah melalui tahapan *preprocessing*. Model *N-BEATS* dengan varian *N-BEATSx* akan diuji coba dengan skema split 80% *Train* 20% *Test*, 70% *Train* 30% *Test* dan 60% *Train* 40% *Test*. Hasil ujicoba dari *N-BEATSx* 80% *Train* 20% *Test* dapat dilihat pada Gambar 4.15.



Gambar 4. 15 Visualisasi Forecast vs Actual 80% Train 20% Test

Hasil ujicoba model *N-BEATS* dengan split 80% Train 20% Test menunjukkan hasil yang cukup akurat. Komparasi antara nilai aktual dan hasil *forecasting* memiliki jarak yang cukup berdekatan dan deviasi yang relatif rendah. Hasil *forecasting* juga masih masuk kedalam area *confident interval*, yang menunjukkan seberapa yakin model dapat meramal nilai inflasi di *range* area tersebut . Dari ke-empat metrik pada tabel 4.17 yang digunakan sebagai validitas model, terlihat seluruhnya memiliki nilai dibawah 15%.

Tabel 4 17 Metrik *N-BEATS* 80% Train 20% Test

<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>SMAPE</i>
0.297	0.473	9.42%	10.00%

Dari 20% data yang diujicoba, berikut adalah perbandingan antara nilai aktual dengan nilai dari hasil permalan yang dapat dilihat pada 4.18.


Tabel 4 18 *Actual vs Forecast Table split 80% Train 20% Test*

No	Date	Actual	Forecast	Difference
#1	2020-01-01	2.68 %	2.75 %	+0.07
#2	2020-02-01	2.98 %	2.89 %	-0.09
#3	2020-03-01	2.96 %	2.87 %	-0.09
#4	2020-04-01	2.67 %	2.63 %	-0.04
#5	2020-05-01	2.19 %	2.19 %	0.00
#6	2020-06-01	1.96 %	1.96 %	0.00
#7	2020-07-01	1.54 %	1.56 %	+0.02
#8	2020-08-01	1.32 %	1.39 %	+0.07
#9	2020-09-01	1.42 %	1.43 %	+0.01
#10	2020-10-01	1.44 %	1.46 %	+0.02
#11	2020-11-01	1.59 %	1.56 %	-0.03
#12	2020-12-01	1.68 %	1.60 %	-0.08
#13	2021-01-01	1.55 %	1.54 %	-0.01
#14	2021-02-01	1.38 %	1.45 %	+0.07
#15	2021-03-01	1.37 %	1.35 %	-0.02
#16	2021-04-01	1.42 %	1.41 %	-0.01
#17	2021-05-01	1.68 %	1.52 %	-0.16
#18	2021-06-01	1.33 %	1.40 %	+0.07
#19	2021-07-01	1.52 %	1.57 %	+0.05
#20	2021-08-01	1.59 %	1.68 %	+0.09
#21	2021-09-01	1.60 %	1.70 %	+0.10
#22	2021-10-01	1.66 %	1.86 %	+0.20
#23	2021-11-01	1.75 %	1.94 %	+0.19
#24	2021-12-01	1.87 %	2.02 %	+0.15
#25	2022-01-01	2.18 %	2.22 %	+0.04
#26	2022-02-01	2.06 %	2.19 %	+0.13
#27	2022-03-01	2.64 %	2.67 %	+0.03
#28	2022-04-01	3.47 %	3.20 %	-0.27

#29	2022-05-01	3.55 %	3.19 %	-0.36
#30	2022-06-01	4.35 %	3.76 %	-0.59
#31	2022-07-01	4.94 %	4.17 %	-0.77
#32	2022-08-01	4.69 %	4.09 %	-0.60
#33	2022-09-01	5.95 %	5.02 %	-0.93
#34	2022-10-01	5.71 %	4.92 %	-0.79
#35	2022-11-01	5.42 %	4.73 %	-0.69
#36	2022-12-01	5.51 %	4.53 %	-0.98
#37	2023-01-01	5.28 %	4.37 %	-0.91
#38	2023-02-01	5.47 %	4.28 %	-1.19
#39	2023-03-01	4.97 %	4.07 %	-0.90
#40	2023-04-01	4.33 %	3.70 %	-0.63
#41	2023-05-01	4.00 %	3.22 %	-0.78
#42	2023-06-01	3.52 %	2.94 %	-0.58
#43	2023-07-01	3.08 %	2.89 %	-0.19
#44	2023-08-01	3.27 %	3.04 %	-0.23
#45	2023-09-01	2.28 %	2.81 %	+0.53
#46	2023-10-01	2.56 %	2.41 %	-0.15
#47	2023-11-01	2.86 %	2.25 %	-0.61
#48	2023-12-01	2.61 %	2.18 %	-0.43
#49	2024-01-01	2.57 %	2.18 %	-0.39
#50	2024-02-01	2.75 %	2.14 %	-0.61
#51	2024-03-01	3.05 %	2.10 %	-0.95

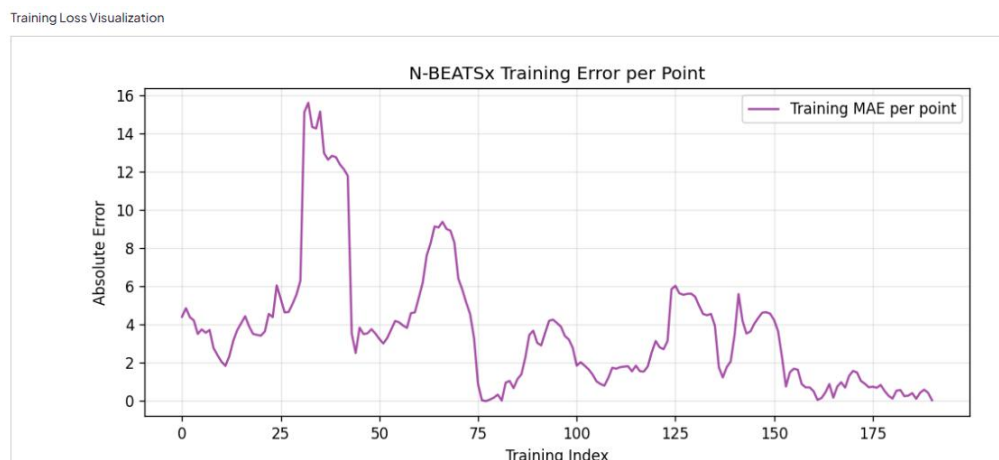
Grafik *residual* juga menunjukkan bahwa model berjalan diantara nilai positif dan negatif. Analisis *residual* digunakan sebagai penanda agar model tidak mengalami bias sistematis. Nilai *residual* berasal dari selisih antar nilai aktual dengan nilai *forecast*. Residual yang baik adalah yang tersebar acak disekitar 0. Hal ini menandakan bahwa model tidak akan *overestimate* atau *underestimate*

inflasi. Berikut adalah hasil visualisasi analisis *residual* yang dapat dilihat pada Gambar 4.16.



Gambar 4. 16 Residual *Visualization N-BEATS 80% Train 20% Test*

Kemudian terdapat grafik *Training Error per point* dari *N-BEATS*. Grafik ini memiliki plot yang relatif sama dengan data aktual dengan perbedaan besar di beberapa titik karena adanya proses learning dari model *N-BEATS* ini. Jika nilai selalu konstan tinggi, maka model mengalami *underfitting*. Jika selalu rendah maka model mengalami *overfitting*. Dalam grafik ini model selalu belajar namun dengan gangguan atau *noise* yang cukup tinggi karena ada *spike* besar seperti tahun 2008 karena krisis. Namun secara garis besar, model berjalan secara normal. Grafik tersebut dapat dilihat pada Gambar 4.17.



Gambar 4. 17 Training Error per Point *Visualization N-BEATS 80% Train 20% Test*

Kemudian lanjut pengujian dengan skema kedua. Skema selanjutnya yang akan diujicoba adalah split 70% *Train* 30% *Test*. Disini model akan menggunakan 70% data untuk *training* dan 30%-nya untuk *testing* dan ujicoba. Berikut adalah hasil visualisasi *forecasting* pada Gambar 4.18 untuk skema 70% *Train* 30% *Test*.



Gambar 4. 18 Visualisasi Forecast vs Actual 70% *Train* 30% *Test*

Hasil ujicoba model dengan skema 70% *Train* 30% *Test* menunjukkan hasil yang cukup berbeda dengan sebelumnya. Nilai aktual dan hasil *forecasting* memiliki jarak yang cukup jauh dan deviasi yang tinggi. *Confident Interval* juga terlampaui jauh dari nilai aktual *forecasting*. Hal ini menunjukkan bahwa model mengalami *struggle* ketika data yang mereka pelajari lebih sedikit dan memungkinkan mereka memiliki kemampuan yang rendah dalam mempelajari pola. Dari ke-empat metrik yang digunakan sebagai validitas model, terlihat seluruhnya memiliki nilai diatas 15%. Berikut adalah perbandingan antar metrik pada Tabel 4.19.

Tabel 4 19 Metrik *N-BEATS* 70% Train 30% Test

<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>SMAPE</i>
1.016	1.105	44.50%	34.55%

Tabel 4.20 menunjukkan perbandingan antara nilai aktual dengan nilai dari hasil peramalan dari 30% data yang diujicoba, .


Tabel 4 20 *Actual vs Forecast Table split 70% Train 30% Test*

No	Date	Actual	Forecast	Difference
#1	2017-11-01	3.30 %	3.74 %	+0.44
#2	2017-12-01	3.61 %	3.93 %	+0.32
#3	2018-01-01	3.25 %	3.67 %	+0.42
#4	2018-02-01	3.18 %	3.69 %	+0.51
#5	2018-03-01	3.40 %	4.02 %	+0.62
#6	2018-04-01	3.41 %	4.12 %	+0.71
#7	2018-05-01	3.23 %	4.23 %	+1.00
#8	2018-06-01	3.12 %	4.13 %	+1.01
#9	2018-07-01	3.18 %	3.91 %	+0.73
#10	2018-08-01	3.20 %	4.17 %	+0.97
#11	2018-09-01	2.88 %	4.08 %	+1.20
#12	2018-10-01	3.16 %	4.25 %	+1.09
#13	2018-11-01	3.23 %	4.26 %	+1.03
#14	2018-12-01	3.13 %	4.04 %	+0.91
#15	2019-01-01	2.82 %	3.80 %	+0.98
#16	2019-02-01	2.57 %	3.68 %	+1.11
#17	2019-03-01	2.48 %	3.67 %	+1.19
#18	2019-04-01	2.83 %	4.05 %	+1.22
#19	2019-05-01	3.32 %	4.43 %	+1.11

#20	2019-06-01	3.28 %	4.40 %	+1.12
#21	2019-07-01	3.32 %	4.57 %	+1.25
#22	2019-08-01	3.49 %	4.86 %	+1.37
#23	2019-09-01	3.39 %	4.71 %	+1.32
#24	2019-10-01	3.13 %	4.47 %	+1.34
#25	2019-11-01	3.00 %	4.44 %	+1.44
#26	2019-12-01	2.72 %	4.09 %	+1.37
#27	2020-01-01	2.68 %	4.21 %	+1.53
#28	2020-02-01	2.98 %	4.44 %	+1.46
#29	2020-03-01	2.96 %	4.33 %	+1.37
#30	2020-04-01	2.67 %	4.03 %	+1.36
#31	2020-05-01	2.19 %	3.51 %	+1.32
#32	2020-06-01	1.96 %	3.22 %	+1.26
#33	2020-07-01	1.54 %	2.72 %	+1.18
#34	2020-08-01	1.32 %	2.51 %	+1.19
#35	2020-09-01	1.42 %	2.64 %	+1.22
#36	2020-10-01	1.44 %	2.61 %	+1.17
#37	2020-11-01	1.59 %	2.71 %	+1.12
#38	2020-12-01	1.68 %	2.78 %	+1.10
#39	2021-01-01	1.55 %	2.69 %	+1.14
#40	2021-02-01	1.38 %	2.60 %	+1.22
#41	2021-03-01	1.37 %	2.48 %	+1.11
#42	2021-04-01	1.42 %	2.61 %	+1.19
#43	2021-05-01	1.68 %	2.81 %	+1.13
#44	2021-06-01	1.33 %	2.62 %	+1.29
#45	2021-07-01	1.52 %	2.87 %	+1.35
#46	2021-08-01	1.59 %	3.02 %	+1.43
#47	2021-09-01	1.60 %	3.02 %	+1.42
#48	2021-10-01	1.66 %	3.16 %	+1.50
#49	2021-11-01	1.75 %	3.26 %	+1.51


#50	2021-12-01	1.87 %	3.28 %	+1.41
#51	2022-01-01	2.18 %	3.43 %	+1.25
#52	2022-02-01	2.06 %	3.50 %	+1.44
#53	2022-03-01	2.64 %	3.94 %	+1.30
#54	2022-04-01	3.47 %	4.44 %	+0.97
#55	2022-05-01	3.55 %	4.43 %	+0.88
#56	2022-06-01	4.35 %	4.97 %	+0.62
#57	2022-07-01	4.94 %	5.42 %	+0.48
#58	2022-08-01	4.69 %	5.33 %	+0.64
#59	2022-09-01	5.95 %	6.34 %	+0.39
#60	2022-10-01	5.71 %	6.28 %	+0.57
#61	2022-11-01	5.42 %	6.13 %	+0.71
#62	2022-12-01	5.51 %	5.99 %	+0.48
#63	2023-01-01	5.28 %	5.86 %	+0.58
#64	2023-02-01	5.47 %	5.77 %	+0.30
#65	2023-03-01	4.97 %	5.57 %	+0.60
#66	2023-04-01	4.33 %	5.22 %	+0.89
#67	2023-05-01	4.00 %	4.66 %	+0.66
#68	2023-06-01	3.52 %	4.34 %	+0.82
#69	2023-07-01	3.08 %	4.34 %	+1.26
#70	2023-08-01	3.27 %	4.59 %	+1.32
#71	2023-09-01	2.28 %	4.34 %	+2.06
#72	2023-10-01	2.56 %	3.90 %	+1.34
#73	2023-11-01	2.86 %	3.72 %	+0.86
#74	2023-12-01	2.61 %	3.66 %	+1.05
#75	2024-01-01	2.57 %	3.67 %	+1.10
#76	2024-02-01	2.75 %	3.64 %	+0.89
#77	2024-03-01	3.05 %	3.59 %	+0.54

Grafik *residual* juga menunjukkan bahwa model berjalan konsisten dibawah angka 0. Angka <-1 menunjukkan bahwa model terlalu optimis dalam melakukan tebakan terhadap nilai inflasi, sehingga dapat kita lihat di gambar sebelumnya bahwa nilai peramalam selalu berada diatas nilai aktual. Skema di model ini mengalami *overestimate*. Berikut adalah hasil visualisasi analisis *residual* pada Gambar 4.19.



Gambar 4. 19 Residual *Visualization N-BEATS 70% Train 30% Test*

Lalu grafik *Training Error per point* dari skema 70% Train 30% Test memiliki skema yang relatif sama dengan sebelumnya. Artinya model terus belajar dari pola-pola yang ada. Berikut adalah visualisasinya pada Gambar 4.20.



Gambar 4. 20 Training Error per Point *Visualization N-BEATS 70% Train 30% Test*

Terakhir adalah model dengan skema 60% *Train* 40% *Test*. 60% data untuk *training* dan 40% data untuk ujicoba. Berikut adalah hasil visualisasinya, terlihat pada Gambar 4.21.



Gambar 4. 21 Visualisasi Forecast vs Actual 60% *Train* 40% *Test*

Hasil ujicoba model dengan skema 60% *Train* 40% *Test* menunjukkan hasil dengan deviasi error cukup besar dibandingkan dengan skema sebelumnya. Nilai aktual skema 60% *Train* 40% *Test* memiliki masalah yang sama dengan 70% *Train* 30% *Test* dimana hasil *forecasting* memiliki jarak yang cukup jauh dan deviasi yang tinggi. *Confident Interval* juga memiliki masalah yang sama yaitu terlampaui jauh dari nilai aktual peramalan. Hal ini mengindikasikan adanya masalah yang teramplifikasi ketika data *training* semakin kecil. Dari ke-empat metrik yang digunakan sebagai validitas model, terlihat seluruhnya memiliki nilai diatas 15%. Berikut tabel perbandingan antar metrik yang dapat dilihat pada tabel 4.21.

Tabel 4 21 Metrik *N-BEATS* 80% Train 20% Test

<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>SMAPE</i>
1.502	1.688	64.88%	44.31%

Tabel 4.22 menunjukkan perbandingan antara nilai aktual dengan nilai dari hasil peramalan dari 40% data yang diujicoba, .

Tabel 4 22 Actual vs Forecast Table split 60% Train 40% Test


No	Date	Actual	Forecast	Difference
#1	2015-10-01	6.25 %	6.45 %	+0.20
#2	2015-11-01	4.89 %	5.34 %	+0.45
#3	2015-12-01	3.35 %	4.03 %	+0.68
#4	2016-01-01	4.14 %	4.53 %	+0.39
#5	2016-02-01	4.42 %	4.75 %	+0.33
#6	2016-03-01	4.45 %	4.69 %	+0.24
#7	2016-04-01	3.60 %	4.38 %	+0.78
#8	2016-05-01	3.33 %	4.25 %	+0.92
#9	2016-06-01	3.45 %	4.31 %	+0.86
#10	2016-07-01	3.21 %	4.33 %	+1.12
#11	2016-08-01	2.79 %	4.31 %	+1.52
#12	2016-09-01	3.07 %	4.45 %	+1.38
#13	2016-10-01	3.31 %	4.63 %	+1.32
#14	2016-11-01	3.58 %	4.72 %	+1.14
#15	2016-12-01	3.02 %	4.71 %	+1.69
#16	2017-01-01	3.49 %	5.05 %	+1.56
#17	2017-02-01	3.83 %	5.35 %	+1.52
#18	2017-03-01	3.61 %	5.14 %	+1.53
#19	2017-04-01	4.17 %	5.25 %	+1.08

#20	2017-05-01	4.33 %	5.31 %	+0.98
#21	2017-06-01	4.37 %	5.30 %	+0.93
#22	2017-07-01	3.88 %	5.07 %	+1.19
#23	2017-08-01	3.82 %	4.90 %	+1.08
#24	2017-09-01	3.72 %	4.90 %	+1.18
#25	2017-10-01	3.58 %	4.90 %	+1.32
#26	2017-11-01	3.30 %	4.91 %	+1.61
#27	2017-12-01	3.61 %	5.06 %	+1.45
#28	2018-01-01	3.25 %	4.98 %	+1.73
#29	2018-02-01	3.18 %	5.02 %	+1.84
#30	2018-03-01	3.40 %	5.32 %	+1.92
#31	2018-04-01	3.41 %	5.37 %	+1.96
#32	2018-05-01	3.23 %	5.38 %	+2.15
#33	2018-06-01	3.12 %	5.30 %	+2.18
#34	2018-07-01	3.18 %	5.06 %	+1.88
#35	2018-08-01	3.20 %	5.18 %	+1.98
#36	2018-09-01	2.88 %	4.93 %	+2.05
#37	2018-10-01	3.16 %	4.90 %	+1.74
#38	2018-11-01	3.23 %	4.86 %	+1.63
#39	2018-12-01	3.13 %	4.69 %	+1.56
#40	2019-01-01	2.82 %	4.50 %	+1.68
#41	2019-02-01	2.57 %	4.39 %	+1.82
#42	2019-03-01	2.48 %	4.36 %	+1.88
#43	2019-04-01	2.83 %	4.60 %	+1.77
#44	2019-05-01	3.32 %	4.85 %	+1.53
#45	2019-06-01	3.28 %	4.83 %	+1.55
#46	2019-07-01	3.32 %	4.92 %	+1.60
#47	2019-08-01	3.49 %	5.16 %	+1.67
#48	2019-09-01	3.39 %	5.05 %	+1.66
#49	2019-10-01	3.13 %	4.89 %	+1.76

#50	2019-11-01	3.00 %	4.89 %	+1.89
#51	2019-12-01	2.72 %	4.58 %	+1.86
#52	2020-01-01	2.68 %	4.65 %	+1.97
#53	2020-02-01	2.98 %	4.90 %	+1.92
#54	2020-03-01	2.96 %	4.85 %	+1.89
#55	2020-04-01	2.67 %	4.69 %	+2.02
#56	2020-05-01	2.19 %	4.37 %	+2.18
#57	2020-06-01	1.96 %	4.22 %	+2.26
#58	2020-07-01	1.54 %	3.89 %	+2.35
#59	2020-08-01	1.32 %	3.79 %	+2.47
#60	2020-09-01	1.42 %	3.88 %	+2.46
#61	2020-10-01	1.44 %	3.87 %	+2.43
#62	2020-11-01	1.59 %	3.95 %	+2.36
#63	2020-12-01	1.68 %	3.99 %	+2.31
#64	2021-01-01	1.55 %	3.93 %	+2.38
#65	2021-02-01	1.38 %	3.87 %	+2.49
#66	2021-03-01	1.37 %	3.78 %	+2.41
#67	2021-04-01	1.42 %	3.84 %	+2.42
#68	2021-05-01	1.68 %	3.96 %	+2.28
#69	2021-06-01	1.33 %	3.82 %	+2.49
#70	2021-07-01	1.52 %	3.97 %	+2.45
#71	2021-08-01	1.59 %	4.04 %	+2.45
#72	2021-09-01	1.60 %	4.02 %	+2.42
#73	2021-10-01	1.66 %	4.10 %	+2.44
#74	2021-11-01	1.75 %	4.14 %	+2.39
#75	2021-12-01	1.87 %	4.14 %	+2.27
#76	2022-01-01	2.18 %	4.20 %	+2.02
#77	2022-02-01	2.06 %	4.19 %	+2.13
#78	2022-03-01	2.64 %	4.54 %	+1.90
#79	2022-04-01	3.47 %	4.91 %	+1.44


#80	2022-05-01	3.55 %	4.91 %	+1.36
#81	2022-06-01	4.35 %	5.26 %	+0.91
#82	2022-07-01	4.94 %	5.56 %	+0.62
#83	2022-08-01	4.69 %	5.54 %	+0.85
#84	2022-09-01	5.95 %	6.19 %	+0.24
#85	2022-10-01	5.71 %	6.14 %	+0.43
#86	2022-11-01	5.42 %	6.00 %	+0.58
#87	2022-12-01	5.51 %	5.83 %	+0.32
#88	2023-01-01	5.28 %	5.73 %	+0.45
#89	2023-02-01	5.47 %	5.64 %	+0.17
#90	2023-03-01	4.97 %	5.49 %	+0.52
#91	2023-04-01	4.33 %	5.20 %	+0.87
#92	2023-05-01	4.00 %	4.82 %	+0.82
#93	2023-06-01	3.52 %	4.63 %	+1.11
#94	2023-07-01	3.08 %	4.65 %	+1.57
#95	2023-08-01	3.27 %	4.81 %	+1.54
#96	2023-09-01	2.28 %	4.65 %	+2.37
#97	2023-10-01	2.56 %	4.39 %	+1.83
#98	2023-11-01	2.86 %	4.30 %	+1.44
#99	2023-12-01	2.61 %	4.28 %	+1.67
#100	2024-01-01	2.57 %	4.31 %	+1.74
#101	2024-02-01	2.75 %	4.32 %	+1.57
#102	2024-03-01	3.05 %	4.30 %	+1.25

Grafik *residual* juga menunjukkan bahwa model memiliki kendala yang sama dengan skema sebelumnya, yaitu berjalan konsisten dibawah angka 0 alias *residual* negatif. Model terlalu overestimate terhadap nilai inflasi. Berikut adalah hasil visualisasi analisis *residual* pada Gambar 4.22.



Gambar 4. 22 Residual Visualization *N-BEATS* 60% Train 40% Test

Untuk grafik *Training Error per point* dari sekam 60% Train 40% Test juga memiliki skema yang relatif sama dengan sebelumnya. Berikut adalah visualisasinya pada Gambar 4.23.



Gambar 4. 23 Training Error per Point Visualization *N-BEATS* 60% Train 40% Test

Dari ketiga ujicoba terhadap model *N-BEATS* varian *N-BEATSx*. Dapat disimpulkan bahwa skema 80% Train 20% Test memberikan hasil paling akurat dan nilai matriks yang lebih bagus jika dibandingkan dengan dua skema lainnya yaitu 70% Train 30% Test dan 60% Train 40% Test. Berikut adalah tabel perbandingan ketiga skema yang dapat dilihat pada Tabel 4.23.

Tabel 4 23 Komparasi ujicoba *N-BEATS*

<i>N-BEATS</i>	<i>Training Data</i>	<i>Testing Data</i>	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>SMAPE</i>
Ujicoba 1	80%	20%	0.297	0.473	9.42%	10.00%
Ujicoba 2	70%	30%	1.016	1.105	44.50%	34.55%
Ujicoba 3	60%	40%	1.502	1.688	64.88 %	44.31 %

4.4 Integrasi Islam Dalam Penelitian

A. Tinjauan *Muamalah Ma'a Allah*

Penelitian ini dilaksanakan tidak hanya sebagai bentuk tanggung jawab penulis terhadap kewajiban akademik, tetapi juga kepada Allah SWT (*muamalah ma'a Allah*). Dalam general perspektif menurut Islam, menuntut ilmu dan mengembangkan pengetahuan merupakan bagian dari ibadah.

Penerepan metode *N-BEATS* dalam melakukan *forecasting* inflasi dilakukan dengan tanggung jawab penulis. Seluruh proses penelitian dimulai dari pengumpulan data, pengolahan data, pemodelan, hingga evaluasi hasil dari *forecasting* dilakukan secara hati-hati dan cermat.

Penulis juga menyadari bahwa implementasi penelitian ini dengan menggunakan metode *N-BEATS deep learning* merupakan amanah ilmu yang diberikan oleh Allah SWT. Sehingga penelitian ini diniatkan juga sebagai bentuk ibadah dan pengabdian. Hal ini seperti yang dijelaskan di dalam QS. Al-Mujadilah ayat 11 yang berbunyi :

يَا أَيُّهَا الَّذِينَ آمَنُوا إِذَا قِيلَ لَكُمْ تَفَسَّحُوا فِي الْمَجَالِسِ فَافْسَحُوا يَفْسَحِ اللَّهُ لَكُمْ وَإِذَا قِيلَ انشُرُوا فَاَنْشُرُوا يَرْفَعِ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ وَاللَّهُ بِمَا تَعْمَلُونَ خَبِيرٌ

“Wahai orang-orang yang beriman, apabila dikatakan kepadamu “Berilah kelapangan di dalam majelis-majelis,” lapangkanlah, niscaya Allah akan memberi kelapangan untukmu. Apabila dikatakan, “Berdirilah,” (kamu) berdirilah. Allah niscaya akan mengangkat orang-orang yang beriman di antaramu dan orang-orang yang diberi ilmu beberapa derajat. Allah Mahateliti terhadap apa yang kamu kerjakan.”

Berdasarkan tafsir dari Ahmad Mustofa Al-Maraghi dari *Tafsir Al-Maraghi* menjelaskan bahwa ayat ini mencakup pemberian kelapangan dan segala kebaikan kepada kaum muslimin. Allah akan meninggikan derajat bagi orang mukmin yang patuh dengan perintah-Nya, khususnya orang-orang berilmu, derajat-derajat yang banyak dalam pahala (Al-Maraghi sebagaimana dikutip dalam Sholeh, 2016). Dalam konteks penelitian ini, ilmu yang diriset dan ditelaah adalah metode *forecasting* inflasi Indonesia menggunakan *N-BEATS*. Pengaplikasian ilmu ini di bidang teknologi menjadi salah satu bentuk ikhtiar untuk dapat menjadi orang-orang yang turut andil dalam keilmuan dan penyebarannya untuk masyarakat. Sebagaimana dikatakan di dalam Al-Mujadilah ayat 11 dan *Tafsir Al-Maraghi*, bahwa orang-orang yang berilmu akan diangkat derajat pahala dan kebaikannya.

B. Tinjauan *Muamalah Ma'a An-nas*

Muamalah Ma'a An-nas dalam penelitian ini dapat terlihat dari tujuan dan manfaat dari penerapan metode *N-BEATS* untuk melakukan *forecasting* inflasi Indonesia. Inflasi merupakan salah satu indikator dari berjalannya sebuah perekonomian suatu negara. Inflasi menjadi salah satu acuan untuk melihat bagaimana kehidupan masyarakat khususnya dalam daya beli, stabilitas harga, dan kesejahteraan sosial.

Hasil dari *forecasting* inflasi yang diperoleh dari penelitian ini diharapkan dapat mampu memberikan manfaat bagi berbagai *stakeholder* terkait seperti pemerintah, akademisi, dan juga masyarakat umum. Pemerintah dapat menjadikan nilai prediksi sebagai pertimbangan dalam merumuskan kebijakan fiskal dan moneter negara. Untuk masyarakat, informasi proyeksi inflasi dapat membantu perancahan ekonomi individu dalam menavigasi dan merancang kebutuhan pribadi. Hal ini seperti yang pernah dilakukan oleh nabi yusuf didalam surat Yusuf ayat 47-48 yang berbunyi :

قَالَ تَزْرَعُونَ سَبْعَ سِنِينَ دَابًّا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُنْبُلِهِ إِلَّا قَلِيلًا مِّمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ
بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَأْكُلْنَ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِّمَّا نُحْصِنُونَ ﴿٤٨﴾

“(Yusuf) berkata, “Bercocoktanamlah kamu tujuh tahun berturut-turut! Kemudian apa yang kamu tuai, biarkanlah di tangkainya, kecuali sedikit untuk kamu makan. Kemudian, sesudah itu akan datang tujuh (tahun) yang sangat sulit (paceklik) yang menghabiskan apa yang kamu simpan untuk menghadapinya, kecuali sedikit dari apa (bibit gandum) yang kamu simpan.”

Ibnu Katsir menjelaskan didalam kitabnya bahwa Nabi Yusuf menghimbau untuk mengkonsumsi makanan dengan hati-hati sehingga jumlah makanan akan cukup sebagai persediaan selama masa paceklik. Nabi Yusuf kemudian memberitahu raja tentang adanya tujuh tahun masa paceklik, kemudian setelah itu tahun-tahun berbuah akan tiba. (Ibnu Katsir sebagaimana dikutip dari Zulaiha, dkk 2023). Tafsir ini dapat interpretasikan sebagai rencana ekonomi dari Nabi Yusuf dalam menghadapi informasi dari masa mendatang (Zulaiha, 2023). Dalam penelitian ini, rencana yang dilakukan oleh Nabi Yusuf A.S sejalan dengan kebijakan *stakeholder* dalam penentuan kebijakan fiskal dan moneter berdasarkan data yang ada. Nabi yusuf mendapatkan wahyu tuhan dan menjadi basis atas keputusan ekonomi yang

dilakukan di masa paceklik. Sedangkan di masa modern, stakeholder dapat memanfaatkan teknologi *forecasting* seperti *N-BEATS* untuk melakukan proyeksi ekonomi dan merencanakan kebijakan-kebijakan di masa mendatang.

Selain itu, penelitian ini juga ikut berperan dalam pengembangan ilmu, pengetahuan di bidang ekonomi khususnya pada bidang terapan untuk analisis data ekonomi. Dengan demikian penelitian ini tidak hanya berorientasi pada kepentingan akademik semata, tetapi diharapkan dapat memberikan kemaslahatan bagi umat. Hal ini sejalan dengan prinsip Islam yaitu menekankan ilmu dan memberikan manfaat bagi sesama umat manusia

BAB V

KESIMPULAN

5.1 Kesimpulan

Penelitian ini bertujuan untuk melakukan implementasi Model *N-BEATS* dalam peramalan inflasi Indonesia. Berdasarkan hasil ujicoba dan pembahasan yang dijabarkan pada bab sebelumnya, dapat diambil kesimpulan sebagai berikut :

1. Model *N-BEATS* berhasil diterapkan untuk memprediksi nilai inflasi Indonesia di masa mendatang. Ujicoba penerapan *N-BEATS* varian multivariate dilakukan dengan menggunakan tiga skema uji split *Train* dan *Test* data. Skema pertama adalah 80% *Train* 20% *Test*, kedua adalah 70% *Train* 30% *Test*, dan yang ketiga adalah 60% *Train* 40% *Test*, menunjukkan bahwa skema 80% *Train* 20% *Test* menunjukkan hasil terbaik dengan perolehan nilai metrik sebagai berikut : nilai *MAE* sebesar 0.297, nilai *RMSE* sebesar 0.473, nilai *MAPE* sebesar 9.42 % dan nilai *SMAPE* sebesar 10.00 %
2. Dari sisi ekonomi, hasil penelitian ini dapat digunakan sebagai salah satu pertimbangan praktis dalam penentuan kebijakan

5.2. Saran

Berikut adalah beberapa saran dan masukan yang dapat digunakan di pengembangan penelitian selanjutnya.

1. Perbandingan dengan Model Statistika Klasik. Penelitian selanjutnya dapat menambahkan *ARIMA*, *Prophet*, atau *SARIMA* sebagai pembanding dari model klasik

2. Peningkatan Interpretabilitas Visual, menerapkan fitur tambahan seperti *SHAP* (*SHapley Additive Explanaition*) atau *Feature Attribution Map*, agar hasil prediksi dapat lebih mudah dipahami

5.3. Penutup

Penelitian ini membuktikan bahwa *N-BEATS* merupakan model deep-learning yang efektif dalam peramalan inflasi indonesia. Hasil yang diperoleh tidak hanya memberikan kontribusi teoritis tetapi juga menawarkan manfaat praktis dalam mendukung kebijakan ekonomi berbasis data. Dengan demikian diharapkan penelitian ini dapat menjadi dasar untuk penelitian lanjutan bagi penulis maupun orang lain.

DAFTAR PUSTAKA

- Adrian Sutedi, S. H. (2022). *Hukum keuangan negara*. Sinar Grafika.
- Baron, M., & Karpinski, A. (2025). *The Relevance of AWS Chronos: An Evaluation of Standard Methods for Time Series Forecasting with Limited Tuning*. Diambil dari <http://arxiv.org/abs/2501.10216>
- Bharath. (2021). *Stock Price Prediction Using Deep Learning (Part 1)*.
- Bhatti, A., Thangavelu, N., Hassan, M., Kim, C., Lee, S., Kim, Y., & Kim, J. Y. (2023). *Interpreting Forecasted Vital Signs Using N-BEATS in Sepsis Patients*. <https://doi.org/https://doi.org/10.48550/arXiv.2306.14016>
- Binte Habib, A. (2022). *A Detailed Explanation of the workflow of N-BEATS Architecture*. <https://doi.org/10.13140/RG.2.2.36379.34083>
- Black, S. (2020). *Identifying and Quantifying Trends in Time Series Data using the Mann-Kendall Test*. Diambil dari <https://sam-black.medium.com/identifying-and-quantifying-trends-in-time-series-data-using-the-mann-kendall-test-7ef282c451f4>
- Botchkarev, A. (2019). A New Typology Design of Performance Metrik to Measure Errors in Machine Learning Regression Algorithms. *Interdisciplinary Journal of Information, Knowledge, and Management*, 14, 045–076. <https://doi.org/10.28945/4184>
- Bulatov, A. (2020). *Forecasting bitcoin prices using n-beats deep learning architecture*.
- Cochrane, J. H. (1997). *Time series for macroeconomics and finance*. U. of Chicago,.
- Hasanah, U. (2023). Peramalan BI Rate Di Indonesia Dengan Metode *Time Series Model ARIMA*. Dalam *IHTIYATH Jurnal Manajemen Keuangan Syariah* (Vol. 7).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep Residual Learning for Image Recognition*. Diambil dari <http://image-net.org/challenges/LSVRC/2015/>
- Heizer, J., & Render, B. (2015). *Manajemen Operasi* (alih bahasa oleh Hirson Kurnia, Ratna Saraswati dan David Wijaya). *Salemba Empat, Jakarta*.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Jossou, T. R., Tahori, Z., Houdji, G., Medenou, D., Lasfar, A., Sanya, F., ... Et-Tahir, A. (2022). N-Beats as an *EHG Signal Forecasting Method for Labour Prediction in Full Term Pregnancy*. *Electronics (Switzerland)*, 11(22). <https://doi.org/10.3390/electronics11223739>

- Kenton, W. (2023). Economy: What It Is, Types of Economies. *Economic Indicators*. retrieve from Investopedia, <https://www.investopedia.com/terms/e/economy.asp>.
- Liu, Y., Zhong, C., Ma, Q., Jiang, Y., & Zhang, C. (2023). *The S&P 500 Index Prediction Based on N-BEATS*. https://doi.org/10.2991/978-94-6463-198-2_96
- Nayak, G. H. H., Alam, M. W., Avinash, G., Singh, K. N., Ray, M., & Kumar, R. R. (2024). *N-BEATS Deep Learning Architecture for Agricultural Commodity Price Forecasting*. *Potato Research*. <https://doi.org/10.1007/s11540-024-09789-y>
- Oreshkin, B. N., Carpov, D., Chapados, N., & Bengio, Y. (2019). *N-BEATS: Neural basis expansion analysis for interpretable time series forecasting*. *arXiv preprint arXiv:1905.10437*.
- K. G. Olivares, C. Challu, G. Marcjasz, R. Weron, and A. Dubrawski, "Neural basis expansion analysis with exogenous variabls: *Forecasting* electricity prices with NBEATSx," *Int. J. Forecast.*, vol. 39, no. 2, pp. 884–900, Apr.–Jun. 2023, doi: 10.1016/j.ijforecast.2022.03.001
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., ... Ziel, F. (2022, Juli 1). *Forecasting: theory and practice*. *International Journal of Forecasting*, Vol. 38, hlm. 705–871. Elsevier B.V. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- Prasad, A., Sharma, S., & Agarwal, H. (2022, Februari 9). *Forecasting Marine Heatwaves using Machine Learning*. <https://doi.org/10.31223/X58D2S>
- Prihadyatama, A., & Kurniawan, H. A. (2022). Studi literatur roadmap pengendalian inflasi daerah di indonesia. *Inisiatif: Jurnal Ekonomi, Akuntansi Dan Manajemen*, 1(4), 238–264.
- Priyono, D., & Handayani, H. R. (2021). Analisis Pengaruh PDRB, Inflasi, Jumlah Penduduk Terhadap Pendapatan Asli Daerah di Kabupaten Eks Karisidenan Pati Tahun 2012 - 2018. *Diponegoro Journal of Economics*, 10(2). <https://doi.org/10.14710/djoe.31614>
- Rahayu, P. N. U. (2020). *Peramalan Curah Hujan Di Kota Semarang Dengan Metode Hybrid Seasonal Autoregressive Integrated Moving Average (SARIMA) Adapative Neuro Fuzzy Inference System (ANFIS) Jurnal Ilmiah*. Diambil dari <http://repository.unimus.ac.id>
- Samudra, M. S., Marcelina, D., Terttiaavini, Yulianti, E., Coyanda, J., & Putri, I. (2024). Penerapan Metode *Forecasting* Dalam Menentukan Prediksi Jumlah Mahasiswa Baru Dengan Menggunakan Single Exponential Smoothing. *Jurnal Ilmiah Informatika Global*, 15, 45–51. <https://doi.org/10.36982/jiig.v15i2.3916>

- Simanungkalit, E. F. B. (2020). Pengaruh inflasi terhadap pertumbuhan ekonomi di Indonesia. *Journal of Management: Small and Medium Enterprises (SMEs)*, 13(3), 327–340.
- Singh, N. P., & Alam, M. N. (2024, Maret 20). *Short-Term Forecasting in Smart Grid Environment using N-BEATS*. <https://doi.org/10.21203/rs.3.rs-4116626/v1>
- Sutawijaya, A. (2012). *Pengaruh Faktor-Faktor Ekonomi Terhadap Inflasi Indonesia*.
- Syakura, A., Hendaryani, O., & Ramadhan, R. (2016). Analisis Penggunaan Peramalan dalam Meminimalkan Biaya Simpan Produk Linzhi Plus pada CV. HN. *PERFORMA: Media Ilmiah Teknik Industri*, 15(2), 93–104. <https://doi.org/10.20961/performa.15.2.9826>
- Zein, M. H., Yudistira, N., & Adikara, P. P. (2024). Indonesian Stock Price Prediction Using *Neural Basis Expansion Analysis for Interpretable Time Series* Method. *Journal of Information and Communication Technology*, 23(3), 361–392. <https://doi.org/10.32890/jict2024.23.3.1>
- Taufiq. (2018) Memakan Harta Secara Bathil (Perspektif Surat An-Nisa: 29 dan At-Taubah: 34) . *Jurnal Ilmiah Syariah (JURIS)*, 17(2), 5. <https://doi.org/10.31958/juris.v17i2.1162>
- Ananda, Rizqa., Fauzi Aseri, Akh., & Hafidzi, Anwar. (2025). Keadilan Distributif dalam Ekonomi Syariah: Studi Qs. Al-Hasyr Ayat 7 terhadap Kebijakan Fiskal dan Pemerataan Ekonomi di Indonesia. *Journal of Islamic Law and Studies*, Vol 9, no 1, <https://jurnal.uin-antasari.ac.id/index.php/jils/article/view/17184>
- Sholeh, (2016). Pendidikan dalam Al- Qur'an (Konsep Ta'lim QS. Al-Mujadalah ayat 11). 1(113), 206–222. *Jurnal Pendidikan Agama Islam Al-Thariqah*. [https://doi.org/10.25299/althariqah.2016.vol1\(2\).633](https://doi.org/10.25299/althariqah.2016.vol1(2).633)
- Zulaiha, E., & Yunus, B. M. (2024). Reinterpretasi Kisah Nabi Yusuf dalam Al-Qur ' an untuk Strategi Pemberdayaan Ekonomi Masyarakat. 2(3), 279–286. *Mashadiruna: Jurnal Ilmu Al-Qurân dan Tafsir UIN Sunan Gunung Djati*. <https://doi.org/10.15575/mjiat.v2i3.25243>

LAMPIRAN

Dataset Penelitian

1. Indonesia Monthly Inflation by Bank Indonesia

Date	Inflation
2003-01-01	8.68
2003-02-01	7.60
2003-03-01	7.17
2003-04-01	7.62
2003-05-01	7.15
2003-06-01	6.98
2003-07-01	6.27
2003-08-01	6.51
2003-09-01	6.33
2003-10-01	6.48
2003-11-01	5.53
2003-12-01	5.16
2004-01-01	4.82
2004-02-01	4.60
2004-03-01	5.11
2004-04-01	5.92
2004-05-01	6.47
2004-06-01	6.83
2004-07-01	7.20
2004-08-01	6.67
2004-09-01	6.27
2004-10-01	6.22
2004-11-01	6.18
2004-12-01	6.40
2005-01-01	7.32
2005-02-01	7.15
2005-03-01	8.81
2005-04-01	8.12
2005-05-01	7.40
2005-06-01	7.42
2005-07-01	7.84
2005-08-01	8.33
2005-09-01	9.06
2005-10-01	17.89
2005-11-01	18.38
2005-12-01	17.11
2006-01-01	17.03
2006-02-01	17.92
2006-03-01	15.74
2006-04-01	15.40

2006-05-01	15.60
2006-06-01	15.53
2006-07-01	15.15
2006-08-01	14.90
2006-09-01	14.55
2006-10-01	6.29
2006-11-01	5.27
2006-12-01	6.60
2007-01-01	6.26
2007-02-01	6.30
2007-03-01	6.52
2007-04-01	6.29
2007-05-01	6.01
2007-06-01	5.77
2007-07-01	6.06
2007-08-01	6.51
2007-09-01	6.95
2007-10-01	6.88
2007-11-01	6.71
2007-12-01	6.59
2008-01-01	7.36
2008-02-01	7.40
2008-03-01	8.17
2008-04-01	8.96
2008-05-01	10.38
2008-06-01	11.03
2008-07-01	11.90
2008-08-01	11.85
2008-09-01	12.14
2008-10-01	11.77
2008-11-01	11.68
2008-12-01	11.06
2009-01-01	9.17
2009-02-01	8.60
2009-03-01	7.92
2009-04-01	7.31
2009-05-01	6.04
2009-06-01	3.65
2009-07-01	2.71
2009-08-01	2.75
2009-09-01	2.83
2009-10-01	2.57
2009-11-01	2.41
2009-12-01	2.78
2010-01-01	3.72
2010-02-01	3.81

2010-03-01	3.43
2010-04-01	3.91
2010-05-01	4.16
2010-06-01	5.05
2010-07-01	6.22
2010-08-01	6.44
2010-09-01	5.80
2010-10-01	5.67
2010-11-01	6.33
2010-12-01	6.96
2011-01-01	7.02
2011-02-01	6.84
2011-03-01	6.65
2011-04-01	6.16
2011-05-01	5.98
2011-06-01	5.54
2011-07-01	4.61
2011-08-01	4.79
2011-09-01	4.61
2011-10-01	4.42
2011-11-01	4.15
2011-12-01	3.79
2012-01-01	3.65
2012-02-01	3.56
2012-03-01	3.97
2012-04-01	4.50
2012-05-01	4.45
2012-06-01	4.53
2012-07-01	4.56
2012-08-01	4.58
2012-09-01	4.31
2012-10-01	4.61
2012-11-01	4.32
2012-12-01	4.30
2013-01-01	4.57
2013-02-01	5.31
2013-03-01	5.90
2013-04-01	5.57
2013-05-01	5.47
2013-06-01	5.90
2013-07-01	8.61
2013-08-01	8.79
2013-09-01	8.40
2013-10-01	8.32
2013-11-01	8.37
2013-12-01	8.38

2014-01-01	8.22
2014-02-01	7.75
2014-03-01	7.32
2014-04-01	7.25
2014-05-01	7.32
2014-06-01	6.70
2014-07-01	4.53
2014-08-01	3.99
2014-09-01	4.53
2014-10-01	4.83
2014-11-01	6.23
2014-12-01	8.36
2015-01-01	6.96
2015-02-01	6.29
2015-03-01	6.38
2015-04-01	6.79
2015-05-01	7.15
2015-06-01	7.26
2015-07-01	7.26
2015-08-01	7.18
2015-09-01	6.83
2015-10-01	6.25
2015-11-01	4.89
2015-12-01	3.35
2016-01-01	4.14
2016-02-01	4.42
2016-03-01	4.45
2016-04-01	3.60
2016-05-01	3.33
2016-06-01	3.45
2016-07-01	3.21
2016-08-01	2.79
2016-09-01	3.07
2016-10-01	3.31
2016-11-01	3.58
2016-12-01	3.02
2017-01-01	3.49
2017-02-01	3.83
2017-03-01	3.61
2017-04-01	4.17
2017-05-01	4.33
2017-06-01	4.37
2017-07-01	3.88
2017-08-01	3.82
2017-09-01	3.72
2017-10-01	3.58

2017-11-01	3.30
2017-12-01	3.61
2018-01-01	3.25
2018-02-01	3.18
2018-03-01	3.40
2018-04-01	3.41
2018-05-01	3.23
2018-06-01	3.12
2018-07-01	3.18
2018-08-01	3.20
2018-09-01	2.88
2018-10-01	3.16
2018-11-01	3.23
2018-12-01	3.13
2019-01-01	2.82
2019-02-01	2.57
2019-03-01	2.48
2019-04-01	2.83
2019-05-01	3.32
2019-06-01	3.28
2019-07-01	3.32
2019-08-01	3.49
2019-09-01	3.39
2019-10-01	3.13
2019-11-01	3.00
2019-12-01	2.72
2020-01-01	2.68
2020-02-01	2.98
2020-03-01	2.96
2020-04-01	2.67
2020-05-01	2.19
2020-06-01	1.96
2020-07-01	1.54
2020-08-01	1.32
2020-09-01	1.42
2020-10-01	1.44
2020-11-01	1.59
2020-12-01	1.68
2021-01-01	1.55
2021-02-01	1.38
2021-03-01	1.37
2021-04-01	1.42
2021-05-01	1.68
2021-06-01	1.33
2021-07-01	1.52
2021-08-01	1.59

2021-09-01	1.60
2021-10-01	1.66
2021-11-01	1.75
2021-12-01	1.87
2022-01-01	2.18
2022-02-01	2.06
2022-03-01	2.64
2022-04-01	3.47
2022-05-01	3.55
2022-06-01	4.35
2022-07-01	4.94
2022-08-01	4.69
2022-09-01	5.95
2022-10-01	5.71
2022-11-01	5.42
2022-12-01	5.51
2023-01-01	5.28
2023-02-01	5.47
2023-03-01	4.97
2023-04-01	4.33
2023-05-01	4.00
2023-06-01	3.52
2023-07-01	3.08
2023-08-01	3.27
2023-09-01	2.28
2023-10-01	2.56
2023-11-01	2.86
2023-12-01	2.61
2024-01-01	2.57
2024-02-01	2.75
2024-03-01	3.05

2. USD-IDR Exchange Rate by Yahoo Finance

Date	Open Price	High	Low	Close	Adj Close
2003-01-01	8920.0000	9043.0000	8735.0000	8870.0000	8870.0000
2003-02-01	8875.0000	9085.0000	8745.0000	8883.5000	8883.5000
2003-03-01	8932.5000	9195.0000	8730.0000	8901.5000	8901.5000
2003-04-01	8900.0000	8995.0000	8590.0000	8707.5000	8707.5000
2003-05-01	8685.0000	8692.0000	8670.0000	8675.0000	8675.0000
2003-12-01	8469.2998	8570.9004	8331.0996	8404.2998	8404.2998
2004-01-01	8416.0000	8549.5000	8205.0000	8453.5996	8453.5996
2004-02-01	8453.5996	8550.2998	8287.0000	8389.5996	8389.5996
2004-03-01	8382.9004	8752.2002	8382.2002	8585.5000	8585.5000
2004-04-01	8585.9004	8814.5996	8473.0000	8665.5000	8665.5000
2004-05-01	8665.5000	9310.4004	8605.2002	9256.9004	9256.9004

2004-06-01	9258.0996	9570.7998	9175.0000	9409.0996	9409.0996
2004-07-01	9410.5996	9426.9004	8740.0000	9133.9004	9133.9004
2004-08-01	9133.9004	9374.2998	9044.4004	9361.5000	9361.5000
2004-09-01	9361.9004	9371.9004	8912.0000	9147.0000	9147.0000
2004-10-01	9148.0996	9212.0000	8695.0000	9049.2002	9049.2002
2004-11-01	9051.7002	9127.5000	8851.0000	9018.2998	9018.2998
2004-12-01	9017.2998	9383.2002	8953.0000	9359.0000	9359.0000
2005-01-01	9359.0000	9481.0996	8979.5996	9157.5996	9157.5996
2005-02-01	9159.0000	9304.4004	9107.0000	9258.2998	9258.2998
2005-03-01	9259.0000	9530.0000	9168.0000	9465.0000	9465.0000
2005-04-01	9464.2998	9800.7998	9370.0000	9519.9004	9519.9004
2005-05-01	9519.9004	9560.9004	9335.5996	9508.0000	9508.0000
2005-06-01	9506.0996	9758.7002	9438.0000	9753.4004	9753.4004
2005-07-01	9760.0000	9888.7002	9655.0000	9799.5996	9799.5996
2005-08-01	9798.7998	10848.0000	9640.0000	9929.0996	9929.0996
2005-09-01	9929.0996	10532.0000	9900.0000	10286.0000	10286.0000
2005-10-01	10286.0000	10370.0000	9850.0000	10120.0000	10120.0000
2005-11-01	10120.0000	10189.0000	9880.0000	10010.0000	10010.0000
2005-12-01	10003.0000	10072.0000	9546.9004	9804.5000	9804.5000
2006-01-01	9804.5000	9830.0000	9233.0000	9355.0996	9355.0996
2006-02-01	9355.7998	9433.2998	9085.0000	9232.5996	9232.5996
2006-03-01	9233.0000	9338.0000	8930.0000	9035.7002	9035.7002
2006-04-01	9035.7002	9092.7998	1467.6000	8769.4004	8769.4004
2006-05-01	8769.4004	9366.7998	8615.0000	9270.7002	9270.7002
2006-06-01	9270.7002	9519.2002	9.0000	9163.0000	9163.0000
2006-07-01	9163.0000	9378.7002	9.0000	9074.2002	9074.2002
2006-08-01	9074.2002	9197.7998	1592.1000	9104.0000	9104.0000
2006-09-01	9104.7998	9288.2002	8972.0000	9189.7998	9189.7998
2006-10-01	9189.7998	9319.5996	8990.0000	9083.0996	9083.0996
2006-11-01	9084.5000	9213.7998	9001.0000	9155.4004	9155.4004
2006-12-01	9149.2002	9469.2998	8886.0000	8980.7002	8980.7002
2007-01-01	8980.7002	9162.0000	8870.0000	9031.2002	9031.2002
2007-02-01	9031.2002	9171.0000	8939.0000	9124.2002	9124.2002
2007-03-01	9123.5000	9265.0000	8985.0000	9082.0996	9082.0996
2007-04-01	9082.0996	9173.5996	8974.0000	9102.2002	9102.2002
2007-05-01	9102.2002	9141.0996	8571.0000	8818.9004	8818.9004
2007-06-01	8818.9004	9139.0000	28.9730	9025.0996	9025.0996
2007-07-01	9025.0996	9310.0000	8890.0000	9213.5996	9213.5996
2007-08-01	9215.0000	9487.4004	9165.0000	9454.5000	9454.5000
2007-09-01	9454.5000	9514.7998	9040.0000	9089.2998	9089.2998
2007-10-01	9090.2998	9184.0000	8987.4004	9087.7998	9087.7998
2007-11-01	9088.7002	10231.0000	8980.4004	9370.5000	9370.5000
2007-12-01	9370.5000	9478.7002	9092.0996	9459.9004	9459.9004
2008-01-01	9459.9004	9603.7998	9200.5996	9209.9004	9209.9004
2008-02-01	9210.5000	9351.5996	8957.2002	9039.4004	9039.4004
2008-03-01	9043.2998	197804.0000	8974.7002	9223.5996	9223.5996

2008-04-01	9207.2998	9400.2002	9055.5996	9354.5000	9354.5000
2008-05-01	9444.5996	9504.5000	9110.0000	9337.7998	9337.7998
2008-06-01	9333.5996	9458.7998	9130.7998	9194.5000	9194.5000
2008-07-01	9170.7002	9313.7998	9045.2998	9108.0996	9108.0996
2008-08-01	9330.5996	9358.5000	9064.0000	9177.2002	9177.2002
2008-09-01	9178.7002	9690.9004	9065.0000	9481.7002	9481.7002
2008-10-01	9479.7002	11036.0000	9330.0000	11024.0000	11024.0000
2008-11-01	11024.0000	12792.0000	10368.0000	12768.0000	12768.0000
2008-12-01	12771.0000	12851.0000	10595.0000	11160.0000	11160.0000
2009-01-01	11160.0000	11537.0000	3477.7000	11316.0000	11316.0000
2009-02-01	11316.0000	12144.0000	11282.0000	12041.0000	12041.0000
2009-03-01	12041.0000	12189.0000	11393.0000	11590.0000	11590.0000
2009-04-01	11592.0000	11652.0000	10513.0000	10713.0000	10713.0000
2009-05-01	10713.0000	10713.0000	10145.0000	10181.0000	10181.0000
2009-06-01	10181.0000	10514.0000	9791.5000	10179.0000	10179.0000
2009-07-01	10178.0000	10330.0000	9774.0996	9774.0996	9774.0996
2009-08-01	9774.0996	10101.0000	9662.7002	10101.0000	10101.0000
2009-09-01	10115.0000	10135.0000	9451.9004	9622.5000	9622.5000
2009-10-01	9714.2002	9732.5000	9306.7002	9605.5996	9605.5996
2009-11-01	9605.5996	9663.0996	9264.0000	9353.5996	9353.5996
2009-12-01	9354.7998	9737.0996	9304.0996	9427.2002	9427.2002
2010-01-01	9427.2002	9469.9004	9030.0000	9349.9502	9349.9502
2010-02-01	9359.9502	9664.9502	8867.7998	9335.2002	9335.2002
2010-03-01	9332.7998	9475.5996	8850.9004	9103.0000	9103.0000
2010-04-01	9101.9004	9149.2998	8870.7002	9028.7002	9028.7002
2010-05-01	9028.7002	9544.7002	8912.0000	9284.5996	9284.5996
2010-06-01	9285.0000	9415.5996	8910.0000	9044.7998	9044.7998
2010-07-01	9043.7002	9139.4004	8852.0000	8923.2002	8923.2002
2010-08-01	8923.2002	9093.7002	8775.5996	8918.0000	8918.0000
2010-09-01	9014.7002	9115.2002	8762.5000	8931.7998	8931.7998
2010-10-01	8934.0996	9056.4004	8768.2002	8923.7998	8923.7998
2010-11-01	891.9000	9042.9502	885.7800	9015.4502	9015.4502
2010-12-01	9038.4502	9051.9502	8833.5996	8886.0000	8886.0000
2011-01-01	8975.0000	9088.9502	8843.7002	8935.5996	8935.5996
2011-02-01	9039.9502	9044.9502	8676.7002	8841.4502	8841.4502
2011-03-01	8811.4502	8826.4502	8518.5000	8700.0000	8700.0000
2011-04-01	8718.5000	8721.9004	8399.0996	8553.2998	8553.2998
2011-05-01	8561.5000	8625.5000	8351.0996	8544.4502	8544.4502
2011-06-01	8539.9502	8629.0000	8276.7002	8616.9502	8616.9502
2011-07-01	8571.4502	8573.0000	8322.2998	8495.0000	8495.0000
2011-08-01	8490.4502	8600.0000	8249.5996	8532.9502	8532.9502
2011-09-01	8508.0000	9084.5000	8370.2002	8952.5996	8952.5996
2011-10-01	8809.9502	8974.9502	89.0000	8624.2002	8624.2002
2011-11-01	8892.4502	9190.0000	8726.4004	9120.5000	9120.5000
2011-12-01	9074.9502	9200.0000	8820.2998	8854.7998	8854.7998
2012-01-01	0.9107	9200.0000	0.8969	9074.0000	9074.0000

2012-02-01	9024.0000	9140.0000	0.8993	9005.0000	9005.0000
2012-03-01	9050.0000	9220.0000	0.9158	9112.0000	9112.0000
2012-04-01	0.9166	9211.5000	0.9166	9188.9502	9188.9502
2012-05-01	9192.4502	9581.5996	0.9285	9410.0000	9410.0000
2012-06-01	9368.5000	9500.9004	0.9425	9368.0000	9368.0000
2012-07-01	0.9416	9505.0000	0.9416	9424.2002	9424.2002
2012-08-01	9414.2002	9572.4502	0.9497	9514.7998	9514.7998
2012-09-01	9510.0000	9620.0000	0.9588	9569.9502	9569.9502
2012-10-01	9589.9502	9636.7002	0.9615	9586.2998	9586.2998
2012-11-01	9576.5000	9643.5996	9552.5000	9571.4004	9571.4004
2012-12-01	9569.0000	9697.2998	0.9615	9612.4502	9612.4502
2013-01-01	9607.7998	9860.0000	0.9804	9659.7002	9659.7002
2013-02-01	9669.2998	9737.0996	0.9699	9657.2998	9657.2998
2013-03-01	9634.7998	9815.7998	0.9737	9612.4502	9612.4502
2013-04-01	9610.0000	9751.9004	0.9747	9691.5000	9691.5000
2013-05-01	9694.0000	9800.0000	0.9756	9778.2002	9778.2002
2013-06-01	0.9823	9947.7998	0.9823	9612.4502	9612.4502
2013-07-01	9900.0000	10428.0000	9610.0000	10244.0000	10244.0000
2013-08-01	10250.0000	11383.0000	10229.0000	10895.0000	10895.0000
2013-09-01	10895.0000	11724.0000	1.1561	11552.0000	11552.0000
2013-10-01	11552.0000	11600.0000	9610.0000	11147.0000	11147.0000
2013-11-01	11245.0000	11880.0000	1.1364	11625.0000	11625.0000
2013-12-01	11625.0000	12217.0000	1.2048	12217.0000	12217.0000
2014-01-01	12158.0000	12237.0000	1.1891	12143.0000	12143.0000
2014-02-01	1.2195	12175.0000	1.1628	11601.0000	11601.0000
2014-03-01	1.1587	12295.0000	1.1377	11305.0000	11305.0000
2014-04-01	11230.0000	11643.0000	1.1351	11515.0000	11515.0000
2014-05-01	11553.0000	11725.0000	1.1429	1.1696	1.1696
2014-06-01	1.1696	12147.0000	1.1696	12020.0000	12020.0000
2014-07-01	11890.0000	11970.0000	1.1587	11561.0000	11561.0000
2014-08-01	11890.0000	11890.0000	1.1682	1.1710	1.1710
2014-09-01	11694.0000	12238.0000	1.1737	12132.0000	12132.0000
2014-10-01	12180.0000	12309.0000	1.2092	12150.0000	12150.0000
2014-11-01	1.2092	12276.0000	1.2092	1.2195	1.2195
2014-12-01	12250.0000	12875.0000	1.2407	12420.0000	12420.0000
2015-01-01	12390.0000	12755.0000	1.2516	1.2788	1.2788
2015-02-01	1.2788	12993.0000	1.2788	1.3004	1.3004
2015-03-01	1.3004	13248.0000	1.3021	13087.0000	13087.0000
2015-04-01	13040.0000	13050.0000	1.2887	12915.0000	12915.0000
2015-05-01	12957.0000	13228.0000	1.3072	13165.0000	13165.0000
2015-06-01	13198.0000	13395.0000	13060.0000	13322.0000	13322.0000
2015-07-01	13350.0000	13535.0000	13220.0000	13492.0000	13492.0000
2015-08-01	13485.0000	14170.0000	13340.0000	13910.0000	13910.0000
2015-09-01	14040.0000	14790.0000	13870.0000	14680.0000	14680.0000
2015-10-01	14643.0000	14738.0000	1.3793	1.3793	1.3793
2015-11-01	13620.0000	13855.0000	1.3812	13638.0000	13638.0000

2015-12-01	13835.0000	14150.0000	1.3661	13845.0000	13845.0000
2016-01-01	13775.0000	13978.0000	1.3812	1.4104	1.4104
2016-02-01	13728.0000	13808.0000	1.3441	13425.0000	13425.0000
2016-03-01	13330.0000	13443.0000	1.3038	13240.0000	13240.0000
2016-04-01	13155.0000	13248.0000	1.3141	1.3210	1.3210
2016-05-01	1.3210	13700.0000	1.3210	13631.0000	13631.0000
2016-06-01	13650.0000	13698.0000	1.3333	13139.0000	13139.0000
2016-07-01	13141.0000	13230.0000	1.3123	1.3123	1.3123
2016-08-01	13061.0000	13340.0000	1.3123	13283.0000	13283.0000
2016-09-01	13277.0000	13444.0000	1.3175	13003.0000	13003.0000
2016-10-01	13012.0000	13102.0000	1.2970	13063.0000	13063.0000
2016-11-01	13016.0000	13758.0000	1.3369	13502.0000	13502.0000
2016-12-01	13571.0000	13697.0000	1.3351	13518.0000	13518.0000
2017-01-01	13518.0000	13529.0000	1.3369	13338.0000	13338.0000
2017-02-01	13345.0000	13411.0000	1.3333	13339.0000	13339.0000
2017-03-01	13393.0000	13412.0000	1.3333	13299.0000	13299.0000
2017-04-01	1.3333	13377.0000	1.3298	13322.0000	13322.0000
2017-05-01	13322.0000	13465.0000	1.3333	13319.0000	13319.0000
2017-06-01	13294.0000	13357.0000	1.3316	13278.0000	13278.0000
2017-07-01	13295.0000	13417.0000	1.3298	13320.0000	13320.0000
2017-08-01	13295.0000	13382.0000	1.3333	13334.0000	13334.0000
2017-09-01	13321.0000	13566.0000	1.3263	1.3477	1.3477
2017-10-01	13465.0000	13647.0000	13405.0000	13574.0000	13574.0000
2017-11-01	13552.0000	13595.0000	13453.0000	13504.0000	13504.0000
2017-12-01	13541.0000	13619.0000	13477.0000	13477.0000	13477.0000
2018-01-01	13542.0000	13557.0000	13256.0000	13421.0000	13421.0000
2018-02-01	13384.0000	13766.0000	13378.0000	13694.0000	13694.0000
2018-03-01	13757.0000	13822.0000	13673.0000	13736.0000	13736.0000
2018-04-01	13748.0000	13986.0000	13721.5000	13870.0000	13870.0000
2018-05-01	13915.5000	14268.5000	13853.0000	13977.0000	13977.0000
2018-06-01	13923.5000	14402.0000	13809.0000	14350.0000	14350.0000
2018-07-01	14273.0000	14569.2002	14270.4004	14403.0000	14403.0000
2018-08-01	14409.2002	14882.2998	14374.0000	14751.0000	14751.0000
2018-09-01	14751.0000	15358.7998	14700.0000	14890.0000	14890.0000
2018-10-01	14902.0000	15409.0996	14885.0000	15273.0996	15273.0996
2018-11-01	15196.0000	15208.4004	14253.0000	14356.0000	14356.0000
2018-12-01	14358.5000	14710.0000	13971.7002	14553.0000	14553.0000
2019-01-01	14460.0000	14513.0000	13855.0000	14033.0000	14033.0000
2019-02-01	13931.5996	14244.0000	13885.5000	14015.0000	14015.0000
2019-03-01	14195.5000	14411.0000	14055.0000	14233.0000	14233.0000
2019-04-01	14233.0000	14305.0000	13972.0000	14191.0000	14191.0000
2019-05-01	14286.0000	14655.0000	14178.5000	14401.0000	14401.0000
2019-06-01	14399.0000	14415.0000	14078.7002	14184.5000	14184.5000
2019-07-01	14121.0000	14235.0000	13883.0000	14066.4004	14066.4004
2019-08-01	14165.0000	14442.7002	14054.2998	14231.0000	14231.0000
2019-09-01	14264.0000	14265.0000	13889.5000	14158.0000	14158.0000

2019-10-01	14221.9004	14265.0996	13971.9004	14060.0000	14060.0000
2019-11-01	14126.0000	14169.0000	13833.4932	14081.6670	14081.6670
2019-12-01	14081.3105	14170.2998	13719.0078	13919.0000	13919.0000
2020-01-01	13862.0000	13973.2998	13215.0400	13643.1807	13643.1807
2020-02-01	13762.2998	14422.0000	13434.6699	14311.5000	14311.5000
2020-03-01	14311.5000	16915.0000	13877.8184	16346.9619	16346.9619
2020-04-01	16395.5000	17178.0000	14399.0000	15234.6367	15234.6367
2020-05-01	15252.7998	15446.0000	14496.7002	14639.5996	14639.5996
2020-06-01	14540.7129	14603.0000	13804.8330	14470.2002	14470.2002
2020-07-01	14604.2002	14950.0000	14148.2002	14486.6689	14486.6689
2020-08-01	14697.0000	14971.0996	14296.4951	14618.0000	14618.0000
2020-09-01	14599.7002	15045.2998	14337.1328	14910.0000	14910.0000
2020-10-01	14857.0000	14933.5000	14462.9053	14585.0215	14585.0215
2020-11-01	14586.1699	14748.7998	13826.8730	14061.6445	14061.6445
2020-12-01	14200.0000	14324.2002	13832.3350	13832.5596	13832.5596
2021-01-01	13875.0000	14297.0000	13826.0996	14023.0000	14023.0000
2021-02-01	13843.5215	14410.0000	13724.6133	14332.4004	14332.4004
2021-03-01	14092.2578	14605.0000	14079.6787	14605.0000	14605.0000
2021-04-01	14605.0000	14688.0000	14384.9004	14439.7002	14439.7002
2021-05-01	14434.2002	14529.0000	14055.9004	14278.0000	14278.0000
2021-06-01	14274.2002	14629.0996	14148.0000	14629.0996	14629.0996
2021-07-01	14601.5996	14664.7998	14343.2002	14419.7002	14419.7002
2021-08-01	14419.7002	14548.0000	14142.4004	14362.0000	14362.0000
2021-09-01	14246.5000	14385.0000	14109.5000	14385.0000	14385.0000
2021-10-01	14366.5000	14366.5000	13579.2002	14228.5000	14228.5000
2021-11-01	14161.0000	14439.0996	14003.5000	14377.0000	14377.0000
2021-12-01	14330.0000	14514.0000	14022.0000	14285.2002	14285.2002
2022-01-01	14215.0000	14445.7998	14063.7002	14381.5996	14381.5996
2022-02-01	14350.0000	14457.2998	14081.0000	14334.2002	14334.2002
2022-03-01	14395.0000	14445.5000	14081.2002	14327.5000	14327.5000
2022-04-01	14351.0000	15611.5996	14275.2695	14506.0996	14506.0996
2022-05-01	14506.0996	14755.0000	14386.0000	14538.4004	14538.4004
2022-06-01	14543.9004	14984.0000	14364.5000	14877.0000	14877.0000
2022-07-01	14921.9004	15121.0000	14777.9004	14777.9004	14777.9004
2022-08-01	14826.0000	14977.0000	14635.5000	14850.0000	14850.0000
2022-09-01	14855.0000	15319.2998	14508.7002	15175.2002	15175.2002
2022-10-01	15303.0996	15656.7998	15115.0996	15549.2002	15549.2002
2022-11-01	15649.0000	15800.5000	15280.2002	15726.5000	15726.5000
2022-12-01	15634.5000	15795.2998	15286.0000	15502.2002	15502.2002
2023-01-01	15508.7998	15692.0996	14857.4004	14995.0000	14995.0000
2023-02-01	14990.7002	15286.5000	14824.7998	15209.0000	15209.0000
2023-03-01	15240.0000	15505.0996	14838.0000	15020.0000	15020.0000
2023-04-01	14968.5996	15022.7002	14627.9004	14666.0996	14666.0996
2023-05-01	14663.0000	15018.5996	14570.0000	14979.0000	14979.0000
2023-06-01	14984.0000	15084.0996	13636.5996	15064.0000	15064.0000
2023-07-01	15036.2002	15248.0996	13082.0000	15088.0000	15088.0000

2023-08-01	15104.0000	15389.0000	15084.5000	15216.0000	15216.0000
2023-09-01	15231.0000	15597.5000	15046.7998	15487.2002	15487.2002
2023-10-01	15487.2002	15972.7002	15068.0000	15843.0000	15843.0000
2023-11-01	15748.7002	15969.2998	15157.4004	15407.0000	15407.0000
2023-12-01	15549.2998	15679.0000	14416.5000	15383.0996	15383.0996
2024-01-01	15383.0996	15876.5000	14379.7998	15785.0000	15785.0000
2024-02-01	15769.0000	15793.2002	15278.5996	15712.2002	15712.2002
2024-03-01	15704.0000	15914.5000	14784.4004	15873.0996	15873.0996

3. Monthly Indonesian Oil Price Marker by Author

Date	Is Fuel Hike
2003-01-01	false
2003-02-01	false
2003-03-01	false
2003-04-01	false
2003-05-01	false
2003-06-01	false
2003-07-01	false
2003-08-01	false
2003-09-01	false
2003-10-01	false
2003-11-01	false
2003-12-01	false
2004-01-01	false
2004-02-01	false
2004-03-01	false
2004-04-01	false
2004-05-01	false
2004-06-01	false
2004-07-01	false
2004-08-01	false
2004-09-01	false
2004-10-01	false
2004-11-01	false
2004-12-01	false
2005-01-01	false
2005-02-01	false
2005-03-01	true

2005-04-01	false
2005-05-01	false
2005-06-01	false
2005-07-01	false
2005-08-01	false
2005-09-01	false
2005-10-01	true
2005-11-01	false
2005-12-01	false
2006-01-01	false
2006-02-01	false
2006-03-01	false
2006-04-01	false
2006-05-01	false
2006-06-01	false
2006-07-01	false
2006-08-01	false
2006-09-01	false
2006-10-01	false
2006-11-01	false
2006-12-01	false
2007-01-01	false
2007-02-01	false
2007-03-01	false
2007-04-01	false
2007-05-01	false
2007-06-01	false
2007-07-01	false
2007-08-01	false
2007-09-01	false
2007-10-01	false
2007-11-01	false
2007-12-01	false
2008-01-01	false
2008-02-01	false
2008-03-01	false
2008-04-01	false

2008-05-01	true
2008-06-01	false
2008-07-01	false
2008-08-01	false
2008-09-01	false
2008-10-01	false
2008-11-01	false
2008-12-01	false
2009-01-01	false
2009-02-01	false
2009-03-01	false
2009-04-01	false
2009-05-01	false
2009-06-01	false
2009-07-01	false
2009-08-01	false
2009-09-01	false
2009-10-01	false
2009-11-01	false
2009-12-01	false
2010-01-01	false
2010-02-01	false
2010-03-01	false
2010-04-01	false
2010-05-01	false
2010-06-01	false
2010-07-01	false
2010-08-01	false
2010-09-01	false
2010-10-01	false
2010-11-01	false
2010-12-01	false
2011-01-01	false
2011-02-01	false
2011-03-01	false
2011-04-01	false
2011-05-01	false

2011-06-01	false
2011-07-01	false
2011-08-01	false
2011-09-01	false
2011-10-01	false
2011-11-01	false
2011-12-01	false
2012-01-01	false
2012-02-01	false
2012-03-01	false
2012-04-01	false
2012-05-01	false
2012-06-01	false
2012-07-01	false
2012-08-01	false
2012-09-01	false
2012-10-01	false
2012-11-01	false
2012-12-01	false
2013-01-01	false
2013-02-01	false
2013-03-01	false
2013-04-01	false
2013-05-01	false
2013-06-01	true
2013-07-01	false
2013-08-01	false
2013-09-01	false
2013-10-01	false
2013-11-01	false
2013-12-01	false
2014-01-01	false
2014-02-01	false
2014-03-01	false
2014-04-01	false
2014-05-01	false
2014-06-01	false

2014-07-01	false
2014-08-01	false
2014-09-01	false
2014-10-01	false
2014-11-01	true
2014-12-01	false
2015-01-01	false
2015-02-01	false
2015-03-01	false
2015-04-01	false
2015-05-01	false
2015-06-01	false
2015-07-01	false
2015-08-01	false
2015-09-01	false
2015-10-01	false
2015-11-01	false
2015-12-01	false
2016-01-01	false
2016-02-01	false
2016-03-01	false
2016-04-01	false
2016-05-01	false
2016-06-01	false
2016-07-01	false
2016-08-01	false
2016-09-01	false
2016-10-01	false
2016-11-01	false
2016-12-01	false
2017-01-01	true
2017-02-01	false
2017-03-01	true
2017-04-01	false
2017-05-01	false
2017-06-01	false
2017-07-01	false

2017-08-01	false
2017-09-01	false
2017-10-01	false
2017-11-01	false
2017-12-01	false
2018-01-01	false
2018-02-01	false
2018-03-01	false
2018-04-01	false
2018-05-01	false
2018-06-01	false
2018-07-01	false
2018-08-01	false
2018-09-01	false
2018-10-01	false
2018-11-01	false
2018-12-01	false
2019-01-01	false
2019-02-01	false
2019-03-01	false
2019-04-01	false
2019-05-01	false
2019-06-01	false
2019-07-01	false
2019-08-01	false
2019-09-01	false
2019-10-01	false
2019-11-01	false
2019-12-01	false
2020-01-01	false
2020-02-01	false
2020-03-01	false
2020-04-01	false
2020-05-01	false
2020-06-01	false
2020-07-01	false
2020-08-01	false

2020-09-01	false
2020-10-01	false
2020-11-01	false
2020-12-01	false
2021-01-01	false
2021-02-01	false
2021-03-01	false
2021-04-01	false
2021-05-01	false
2021-06-01	false
2021-07-01	false
2021-08-01	false
2021-09-01	false
2021-10-01	false
2021-11-01	false
2021-12-01	false
2022-01-01	false
2022-02-01	false
2022-03-01	false
2022-04-01	false
2022-05-01	false
2022-06-01	false
2022-07-01	false
2022-08-01	false
2022-09-01	true
2022-10-01	false
2022-11-01	false
2022-12-01	false
2023-01-01	false
2023-02-01	false
2023-03-01	false
2023-04-01	false
2023-05-01	false
2023-06-01	false
2023-07-01	false
2023-08-01	false
2023-09-01	false

2023-10-01	false
2023-11-01	false
2023-12-01	false
2024-01-01	false
2024-02-01	false
2024-03-01	false