

**PREDIKSI KUNJUNGAN MUSEUM MPU PURWA DENGAN
PENDEKATAN *NEURAL BASIS EXPANSION ANALYSIS FOR
INTERPRETABLE TIME SERIES FORECASTING* (N-BEATS)**

SKRIPSI

Oleh:

FADHILLAH PUTRI TRIANA
NIM. 220605110093



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

**PREDIKSI KUNJUNGAN MUSEUM MPU PURWA DENGAN
PENDEKATAN *NEURAL BASIS EXPANSION ANALYSIS FOR
INTERPRETABLE TIME SERIES FORECASTING* (N-BEATS)**

SKRIPSI

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

Oleh :
FADHILLAH PUTRI TRIANA
NIM. 220605110093

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

HALAMAN PERSETUJUAN

PREDIKSI KUNJUNGAN MUSEUM MPU PURWA DENGAN PENDEKATAN *NEURAL BASIS EXPANSION ANALYSIS FOR INTERPRETABLE TIME SERIES FORECASTING (N-BEATS)*

SKRIPSI

Oleh :
FADHILLAH PUTRI TRIANA
NIM. 220605110093

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 10 April 2026

Pembimbing I,


Prof. Dr. Ir. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Pembimbing II,


Prof. Dr. Suhartono S.Si M.Kom
NIP. 19680519 200312 1 001

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

PREDIKSI KUNJUNGAN MUSEUM MPU PURWA DENGAN PENDEKATAN *NEURAL BASIS EXPANSION ANALYSIS FOR INTERPRETABLE TIME SERIES FORECASTING (N-BEATS)*

SKRIPSI

Oleh :
FADHILLAH PUTRI TRIANA
NIM. 220605110093

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 27 April 2026

Susunan Dewan Penguji

Ketua Penguji	: <u>Fatchurrohman, M.Kom</u> NIP. 19700731 200501 1 002	()
Anggota Penguji I	: <u>Hani Nurhayati, M.T</u> NIP. 19780625 200801 2 006	()
Anggota Penguji II	: <u>Prof. Dr. Ir. Muhammad Faisal, M.T</u> NIP. 19740510 200501 1 007	()
Anggota Penguji III	: <u>Prof. Dr. Suhartono S.Si M.Kom</u> NIP. 19680519 200312 1 001	()

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



Supriyanto, M. Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Fadhillah Putri Triana
NIM : 220605110093
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Kunjungan Museum Mpu Purwa Dengan Pendekatan *Neural Basis Expansion Analysis For Interpretable Time Series Forecasting* (N-Beats)

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

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

Malang, 27 April 2026
Yang membuat pernyataan,



Fadhillah Putri Triana
NIM. 220605110093

MOTTO

*“Sometimes the wrong train takes you to the right station”
-Indian Proverb*

HALAMAN PERSEMBAHAN

Alhamdulillah rabbil 'alamin, puji syukur ke hadirat Allah Subhanahu wa Ta'ala atas segala rahmat, karunia, dan kemudahan-Nya sehingga karya sederhana ini dapat terselesaikan dengan baik. Shalawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad SAW. Dengan penuh rasa syukur dan kerendahan hati, karya ini penulis persembahkan kepada:

Ayah dan Ibu tercinta, sebagai sumber doa, kasih sayang, dan dukungan yang tiada henti.

Faizan dan Syafiq, adik penulis yang selalu memberikan semangat dan kebahagiaan.

Diriku sendiri yang tetap memilih untuk bertahan dan terus melangkah.

KATA PENGANTAR

Puji syukur kehadiran Allah SWT atas segala rahmat, karunia, dan kemudahan yang senantiasa diberikan dalam setiap langkah perjalanan hidup penulis, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Prediksi Kunjungan Museum Mpu Purwa dengan Pendekatan Neural Basis Expansion Analysis for Interpretable Time Series Forecasting (N-BEATS)” dengan baik. Tanpa pertolongan-Nya, segala usaha dan ikhtiar tidak akan sampai pada tahap ini. Shalawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad SAW, yang telah menjadi teladan bagi seluruh umat. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika, UIN Maulana Malik Ibrahim Malang.

Dalam proses penyusunan skripsi ini, penulis mendapatkan banyak bantuan, dukungan, serta arahan dari berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP., selaku Rektor UIN Maulana Malik Ibrahim Malang, yang telah memimpin dan memberikan fasilitas serta lingkungan akademik yang mendukung proses pembelajaran.
2. Dr. Agus Mulyono, M.Kes., selaku Dekan Fakultas Sains dan Teknologi, yang telah memberikan dukungan dalam penyelenggaraan kegiatan akademik.

3. Supriyono, M.Kom., selaku Ketua Program Studi Teknik Informatika, yang telah memberikan arahan serta kebijakan yang mendukung kelancaran studi penulis.
4. Prof. Dr. Ir. Muhammad Faisal, M.T. dan Prof. Dr. Suhartono, S.Si., M.Kom., selaku dosen pembimbing, yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan, serta masukan selama proses penyusunan skripsi ini.
5. Hani Nurhayati, M.T. dan Fatchurrochman, M.Kom., selaku dosen penguji, yang telah memberikan saran, kritik, dan evaluasi yang membangun untuk penyempurnaan skripsi ini.
6. Dr. Ir. Fresy Nugroho, S.T., M.T., I.P.M., ASEAN Eng., selaku dosen wali, yang telah memberikan bimbingan dan arahan selama masa perkuliahan.
7. Nia Faricha, S.Si., yang telah membantu dan memberikan dukungan dalam proses penyusunan skripsi ini.
8. Seluruh dosen dan staf akademik Program Studi Teknik Informatika UIN Maulana Malik Ibrahim Malang, yang telah memberikan ilmu, pengalaman, serta pelayanan akademik selama masa studi penulis.
9. Dinas Pendidikan dan Kebudayaan Kota Malang, yang telah memberikan dukungan serta membantu dalam penyediaan data yang diperlukan dalam penelitian ini.
10. Kedua orang tua tercinta, Alfiah dan Triono Basuki yang senantiasa menjadi pendukung terbesar dalam hidup saya, menjadi alasan penulis tetap berdiri dan melangkah sampai hari ini. Terima kasih atas segala doa yang tidak

pernah terputus, kasih sayang yang tulus, serta pengorbanan yang tiada hentinya.

11. Kedua adik penulis, Achmad Syafiq Alfathoni dan Faizan Jazib Abqary, terimakasih telah mengisi tawa penulis dan menjadi semangat penulis setiap harinya.
12. Seluruh keluarga besar, yang telah memberikan doa dan dukungan selama proses penyusunan skripsi ini.
13. Seluruh teman – teman Angkatan 22 Infinity, terkhusus untuk Citra Ayu Putri Ningrum, Sivana Firdausy Khuriyyah, Laudza Atsila Prasetyo, Lailatul Ilmi Silviana, Azizatul Munawaroh, Putri Nabila, dan Rifda Anggraeni yang telah memberikan bantuan, dukungan, serta kebersamaan selama proses perkuliahan dan penyusunan skripsi.
14. Teman-teman kamar USA 28, yang telah memberikan semangat, dukungan, dan juga kenangan yang indah selama masa perkuliahan hingga penyusunan skripsi.

Penulis menyadari bahwa skripsi ini masih memiliki keterbatasan dalam penyusunan maupun pembahasan yang disajikan. Penulis terbuka terhadap kritik dan saran yang membangun sebagai bahan perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat serta menambah wawasan bagi pembaca.

Malang, 27 April 2026

Penulis

DAFTAR ISI

SKRIPSI	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN.....	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xiv
ABSTRAK	xv
ABSTRACT.....	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
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 Museum Mpu Purwa	11
2.3 Prediksi.....	12
2.4 <i>Time Series</i>	14
2.5 <i>Rolling Mean 7</i>	15
2.6 <i>Neural Basis Expansion Analysis for Interpretable Time Series</i>	16
2.7 <i>Root Mean Square Error (RMSE)</i>	20
2.8 <i>Mean Absolute Error (MAE)</i>	20
2.9 <i>Symmetric Mean Absolute Percentage Error (sMAPE)</i>	21
BAB III METODOLOGI PENELITIAN	23
3.1 Tahapan Penelitian	23
3.1.1 Pengumpulan Data	26
3.1.2 <i>Preprocessing</i>	27
3.1.2.1 <i>Data Cleaning</i>	28
3.1.2.2 Agregasi Harian	29
3.1.2.3 <i>Rolling Mean 7</i>	30
3.1.2.4 Transformasi dan Normalisasi Data	31
3.1.3 <i>Data Splitting</i>	33
3.1.4 Implementasi Metode N-Beats	34
3.1.5 Evaluasi Model.....	47
3.2 Skenario Pengujian.....	49
BAB IV HASIL DAN PEMBAHASAN	52
4.1 Hasil Preprocessing Data	52
4.1.1 <i>Data Cleaning</i>	52
4.1.2 Agregasi Harian.....	53
4.1.3 <i>Rolling Mean 7</i>	55

4.1.4 Transformasi dan Normalisasi Data	55
4.2 Hasil <i>Data Splitting</i>	56
4.3 Hasil Pengujian Model N-Beats	58
4.3.1 Hasil Pengujian Skenario 1	58
4.3.2 Hasil Pengujian Skenario 2	73
4.3.3 Hasil Pengujian Skenario 3	87
4.4 Pembahasan	104
4.5 Integrasi Islam	119
BAB V KESIMPULAN DAN SARAN	123
5.1 Kesimpulan	123
5.2 Saran	124
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 2. 1 Diagram Cara Kerja N-Beats	17
Gambar 3.1 Diagram Tahapan Penelitian	24
Gambar 3. 2 Diagram Preprocessing	27
Gambar 3. 3 Implementasi N-Beats	35
Gambar 4. 2 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 1.....	61
Gambar 4. 3 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 1.....	62
Gambar 4. 4 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 1.....	64
Gambar 4. 5 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 1.....	65
Gambar 4. 6 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 1.....	67
Gambar 4. 7 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 1.....	68
Gambar 4. 8 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 1.....	69
Gambar 4. 9 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 1.....	71
Gambar 4. 10 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 2.....	76
Gambar 4. 11 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 2.....	77
Gambar 4. 12 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 2.....	78
Gambar 4. 13 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 2.....	79
Gambar 4. 14 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 2.....	81
Gambar 4. 15 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 2.....	82
Gambar 4. 16 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 2....	83
Gambar 4. 17 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 2.....	85
Gambar 4. 18 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 3.....	90
Gambar 4. 19 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 3.....	91
Gambar 4. 20 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 3.....	93
Gambar 4. 21 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 3.....	95
Gambar 4. 22 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 3.....	97
Gambar 4. 23 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 3.....	98
Gambar 4. 24 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 3...	100
Gambar 4. 25 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 3...	102
Gambar 4. 26 Grafik Evaluasi RMSE.....	106
Gambar 4. 27 Grafik Evaluasi MAE.....	107
Gambar 4. 28 Grafik Evaluasi SMAPE	108
Gambar 4. 29 Hasil Prediksi Model Terbaik 1	113
Gambar 4. 30 Hasil Prediksi Model Terbaik 2	114
Gambar 4. 31 Hasil Prediksi Model Terbaik 3	116

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	7
Tabel 3.1 Fitur Dataset.....	26
Tabel 3. 2 Sampel Hasil Cleaning Data	28
Tabel 3. 3 Sampel Hasil Agregasi Harian.....	29
Tabel 3. 4 Sampel Finalisasi Dataset	31
Tabel 3. 5 Splitting Data	34
Tabel 3. 6 Sampel Dataset.....	37
Tabel 3. 7 Perhitungan Residual	41
Tabel 3. 8 Skenario Pengujian	50
Tabel 3. 9 Skenario Tuning Hyperparameter.....	50
Tabel 4. 1 Data Sebelum Agregasi.....	53
Tabel 4. 2 Data Setelah Agregasi.....	54
Tabel 4. 3 Data Setelah Transformasi dan Normalisasi.....	56
Tabel 4. 4 Hasil Data Splitting.....	57
Tabel 4. 5 Tabel Percobaan Skenario Pengujian 70:15:15	59
Tabel 4. 6 Hasil Evaluasi RMSE, MAE, dan SMAPE Skenario Pengujian 1	59
Tabel 4. 7 Tabel Percobaan Skenario Pengujian 80:10:10	74
Tabel 4. 8 Hasil Evaluasi RMSE, MAE, dan SMAPE Skenario Pengujian 2	74
Tabel 4. 9 Tabel Percobaan Skenario Pengujian 90:05:05	88
Tabel 4. 10 Hasil Evaluasi RMSE, MAE, SMAPE Skenario Pengujian 3	88
Tabel 4. 11 Hasil Evaluasi Keseluruhan Model.....	109
Tabel 4. 12 Ringkasan Hasil Tiga Model Terbaik	111
Tabel 4. 13 Hasil Evaluasi Menggunakan Data Terbaru	118

ABSTRAK

Triana, Fadhillah Putri. 2026. **Prediksi Kunjungan Museum Mpu Purwa Dengan Pendekatan *Neural Basis Expansion Analysis For Interpretable Time Series Forecasting* (N-Beats)**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Ir. Muhammad Faisal, M.T (II) Prof. Dr. Suhartono S.Si M.Kom

Kata kunci: N-BEATS, prediksi deret waktu, kunjungan museum, *deep learning*.

Penelitian ini bertujuan untuk memprediksi jumlah kunjungan harian pada Museum Mpu Purwa menggunakan model deep learning berbasis N-BEATS (*Neural Basis Expansion Analysis for Time Series*). Latar belakang penelitian ini didasarkan pada pentingnya peramalan jumlah pengunjung sebagai dasar pengambilan keputusan dalam pengelolaan museum, terutama dalam perencanaan operasional dan strategi peningkatan kunjungan. Metode yang digunakan adalah pendekatan *time series forecasting* dengan memanfaatkan data historis kunjungan harian. Penelitian ini menguji beberapa kombinasi *hyperparameter*, yaitu *lookback window* (14 dan 30), jumlah *block* (1 dan 2), serta *learning rate* (0.001 dan 0.0005). Selain itu, dilakukan tiga skenario pembagian data, yaitu 70:15:15, 80:10:10, dan 90:05:05 untuk data latih, validasi, dan uji. Evaluasi kinerja model dilakukan menggunakan tiga metrik, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Symmetric Mean Absolute Percentage Error* (SMAPE). Hasil penelitian menunjukkan bahwa performa model dipengaruhi oleh kombinasi *hyperparameter* dan proporsi data latih. Skenario pembagian data 90:05:05 menghasilkan performa terbaik dengan nilai error yang lebih rendah dibandingkan skenario lainnya. Penggunaan *lookback* 30 terbukti lebih efektif dalam menangkap pola data dibandingkan *lookback* 14. Dari seluruh percobaan, model terbaik diperoleh pada konfigurasi *lookback* 30, *block* 1, dan *learning rate* 0.001 dengan nilai MAE sebesar 5.15, RMSE sebesar 6.69, dan SMAPE sebesar 11.31% pada pengujian menggunakan data terbaru. Secara keseluruhan, model N-BEATS mampu mengikuti pola tren data kunjungan museum dengan cukup baik, meskipun masih terdapat keterbatasan dalam menangkap perubahan yang bersifat cepat atau fluktuasi ekstrem. Hasil penelitian ini diharapkan dapat menjadi referensi dalam penerapan metode deep learning untuk peramalan jumlah pengunjung serta mendukung pengambilan keputusan dalam pengelolaan museum.

ABSTRACT

Triana, Fadhillah Putri. 2026. **Predicting Visitor Numbers at the Mpu Purwa Museum Using the Neural Basis Expansion Analysis for Interpretable Time Series Forecasting (N-BEATS)**. Undergraduate Thesis. Department of Informatics Engineering Faculty of Science and Technology Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Prof. Dr. Ir. Muhammad Faisal, M.T. (II) Prof. Dr. Suhartono S.Si., M.Kom.

Keywords: N-BEATS, time series forecasting, museum visits, deep learning.

This study aims to predict daily visitor numbers at the Mpu Purwa Museum using an N-BEATS (Neural Basis Expansion Analysis for Time Series)-based deep learning model. The rationale for this study stems from the importance of forecasting visitor numbers as a basis for decision-making in museum management, particularly in operational planning and strategies to increase visitor numbers. The method used is a time series forecasting approach utilizing historical daily visitation data. This study tested several hyperparameter combinations, namely the lookback window (14 and 30), the number of blocks (1 and 2), and the learning rate (0.001 and 0.0005). Additionally, three data splitting scenarios were applied: 70:15:15, 80:10:10, and 90:05:05 for training, validation, and test data, respectively. Model performance was evaluated using three metrics: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Symmetric Mean Absolute Percentage Error (SMAPE). The results indicate that model performance is influenced by the combination of hyperparameters and the proportion of training data. The 90:05:05 data split scenario yielded the best performance with lower error values compared to the other scenarios. A lookback of 30 proved to be more effective at capturing data patterns than a lookback of 14. Across all experiments, the best model was obtained with a lookback of 30, a block size of 1, and a learning rate of 0.001, yielding an MAE of 5.15, an RMSE of 6.69, and an SMAPE of 11.31% in testing using the latest data. Overall, the N-BEATS model was able to follow the trends in museum visitation data quite well, although there are still limitations in capturing rapid changes or extreme fluctuations. The results of this study are expected to serve as a reference in the application of deep learning methods for visitor forecasting and to support decision-making in museum management.

مستخلص البحث

تريانا ، فَضِيْلَة بوترى. ٢٠٢٦. توقعات عدد زوار متحف مبو بوروا باستخدام نهج تحليل التوسع العصبي الأساسي للتنبؤ القابل (N-Beats) للتفسير بالسلاسل الزمنية. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: الأستاذ الدكتور المهندس محمد فيصل، ماجستير في الهندسة. المشرف الثاني: الأستاذ الدكتور سوهارتونو، بكالوريوس في العلوم، ماجستير في علوم الحاسوب

الكلمات الرئيسية: توقعات السلاسل الزمنية، زيارات المتحف، التعلم العميق، N-BEATS

يهدف هذا البحث إلى توقع عدد الزيارات اليومية لمتحف مبو بوروا باستخدام نموذج التعلم العميق القائم على (تحليل التوسع العصبي الأساسي للسلاسل الزمنية). ويستند خلفية هذا البحث إلى أهمية توقع عدد الزوار كأساس NBEATS لاتخاذ القرارات في إدارة المتحف، لا سيما في التخطيط التشغيلي واستراتيجيات زيادة عدد الزيارات. الطريقة المستخدمة هي نهج باستخدام البيانات التاريخية للزيارات اليومية. تختبر هذه الدراسة عدة (time series forecasting) التنبؤ بالسلاسل الزمنية. مجموعات من الملاحظات الفائقة، وهي نافذة الرجوع (14 و 30)، وعدد الكتل (1 و 2)، ومعدل التعلم (0.001 و 0.0005) بالإضافة إلى ذلك، تم تنفيذ ثلاثة سيناريوهات لتقسيم البيانات، وهي 70:15:15، و 80:10:10، و 90:05:05 لبيانات التدريب والخطأ المربع المتوسط، (MAE) والتحقق والاختبار. تم تقييم أداء النموذج باستخدام ثلاثة مقاييس، وهي الخطأ المطلق المتوسط أظهرت نتائج البحث أن أداء النموذج يتأثر بمزيج الملاحظات. (SMAPE) والخطأ المطلق المتوسط المتماثل، (RMSE) الجذري الفائقة ونسبة بيانات التدريب. أسفر سيناريو تقسيم البيانات 90:05:05 عن أفضل أداء مع قيمة خطأ أقل مقارنة بالسيناريوهات الأخرى. البالغة 30 يومًا فعاليته في التقاط أنماط البيانات مقارنةً بفترة الرجوع البالغة (lookback) أثبت استخدام فترة الرجوع 14 يومًا. ومن بين جميع التجارب، تم الحصول على أفضل نموذج عند استخدام إعدادات فترة الرجوع 30 يومًا، وكتلة واحدة، ومعدل 14 في الاختبار الذي استخدم SMAPE 11.31% و RMSE 6.69 و MAE 5.15 التعلم 0.001، حيث بلغت قيمة من تتبع أنماط اتجاهات بيانات زيارات المتحف بشكل جيد، على الرغم من N-BEATS أحدث البيانات. بشكل عام، تمكن نموذج من وجود بعض القيود في التقاط التغيرات السريعة أو التقلبات الشديدة. ومن المتوقع أن تشكل نتائج هذا البحث مرجعًا في تطبيق طرق التعلم العميق للتنبؤ بعدد الزوار ودعم عملية اتخاذ القرار في إدارة المتاحف.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Museum merupakan salah satu sarana penting dalam melestarikan warisan budaya, sejarah, dan pengetahuan masyarakat. Selain berfungsi sebagai tempat penyimpanan koleksi, museum juga berperan sebagai pusat pembelajaran, penelitian, serta aktivitas budaya (Ardiansyah et al., 2024). Keberadaan museum tidak hanya menjaga nilai historis suatu daerah, tetapi juga menjadi media edukasi bagi generasi muda dalam memahami identitas dan perkembangan peradaban. Salah satu museum yang memiliki peran penting dalam pelestarian budaya lokal adalah Museum Mpu Purwa di Kota Malang. Museum ini menyimpan berbagai peninggalan bersejarah dari masa Kerajaan Kanjuruhan dan Mpu Sindok yang memiliki nilai historis tinggi. Meskipun demikian, jumlah kunjungan ke Museum Mpu Purwa masih bersifat fluktuatif dan cenderung rendah. Kondisi ini dipengaruhi oleh berbagai faktor, seperti keterbatasan promosi digital, kurang optimalnya pemanfaatan media sosial, fasilitas yang belum maksimal, serta rendahnya minat generasi muda terhadap wisata edukatif (Sepira et al., 2024).

Fluktuasi jumlah pengunjung yang terjadi dari waktu ke waktu menunjukkan adanya pola dinamis yang dipengaruhi oleh berbagai faktor, seperti musim liburan, program promosi, serta tren wisata masyarakat. Oleh karena itu, diperlukan suatu pendekatan berbasis data yang mampu membantu pengelola museum dalam memahami pola kunjungan serta memproyeksikan jumlah

pengunjung di masa mendatang. Prediksi jumlah kunjungan dapat menjadi dasar dalam perencanaan strategis, seperti penyusunan program promosi, pengelolaan fasilitas, serta peningkatan kualitas layanan.

Beberapa penelitian terdahulu telah mengkaji prediksi jumlah kunjungan museum menggunakan pendekatan statistik dan logika fuzzy. Penelitian oleh Alfajriani et al.(2020) menggunakan metode Fuzzy Time Series Chen dan Hsu untuk memprediksi jumlah kunjungan di Museum Mulawarman. Hasil penelitian tersebut menunjukkan nilai MAPE sebesar 6% untuk pengunjung domestik dan 10% untuk mancanegara, yang menandakan tingkat akurasi yang cukup baik. Hasil ini menunjukkan bahwa data historis kunjungan museum dapat dimanfaatkan untuk memproyeksikan tren di masa depan.

Meskipun metode statistik dan fuzzy memberikan hasil yang cukup baik, karakteristik data kunjungan museum yang cenderung fluktuatif dan dipengaruhi oleh berbagai faktor eksternal memerlukan pendekatan yang mampu mempelajari pola nonlinier serta dinamika jangka pendek dan jangka panjang secara lebih mendalam. Dalam konteks ini, pendekatan berbasis deep learning dapat dipertimbangkan sebagai salah satu alternatif untuk mendukung proses prediksi pada data deret waktu yang kompleks.

Salah satu model deep learning yang dirancang khusus untuk peramalan deret waktu (time series forecasting) adalah Neural Basis Expansion Analysis for Interpretable Time Series Forecasting (N-BEATS) yang dikembangkan oleh Oreshkin et al.(2019). Model ini menggunakan arsitektur fully connected layers dengan mekanisme residual forward-backward, sehingga mampu menangkap pola

kompleks dalam data tanpa memerlukan rekayasa fitur manual. Keunggulan utama N-BEATS terletak pada kemampuannya dalam mengidentifikasi pola jangka pendek dan jangka panjang secara bersamaan, serta memberikan interpretabilitas hasil yang baik.

Studi oleh Zein et al.(2024) menunjukkan bahwa penerapan N-BEATS dalam prediksi harga saham di Indonesia menghasilkan nilai MAPE sebesar 1,05%, yang lebih unggul dibandingkan model Long Short-Term Memory (LSTM). Berdasarkan temuan tersebut, penerapan N-BEATS pada prediksi jumlah kunjungan Museum Mpu Purwa diharapkan mampu menghasilkan model dengan tingkat akurasi dan stabilitas yang lebih baik dalam menghadapi dinamika data historis.

Pendekatan ilmiah dalam penelitian ini tidak hanya fokus pada aspek teknis, tetapi juga dikaitkan dengan perspektif Islam yang menjelaskan keteraturan dan pola perubahan waktu. Allah Subhanahu Wa Ta'ala berfirman:

إِنَّ فِي خَلْقِ السَّمُوتِ وَالْأَرْضِ وَاجْتِلاَفِ اللَّيْلِ وَالنَّهَارِ لَآيَاتٍ لِأُولَى الْأَلْبَابِ ﴿١٩٠﴾

“Sesungguhnya dalam penciptaan langit dan bumi dan silih bergantinya malam dan siang terdapat tanda-tanda (kebesaran Allah) bagi orang-orang yang berakal.” (QS. Ali Imran: 190)

Menurut tafsir Ibnu Katsir, ayat tersebut menjelaskan bahwa keteraturan dan perubahan yang terjadi di alam semesta merupakan tanda kebesaran Allah bagi orang-orang yang menggunakan akalanya. Pergantian siang dan malam yang berlangsung secara teratur mencerminkan adanya pola waktu yang dapat diamati dan dipelajari. Konsep ini selaras dengan analisis deret waktu dalam ilmu

pengetahuan modern, di mana perubahan data dari waktu ke waktu dianalisis untuk memahami pola dan kecenderungan tertentu.

Dalam konteks penelitian ini, data kunjungan museum yang berubah secara periodik mencerminkan dinamika sosial dan budaya masyarakat yang dapat dianalisis secara ilmiah. Penerapan model N-BEATS dalam mempelajari pola tersebut merupakan bentuk tadabbur ilmiah yang menggabungkan observasi, akal, dan teknologi dalam memahami keteraturan yang diciptakan oleh Allah melalui fenomena kehidupan. Melalui penerapan model N-BEATS, penelitian ini bertujuan mengembangkan sistem prediksi jumlah kunjungan Museum Mpu Purwa yang lebih akurat, adaptif, dan interpretatif terhadap dinamika data historis. Hasil prediksi diharapkan dapat mendukung pengambilan keputusan strategis dalam pengelolaan museum, sekaligus memperkaya literatur ilmiah mengenai penerapan deep learning pada bidang sosial dan kebudayaan. Dengan demikian, penelitian ini tidak hanya berkontribusi secara akademik dan praktis, tetapi juga menjadi refleksi integrasi antara ilmu pengetahuan dan nilai keislaman dalam mendukung pelestarian warisan budaya.

1.2 Rumusan Masalah

Bagaimana tingkat akurasi model prediksi kunjungan Museum MPU Purwa menggunakan metode Neural Basis Expansion Analysis for Interpretable Time Series Forecasting (N-BEATS)?

1.3 Batasan Masalah

Penelitian ini memiliki beberapa batasan agar lebih terarah, yaitu sebagai berikut:

1. Objek penelitian difokuskan pada Museum Mpu Purwa Kota Malang sebagai studi kasus, sehingga hasil penelitian tidak digeneralisasikan untuk museum lain.
2. Data yang digunakan dalam penelitian ini terbatas pada informasi waktu kunjungan dan jumlah pengunjung yang tercatat selama periode 17 Juni 2022 hingga 20 Juli 2025. Data non-kuantitatif, seperti identitas, kesan, kritik, dan saran pengunjung, tidak disertakan dalam proses prediksi.
3. Pada tahap preprocessing, data jumlah pengunjung dilakukan transformasi menggunakan metode rolling mean 7 untuk mengurangi fluktuasi harian dan noise pada data, sehingga pola tren kunjungan menjadi lebih stabil sebelum dilakukan pemodelan.
4. Metode penelitian dibatasi pada penggunaan model *Neural Basis Expansion Analysis for Interpretable Time Series Forecasting* (N-BEATS) sebagai algoritma utama untuk melakukan prediksi jumlah kunjungan.
5. Evaluasi performa model dilakukan menggunakan *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Symmetric Mean Absolute Percentage Error* (sMAPE), sebagai ukuran akurasi hasil prediksi.
6. Penelitian ini hanya sampai pada tahap eksperimen pemodelan prediksi berbasis data dan tidak mengembangkan sistem aplikasi penuh yang terintegrasi dengan pengelolaan museum.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk membangun dan mengevaluasi model prediksi tren kunjungan Museum Mpu Purwa Malang menggunakan metode *Neural Basis Expansion Analysis for Interpretable Time Series Forecasting* (N-BEATS).

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan banyak manfaat yang berguna, di antaranya yaitu:

1. Memberikan kontribusi akademis dalam pengembangan kajian prediksi deret waktu dengan menggunakan metode N-BEATS, dengan pendekatan rolling mean sebagai teknik preprocessing sehingga dapat menjadi referensi ilmiah dalam bidang Teknik Informatika khususnya pada penerapan deep learning.
2. Membantu pengelola Museum Mpu Purwa dalam memperkirakan jumlah kunjungan, sehingga dapat digunakan sebagai dasar perencanaan strategi promosi, pengelolaan fasilitas, serta manajemen sumber daya yang lebih efektif.
3. Menjadi acuan bagi penelitian selanjutnya yang ingin menerapkan atau mengembangkan metode prediksi berbasis deep learning, khususnya dalam bidang pariwisata, kebudayaan, maupun sektor lain yang memerlukan prediksi jumlah kunjungan atau permintaan.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian mengenai prediksi jumlah pengunjung maupun prediksi berbasis *time series* telah banyak dilakukan dengan beragam metode, baik yang bersifat tradisional maupun modern. Beberapa penelitian sebelumnya menunjukkan adanya variasi tingkat akurasi tergantung pada algoritma yang digunakan serta karakteristik data yang dianalisis. Misalnya, terdapat penelitian yang menggunakan pendekatan *machine learning* seperti *Support Vector Machine* (SVM), metode statistik seperti regresi linier, hingga pendekatan berbasis *fuzzy logic*. Selain itu, perkembangan teknologi *deep learning* telah mendorong munculnya arsitektur baru, seperti N-BEATS, yang menawarkan performa lebih baik dalam prediksi deret waktu dibandingkan metode konvensional. Penelitian-penelitian tersebut memberikan gambaran mengenai kelebihan dan keterbatasan masing-masing metode serta menjadi acuan penting dalam menentukan pendekatan yang sesuai untuk prediksi jumlah kunjungan museum.

Tabel 2.1 Penelitian Terdahulu

No	Nama Peneliti	Judul Penelitian	Keunggulan Penelitian (SOTA)	Gap Penelitian
1	Fikri Abdul Najib & Nur Nafi'iyah (2020)	Algoritma SVM untuk Memprediksi Pengunjung Wisata Museum di Jakarta	- Mengimplementasikan Support Vector Machine (SVM) sebagai pendekatan <i>machine learning</i> untuk prediksi jumlah	- Akurasi belum mengakomodasi model berbasis deep learning yang mampu menangkap pola non-linear dan hubungan

			pengunjung museum. - Memanfaatkan data multivariabel (destinasi, bulan, jenis pengunjung, dan jumlah pengunjung) dalam konteks pariwisata berbasis data mining.	temporal jangka panjang. - Penelitian masih terbatas pada pendekatan klasifikasi, bukan <i>time series forecasting</i> yang memprediksi data berurutan.
2	Alfajriani, Masna Wati & Novianti Puspitasari (2020)	Penerapan Metode Fuzzy Time Series Chen dan Hsu dalam Memprediksi Kunjungan Wisatawan di Museum Mulawarman	- Menggunakan metode Fuzzy Time Series Chen & Hsu untuk memprediksi kunjungan wisatawan museum dengan akurasi MAPE < 10%. - Mampu mengidentifikasi pola linguistik dan tren musiman pada data historis kunjungan.	- Belum memanfaatkan model pembelajaran mendalam (deep learning) untuk mempelajari pola temporal non-linear. - Pendekatan linguistik tidak cukup adaptif terhadap perubahan ekstrem atau pola fluktuatif jangka panjang.
3	Yoga Handoko, Eri Satria & Fadia Siti Nursifa (2025)	Prediksi Jumlah Pengunjung Pariwisata di Kabupaten Garut Menggunakan Algoritma Regresi Linear	- Menerapkan algoritma regresi linear untuk menganalisis hubungan antara faktor-faktor pariwisata dengan jumlah pengunjung. - Hasil model menunjukkan tingkat determinasi tinggi ($R^2 = 0,9346$), menandakan kemampuan yang baik dalam	- Terbatas pada hubungan linier dan belum mengakomodasi pola non-linear atau dinamis pada data waktu. - Belum menggunakan pendekatan deep learning time series untuk prediksi jangka panjang yang adaptif.

			menjelaskan variasi data.	
4	Xu et al. (2024)	Forecasting Visitor Arrivals at Tourist Attractions: A Time Series Framework with the N-BEATS for Sustainable Tourism	- Mengusulkan kerangka prediksi berbasis N-BEATS untuk pariwisata berkelanjutan dengan hasil akurasi tinggi dibandingkan metode klasik (SVR, LSTM, ARIMA, SARIMA).	- Belum diterapkan pada jenis wisata budaya atau edukatif, seperti museum. - Belum meneliti penerapan N-BEATS pada dataset berskala kecil dan konteks lokal seperti Indonesia.
5	Naik et al. (2024)	Stock Price Forecasting using N-Beats Deep Learning Architecture	- Membuktikan keunggulan N-BEATS dibandingkan CNN, LSTM, dan GRU pada data deret waktu finansial (S&P 500). - Menunjukkan hasil evaluasi terbaik berdasarkan RMSE, MAE, dan MAPE serta divalidasi dengan <i>Diebold–Mariano test</i>.	- Aplikasi model masih terbatas pada domain keuangan, belum diterapkan pada bidang pariwisata atau sosial budaya. - Belum mengeksplorasi pola temporal yang dipengaruhi perilaku manusia seperti pola kunjungan wisata.
Usulan Penelitian				
6	Prediksi Kunjungan Museum Mpu Purwa Dengan Pendekatan Neural Basis Expansion Analysis For Interpretable Time Series Forecasting (N-Beats)	-	Memprediksi jumlah kunjungan museum berdasarkan data historis dengan menggunakan algoritma N-BEATS.	

Penelitian mengenai prediksi kunjungan wisata, khususnya pada objek museum, telah dilakukan dengan berbagai pendekatan metode. Nafi'iyah (2020) menggunakan algoritma *Support Vector Machine* (SVM) untuk memprediksi jumlah kunjungan museum di Jakarta. Data yang digunakan bersumber dari portal *data.jakarta.go.id* dengan variabel destinasi, bulan, jenis pengunjung, dan jumlah kunjungan. Namun, hasil penelitian menunjukkan bahwa SVM menghasilkan prediksi yang kurang baik karena tingkat error yang tinggi, sehingga kurang optimal dalam menangkap pola fluktuasi kunjungan wisatawan.

Penelitian lain oleh Xu et al. (2024) mengusulkan kerangka kerja prediksi berbasis *Neural Basis Expansion Analysis for Time Series* (N-BEATS) untuk memprediksi kedatangan wisatawan pasca pandemi COVID-19. Dengan dataset kunjungan harian di Jiuzhaigou dan Mount Siguniang, model N-BEATS terbukti lebih unggul dibandingkan baseline model seperti SVR, LSTM, ARIMA, dan SARIMA, dengan rata-rata MAPE 39,60% yang lebih rendah, menunjukkan kemampuan algoritma ini dalam menangkap pola musiman maupun perubahan mendadak pada data kunjungan.

Selain itu, Alfajriani et al. (2020) menerapkan metode *Fuzzy Time Series Chen dan Hsu* untuk memprediksi jumlah kunjungan di Museum Mulawarman. Metode ini memiliki keunggulan dalam menangani data linguistik dan pola *time series* dengan hasil akurasi baik, ditunjukkan oleh nilai MAPE sebesar 6% untuk wisatawan domestik dan 10% untuk wisatawan mancanegara. Penelitian yang dilakukan oleh Agustin et al. (2025) menggunakan regresi linier untuk memprediksi

jumlah pengunjung pariwisata di Kabupaten Garut. Hasilnya menunjukkan model memiliki nilai R^2 sebesar 93,46%, yang berarti mampu menjelaskan variasi data dengan baik meskipun masih terdapat keterbatasan pada nilai MAPE akibat ketidakseimbangan data aktual. Di sisi lain, Naik et al. (2024) mengimplementasikan arsitektur *N-BEATS* pada ranah keuangan untuk prediksi harga saham S&P 500. Studi tersebut menunjukkan bahwa N-BEATS secara konsisten mengungguli model CNN, LSTM, dan GRU berdasarkan metrik evaluasi RMSE, MAE, dan MAPE, serta divalidasi dengan uji Diebold–Mariano, yang menegaskan keandalan N-BEATS dalam menangani data deret waktu kompleks.

2.2 Museum Mpu Purwa

Museum Museum Mpu Purwa merupakan museum yang berfokus pada koleksi benda-benda purbakala, khususnya artefak dari pulau Jawa. Museum ini didirikan pada tahun 2004 dan diresmikan oleh Wali Kota Malang, Drs. Peni Suparto. Awalnya, museum ini bernama Balai Penyelamatan Benda Purbakala Mpu Purwa dan dulunya menempati gedung bekas sekolah (SDN Mojolangu 2) sebagai tempat penyimpanan benda sejarah sebelum kemudian diresmikan sebagai museum. Secara administratif, Museum Mpu Purwa berada di bawah kepemilikan Pemerintah Kota Malang dan dikelola melalui Unit Pelaksana Teknis (UPT) yang berada di bawah Dinas Pendidikan dan Kebudayaan Kota Malang. Museum ini termasuk dalam kategori “Museum Khusus” dengan tipe C. Dalam hal koleksi, Museum Mpu Purwa menyimpan sejumlah artefak warisan kerajaan-kerajaan di Jawa dari masa Mpu Sindok hingga Majapahit, antara lain patung, arca, prasasti, lingga, makara, dan artefak purbakala lainnya. Luas area pameran adalah sekitar 1.200

m², dan koleksinya berjumlah lebih dari seratus artefak yang berasal dari kerajaan-kerajaan seperti Kanjuruhan, Mataram Kuna, Kediri, Singosari, dan Majapahit (Rusmiyati et al., 2018).

Dari sisi fasilitas dan layanan pengunjung, Museum Mpu Purwa dibuka dengan jam operasional reguler dan tidak memungut biaya tiket masuk, sehingga dapat diakses oleh siapa pun. Museum ini memiliki dua lantai pameran: lantai pertama menampilkan berbagai koleksi arca, termasuk arca tertua dan arca unik seperti Ganesya Tikus, serta dilengkapi ruang audio visual; sedangkan lantai kedua lebih berfokus pada tema-tema sejarah lokal, seperti kisah Ken Arok. Fasilitas pendukung lain yang tersedia meliputi perpustakaan untuk kebutuhan studi arsip, toilet, gazebo, pencahayaan, serta pendingin udara (AC) guna menunjang kenyamanan pengunjung (Dinas Pendidikan dan Kebudayaan Kota Malang, 2025).

Proses kunjungan ke museum dilakukan dengan memindai kode batang (barcode) yang terhubung ke formulir digital (Google Form) sebagai sarana pendaftaran. Data pengunjung yang terekam melalui sistem ini menjadi sumber informasi penting yang dapat dimanfaatkan dalam analisis prediksi jumlah kunjungan. Dengan demikian, aspek sejarah, koleksi, operasional, serta data registrasi digital Museum Mpu Purwa dapat dijadikan basis utama dalam pemodelan prediksi kunjungan museum.

2.3 Prediksi

Prediksi merupakan suatu proses memperkirakan kejadian atau nilai di masa mendatang dengan memanfaatkan informasi dari data historis maupun variabel terkait di masa lalu. Menurut penelitian Petropoulos et al. (2022), konsep ini

berlandaskan pada asumsi bahwa pola tertentu yang terjadi pada data historis dapat berulang sehingga memungkinkan dibuatnya prediksi mengenai masa depan. Dalam praktiknya, prediksi dapat menghasilkan berbagai bentuk keluaran, mulai dari nilai tunggal (*point forecast*), interval prediksi (*prediction interval*), hingga distribusi probabilistik penuh yang menggambarkan ketidakpastian.

Lebih lanjut, penelitian tersebut menegaskan bahwa terdapat berbagai pendekatan dalam forecasting, antara lain model statistik klasik seperti *exponential smoothing*, regresi deret waktu, dan ARIMA, maupun model modern berbasis *machine learning* dan *deep learning* seperti *neural networks* serta *probabilistic forecasting models*. Pemilihan metode sangat bergantung pada karakteristik data, tujuan prediksi, serta ketersediaan variabel pendukung. Selain itu, menurut Petropoulos et al. (2022) perkembangan ilmu *forecasting* juga mencakup metode Bayesian, kombinasi model, hingga pendekatan berbasis data besar (*big data*) yang memungkinkan integrasi multi-sumber informasi.

Evaluasi hasil prediksi juga menjadi bagian penting dalam memastikan kualitas prediksi. Menurut studi yang sama, ukuran akurasi seperti MAE (*Mean Absolute Error*), RMSE (*Root Mean Square Error*), maupun uji probabilistik digunakan untuk menilai keandalan model. Lebih jauh lagi, forecasting tidak hanya bersifat teknis, tetapi juga dipengaruhi oleh faktor manusia dan organisasi, sehingga sering kali terdapat intervensi *judgmental* dalam prosesnya. Oleh karena itu, praktik modern menekankan pentingnya analisis *Forecast Value Added (FVA)* guna memastikan bahwa setiap langkah dalam proses prediksi benar-benar meningkatkan kualitas hasil.

Dengan demikian, menurut Petropoulos et al. (2022) prediksi menjadi instrumen penting dalam pengambilan keputusan di berbagai bidang, mulai dari ekonomi, energi, lingkungan, kesehatan, hingga manajemen organisasi, karena membantu meminimalisir ketidakpastian dan meningkatkan efektivitas strategi yang direncanakan.

2.4 Time Series

Time Series atau deret waktu merupakan sekumpulan data yang direkam secara berurutan berdasarkan waktu, di mana setiap observasi merepresentasikan nilai suatu variabel pada titik waktu tertentu. Secara formal, deret waktu dapat dianggap sebagai sebuah himpunan variabel acak yang diindeks oleh waktu, misalnya $x_1, x_2, x_3, \dots, x_t$, yang disebut sebagai realisasi dari suatu proses stokastik (Shumway & Stoffer, 2011). Analisis deret waktu bertujuan untuk memahami struktur ketergantungan antar observasi dalam suatu rentang waktu, baik dalam bentuk tren, musiman, maupun fluktuasi acak, sehingga memungkinkan dilakukan prediksi untuk periode mendatang. Salah satu konsep penting dalam analisis deret waktu adalah stasioneritas, yaitu kondisi ketika sifat statistik data (seperti mean dan varians) tidak berubah sepanjang waktu. Deret waktu yang stasioner lebih mudah dianalisis karena pola keteraturan antar data relatif konsisten.

Dalam perkembangannya, deret waktu banyak digunakan pada berbagai bidang seperti ekonomi, kesehatan, meteorologi, hingga rekayasa. Metode tradisional seperti AR, MA, ARIMA, dan *exponential smoothing* telah lama menjadi pendekatan utama untuk analisis dan prediksi deret waktu. Namun, dengan semakin besarnya volume data dan kompleksitas pola temporal, metode berbasis

pembelajaran mesin (khususnya deep learning) mulai banyak digunakan. Deep learning mampu mempelajari representasi kompleks dari data deret waktu tanpa harus bergantung penuh pada rekayasa fitur manual, sehingga lebih efektif dalam menangkap dinamika non-linear maupun hubungan jangka panjang antar variabel (Lim & Zohren, 2021). Salah satu arsitektur *deep learning* yang dikembangkan khusus untuk analisis deret waktu adalah N-BEATS. Model ini dirancang untuk mempelajari pola tren maupun musiman secara fleksibel, sehingga dapat menjadi alternatif dari metode konvensional.

2.5 Rolling Mean 7

Rolling mean merupakan salah satu teknik smoothing pada data deret waktu yang digunakan untuk mengurangi fluktuasi acak dan noise sehingga pola tren yang mendasari data menjadi lebih jelas. Pada data kunjungan museum yang bersifat runtun waktu, sering muncul variasi jangka pendek akibat faktor harian, peristiwa khusus, atau ketidakteraturan pencatatan. Kondisi tersebut dapat mempersulit model peramalan dalam menangkap pola utama. Oleh karena itu, proses perataan data diperlukan sebagai bagian dari tahap *preprocessing* sebelum pemodelan dilakukan.

Metode rolling mean bekerja dengan menghitung nilai rata-rata dari sejumlah observasi dalam suatu jendela (window) yang bergerak sepanjang deret waktu. Setiap nilai hasil smoothing diperoleh dari rata-rata beberapa titik data terakhir sesuai ukuran window yang ditetapkan. Dalam penelitian ini digunakan rolling mean dengan window 7, yang berarti setiap nilai baru merupakan hasil rata-rata dari tujuh pengamatan berurutan. Pendekatan ini umum digunakan pada data

berbasis periode harian atau mingguan karena mampu mereduksi variasi jangka pendek sekaligus mempertahankan kecenderungan tren.

Penggunaan teknik smoothing seperti moving average atau rolling mean telah banyak direkomendasikan dalam literatur peramalan deret waktu karena dapat meningkatkan stabilitas sinyal data dan membantu model pembelajaran mesin maupun deep learning dalam mempelajari pola yang lebih representatif dari data asli. Proses ini menghasilkan versi data yang lebih halus (smoothed series), sehingga struktur tren dan pola musiman menjadi lebih mudah dikenali oleh model peramalan (Zbezhkhovska & Chumachenko, 2025).

Secara matematis, rolling mean dengan ukuran jendela 7 pada waktu ke- t dinyatakan dengan rumus:

$$RM_t = \frac{1}{7} \sum_{i=0}^6 y_{t-i} \quad (2.1)$$


RM_t menyatakan nilai data asli pada periode ke- t hingga enam periode sebelumnya. Melalui transformasi ini, data kunjungan yang semula berfluktuasi menjadi lebih halus, sehingga lebih sesuai digunakan sebagai masukan pada model peramalan deret waktu seperti N-BEATS.

2.6 Neural Basis Expansion Analysis for Interpretable Time Series

N-BEATS merupakan salah satu arsitektur *deep learning* yang dirancang khusus untuk melakukan peramalan deret waktu. Model ini dikembangkan oleh Oreshkin et al. (2019) dan berhasil mencapai performa *state-of-the-art* pada kompetisi M3, M4, dan Tourism dataset. Keunggulan utama N-BEATS terletak pada sifatnya yang generik, karena tidak memerlukan rekayasa fitur khusus deret waktu ataupun pengetahuan domain tertentu, sehingga dapat digunakan secara luas

pada berbagai jenis data. Selain itu, arsitektur ini juga dapat diperluas menjadi bentuk yang interpretable dengan memisahkan komponen tren dan musiman pada hasil prediksi.

Secara umum, N-BEATS dibangun dari blok dasar (*basic block*) yang memanfaatkan jaringan saraf *fully connected* berlapis dengan aktivasi ReLU. Setiap blok menerima masukan berupa jendela historis (*lookback window*) dari data deret waktu, kemudian menghasilkan dua keluaran utama, yaitu backcast ($\hat{x}$) sebagai estimasi ulang terhadap input, dan forecast ($\hat{y}$) sebagai prediksi ke depan sepanjang horizon tertentu. Struktur hubungan antar blok, stack, serta proses agregasi hingga membentuk ramalan global dapat dilihat pada Gambar berikut.



Gambar 2. 1 Diagram Cara Kerja N-Beats (Oreshkin et al., 2019)

Proses komputasi dalam sebuah blok dapat diformulasikan dengan beberapa tahapan matematis. Pertama, input $x_{l,1}$ dari blok ke- l dilewatkan ke dalam empat lapisan *fully connected* berurutan dengan fungsi aktivasi ReLU, sehingga

menghasilkan representasi laten $h_{l,1}, h_{l,2}, h_{l,3}, h_{l,4}$. Persamaan ini dapat ditulis sebagai berikut:

$$h_{l,1} = FC_{l,1}(x_l) \quad (2.2)$$

$$h_{l,2} = FC_{l,2}(h_{l,1}) \quad (2.3)$$

$$h_{l,3} = FC_{l,3}(h_{l,2}) \quad (2.4)$$

$$h_{l,4} = FC_{l,4}(h_{l,3}) \quad (2.5)$$

Keterangan:

x_l = input pada blok ke- l (data historis dari deret waktu).

$FC_{l,i}$ = lapisan *fully connected* ke- i pada blok ke- l .

$h_{l,i}$ = representasi laten yang dihasilkan pada lapisan ke- i blok ke- l .

Tahap berikutnya adalah pembentukan dua jenis koefisien ekspansi, yaitu θ_l^b dan θ_l^f . Koefisien θ_l^b dihasilkan melalui proyeksi linear $W_l^b h_{l,4}$ dan digunakan untuk merekonstruksi input atau *backcast*. Sementara itu, θ_l^f diperoleh dari $W_l^f h_{l,4}$ dan berfungsi untuk menghasilkan prediksi ke depan atau *forecast*.

Selanjutnya, kedua koefisien tersebut dipetakan ke dalam ruang basis fungsi. Koefisien θ_l^f digunakan oleh fungsi basis g^f untuk membentuk prediksi parsial $\hat{y}_l$, sedangkan θ_l^b digunakan oleh fungsi basis g^b untuk menghasilkan estimasi input $\hat{x}_l$. Dengan demikian, blok ke- l menghasilkan dua keluaran, yaitu:

$$\hat{y}_l = g^f(\theta_l^f) \quad (2.6)$$

$$\hat{x}_l = g^b(\theta_l^b) \quad (2.7)$$

Keterangan:

g^f = fungsi basis untuk menghasilkan *forecast*.

g^b = fungsi basis untuk menghasilkan *backcast*.

θ_l^b = koefisien ekspansi backcast pada blok ke- l .

θ_l^f = koefisien ekspansi forecast pada blok ke- l .

$\hat{y}_l$ = hasil prediksi (forecast) parsial dari blok ke- l .

$\hat{x}_l$ = hasil rekonstruksi (backcast) dari input pada blok ke- l .

Interpretasi dari keseluruhan rumus ini adalah bahwa bagian *forecast* berfungsi khusus untuk memprediksi nilai masa depan dengan cara mengombinasikan basis fungsi sesuai bobot koefisien yang dipelajari, sedangkan bagian *backcast* berperan menghapus atau mengurangi komponen yang sudah terjelaskan dari input (Oreshkin et al., 2019b). Dengan cara ini, blok berikutnya menerima input yang lebih “bersih” sehingga dapat fokus pada pola sisa yang belum ditangkap oleh blok sebelumnya.

Pada saat proses *training*, model N-BEATS dilatih menggunakan *loss function Mean Absolute Error* (MAE) untuk mengukur seberapa besar rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Fungsi kerugian ini dipilih karena bersifat sederhana, stabil, serta tidak terlalu sensitif terhadap nilai ekstrem (*outlier*). Untuk proses optimasinya, model menggunakan *optimizer Adam* (*Adaptive Moment Estimation*), yang mampu menyesuaikan *learning rate* secara adaptif pada setiap parameter sehingga proses pelatihan menjadi lebih cepat dan konvergen (Naik et al., 2024).

Selama pelatihan berlangsung, dilakukan proses *backpropagation*, yaitu mekanisme pembaruan bobot jaringan berdasarkan hasil perhitungan kesalahan (Motavali et al., 2023). Melalui proses ini, model secara bertahap menyesuaikan parameter-parameter pada jaringan *fully connected* agar hasil prediksi semakin mendekati nilai aktual pada data deret waktu.

2.7 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan bentuk turunan dari MSE yang diperoleh dengan mengakarkan nilai MSE. RMSE memberikan ukuran kesalahan model dalam satuan yang sama dengan data aslinya, sehingga lebih mudah diinterpretasikan secara praktis dibandingkan MSE. Hodson (2022) menjelaskan bahwa RMSE secara teoritis merupakan metrik optimal ketika distribusi kesalahan bersifat normal (Gaussian), karena minimisasi MSE atau RMSE *ekuivalen* dengan memaksimalkan *likelihood* model dalam konteks kesalahan yang berdistribusi normal (Hodson, 2022).

Secara matematis, RMSE dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.8)$$

Nilai RMSE yang lebih kecil menunjukkan model memiliki akurasi prediksi yang lebih tinggi. Dalam penelitian prediksi jumlah kunjungan museum menggunakan pendekatan N-BEATS, RMSE berperan penting sebagai indikator performa model untuk mengukur seberapa dekat hasil prediksi terhadap nilai aktual kunjungan. Karena RMSE menekankan kesalahan besar, metrik ini relevan digunakan pada konteks data prediksi deret waktu, di mana kesalahan besar pada titik tertentu dapat berdampak signifikan terhadap interpretasi hasil peramalan secara keseluruhan.

2.8 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan salah satu metrik evaluasi yang banyak digunakan dalam menilai kinerja model peramalan maupun prediksi. MAE

didefinisikan sebagai rata-rata dari nilai absolut selisih antara data aktual dengan data hasil prediksi. Secara matematis, MAE dapat dirumuskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (2.9)$$

dengan Y_t menyatakan nilai aktual, $\hat{Y}_t$ adalah nilai prediksi, dan n jumlah data pengamatan. Kelebihan utama MAE adalah sifatnya yang mudah diinterpretasikan karena hasilnya memiliki satuan yang sama dengan data asli, sehingga menunjukkan rata-rata besar kesalahan yang terjadi pada model (Hodson, 2022).

2.9 Symmetric Mean Absolute Percentage Error (sMAPE)

Symmetric Mean Absolute Percentage Error (sMAPE) merupakan metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan hasil peramalan pada data deret waktu dengan pendekatan persentase yang bersifat simetris. sMAPE membandingkan nilai aktual dan nilai prediksi dengan melakukan normalisasi menggunakan rata-rata keduanya, sehingga menghasilkan ukuran kesalahan yang lebih seimbang dan tidak terlalu bias terhadap nilai yang sangat besar atau sangat kecil. Dalam penelitian peramalan, sMAPE banyak digunakan untuk menilai dan membandingkan kinerja model karena mampu memberikan gambaran akurasi prediksi secara proporsional dalam bentuk persentase (Marpaung et al., 2023)

Secara matematis, sMAPE dirumuskan sebagai berikut:

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{\left(\frac{X_t + F_t}{2}\right)} \times 100\% \quad (2.10)$$

n menyatakan jumlah observasi, X_t adalah nilai aktual pada periode ke- t , dan F_t adalah nilai hasil peramalan pada periode ke- t . Rumus tersebut menunjukkan

bahwa sMAPE menghitung rata-rata persentase kesalahan absolut yang dinormalisasi oleh rata-rata nilai aktual dan prediksi. Pendekatan ini membuat ukuran kesalahan menjadi lebih stabil dan adil untuk berbagai rentang nilai data.


BAB III

METODOLOGI PENELITIAN

Pada bab ini dijelaskan metodologi penelitian yang digunakan sebagai kerangka kerja dalam menyusun proses peramalan jumlah kunjungan Museum Mpu Purwa Malang. Tahapan penelitian meliputi pengumpulan data, *preprocessing* untuk pembersihan dan penyiapan dataset, pembagian data menjadi *training set* dan *testing set*, implementasi metode N-BEATS yang mencakup proses MLP, prediksi backcast dan forecast, residual connection antar block, serta global forecast, hingga tahap evaluasi model menggunakan metrik tertentu. Rangkaian metodologi ini dirancang secara sistematis agar penelitian dapat menghasilkan prediksi yang akurat dan bermanfaat sebagai dasar pengambilan keputusan dalam pengelolaan museum.

3.1 Tahapan Penelitian

Alur kerja pada penelitian ini disusun secara sistematis agar proses peramalan dapat dilakukan dengan terarah dan terstruktur. Setiap tahapan dirancang mulai dari pengumpulan data, pengolahan awal data (*preprocessing*), pembagian data untuk pelatihan dan pengujian, implementasi metode N-BEATS, hingga evaluasi model. Diagram tahapan penelitian berikut menggambarkan secara garis besar langkah-langkah yang ditempuh dalam penelitian ini, sehingga dapat memberikan gambaran alur proses dari awal hingga akhir sebelum dijelaskan lebih rinci pada subbab berikutnya.



Gambar 3.1 Diagram Tahapan Penelitian

Tahapan penelitian ini dibagi menjadi lima bagian utama. Tahapan pertama adalah pengumpulan data, yaitu mengumpulkan data kunjungan harian Museum Mpu Purwa yang akan digunakan sebagai dasar dalam proses peramalan deret waktu. Data yang telah diperoleh kemudian memasuki tahapan kedua, yaitu preprocessing data yang disusun secara bertahap, meliputi proses cleaning untuk memilih atribut yang relevan, menghapus data tanpa tanggal, serta memastikan kolom waktu dan jumlah pengunjung berada dalam format yang seragam. Setelah itu dilakukan agregasi harian untuk menggabungkan seluruh catatan kunjungan

pada tanggal yang sama menjadi total pengunjung per hari dan membentuk urutan tanggal yang kontinu dengan pemberian nilai nol pada tanggal tanpa kunjungan. Data hasil agregasi kemudian melalui proses smoothing menggunakan rolling mean 7 untuk mengurangi fluktuasi jangka pendek, dilanjutkan dengan transformasi logaritmik dan normalisasi Z-Score agar distribusi dan skala data lebih stabil. Parameter normalisasi dihitung hanya dari data training untuk menghindari data leakage, sehingga dataset akhir siap digunakan pada tahap pemodelan.

Tahapan ketiga adalah pembagian data (data splitting), di mana dataset yang sudah melalui tahap preprocessing kemudian dibagi menjadi data training, data validation, dan data testing untuk pengujian performa model. Tahapan keempat adalah implementasi metode N-BEATS, di mana data deret waktu diproses melalui arsitektur fully connected layers di dalam beberapa block untuk membentuk representasi laten. Setiap block menghasilkan komponen backcast untuk merekonstruksi bagian historis dan forecast untuk menghasilkan prediksi, dengan mekanisme residual antar block agar kesalahan dapat diperbaiki secara bertahap hingga diperoleh prediksi akhir, serta menghasilkan global forecast sebagai output keseluruhan model. Tahapan kelima adalah evaluasi model, di mana hasil prediksi dibandingkan dengan data aktual menggunakan metrik evaluasi sMAPE. Nilai evaluasi tersebut digunakan untuk menilai tingkat akurasi dan kinerja model dalam memprediksi jumlah kunjungan museum berdasarkan data deret waktu yang telah diproses.

3.1.1 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan memanfaatkan data kunjungan Museum Mpu Purwa Malang yang tercatat melalui sistem *barcode* yang diintegrasikan dengan *Google Form*. Setiap pengunjung yang memasuki area museum diwajibkan melakukan pemindaian *barcode*, sehingga informasi kunjungan dapat terdokumentasi secara otomatis dan terstruktur. Dataset yang diperoleh terdiri atas beberapa item, antara lain *Timestamp/Datetime*, Jumlah Kunjungan, Identitas Pengunjung, dan Kategori Pengunjung. Namun, tidak semua atribut tersebut digunakan dalam penelitian ini, melainkan hanya dipilih yang relevan dengan tujuan peramalan jumlah kunjungan.


Tabel 3.1 Fitur Dataset

No	Nama	Keterangan
1	Timestamp/Datetime	Waktu kunjungan tercatat saat <i>barcode</i> discan
2	Jumlah Kunjungan	Banyaknya pengunjung pada waktu tertentu

Timestamp/Datetime digunakan sebagai indeks deret waktu yang menunjukkan urutan kronologis data kunjungan, sedangkan *Jumlah Kunjungan* menjadi variabel target utama dalam proses forecasting. Sementara itu, atribut lain seperti *Identitas Pengunjung* dan *Kategori Pengunjung* hanya bersifat tambahan dalam dataset, sehingga tidak dilibatkan dalam tahap analisis maupun implementasi model. Dengan pemilihan dua atribut inti tersebut, pola historis kunjungan dapat dianalisis secara lebih sistematis sehingga mendukung pembentukan prediksi jumlah kunjungan yang akurat.

3.1.2 *Preprocessing*

Sebelum data digunakan dalam proses pemodelan menggunakan metode N-BEATS, dilakukan tahap *preprocessing* untuk memastikan bahwa data berada dalam kondisi bersih, terstruktur, dan siap diolah. Proses ini penting untuk mengurangi potensi kesalahan akibat adanya data yang tidak konsisten, hilang, atau tidak sesuai format. Secara umum, alur tahapan *preprocessing* ditunjukkan pada Gambar 3.2, yang menggambarkan urutan proses mulai dari pembersihan data hingga pembentukan dataset akhir yang siap digunakan.



Gambar 3. 2 Diagram *Preprocessing*

Melalui preprocessing, data mentah diubah menjadi dataset yang dapat dimanfaatkan secara optimal dalam proses pelatihan dan pengujian model N-BEATS. Setiap tahap dalam proses ini memiliki fungsi yang saling berkaitan, meliputi cleaning, agregasi harian, rolling mean 7, transformasi dan normalisasi data. Rangkaian tahapan tersebut bertujuan untuk memastikan kualitas data agar model dapat memproses data secara efektif.

3.1.2.1 Data Cleaning

Tahap cleaning merupakan langkah awal dalam proses preprocessing yang bertujuan untuk memastikan kualitas data agar terstruktur, konsisten, dan siap digunakan dalam analisis lebih lanjut. Pada penelitian ini, proses cleaning difokuskan pada pemilihan dan penyesuaian atribut yang relevan dengan pemodelan deret waktu, yaitu kolom timestamp dan jumlah pengunjung. Kolom timestamp dikonversi ke dalam format tanggal yang seragam agar setiap data memiliki urutan waktu yang jelas dan dapat diproses secara kronologis oleh model peramalan N-BEATS, sedangkan kolom jumlah pengunjung dikonversi ke dalam tipe data numerik untuk memastikan proses komputasi berjalan dengan akurat. Nilai kosong pada kolom timestamp dihapus karena tidak memenuhi karakteristik data deret waktu dan dapat mengganggu urutan observasi, sementara atribut lain yang tidak relevan dengan tujuan prediksi tidak disertakan dalam proses analisis. Kolom-kolom tersebut diabaikan karena tidak berdampak langsung terhadap variabel waktu dan target prediksi. Dengan demikian, proses cleaning ini berfokus pada penyusunan dataset yang ringkas dan relevan berdasarkan variabel waktu dan jumlah kunjungan. Contoh hasil data setelah dilakukan cleaning ditunjukkan pada Tabel 3.2 berikut.

Tabel 3. 2 Sampel Hasil Cleaning Data

Timestamp	Jumlah Pengunjung (Number of Visitors)
6/17/2022 13:27:57	2
6/17/2022 14:20:21	1
6/17/2022 14:20:51	1
6/17/2022 14:25:17	1
6/17/2022 14:26:48	1

3.1.2.2 Agregasi Harian

Tahap agregasi harian dilakukan untuk mengelompokkan dan merangkum data berdasarkan tanggal kunjungan. Tujuan dari proses ini adalah untuk menyeragamkan interval waktu dan memperoleh total jumlah pengunjung per hari sehingga data sesuai dengan kebutuhan analisis deret waktu harian. Data hasil cleaning masih berupa pencatatan berbasis waktu rinci (jam, menit, dan detik) sehingga dalam satu tanggal yang sama terdapat beberapa entri kunjungan. Melalui proses agregasi harian, seluruh entri dengan tanggal yang sama digabungkan dengan cara menjumlahkan nilai kunjungan sehingga setiap tanggal memiliki satu nilai total pengunjung. Selain itu, urutan tanggal juga diselaraskan agar kontinu dengan menambahkan tanggal yang tidak memiliki catatan kunjungan dan mengisinya dengan nilai 0. Dengan agregasi ini, dataset menjadi lebih terstruktur dengan interval harian yang konsisten dan representatif untuk pemodelan deret waktu.

Setelah proses agregasi harian selesai, diperoleh tabel yang berisi dua kolom utama, yaitu tanggal dan total jumlah pengunjung harian, yang siap digunakan dalam tahap analisis berikutnya. Tabel contoh hasil agregasi harian tersebut ditampilkan sebagai berikut.

Tabel 3. 3 Sampel Hasil Agregasi Harian

Timestamp	Kategori Pengunjung (Visitors Categories)
6/17/2022	14
6/18/2022	2
6/19/2022	3
6/20/2022	0
6/21/2022	15

3.1.2.3 *Rolling Mean 7*

Tahap rolling mean 7 dilakukan untuk menghaluskan data deret waktu harian dengan cara meratakan nilai kunjungan menggunakan jendela perhitungan sepanjang tujuh hari. Tujuan dari proses ini adalah untuk mengurangi fluktuasi jangka pendek dan noise pada data kunjungan museum sehingga pola tren yang mendasari menjadi lebih stabil dan lebih mudah dipelajari oleh model peramalan. Data hasil agregasi harian masih dapat mengandung lonjakan atau penurunan tajam akibat variasi kunjungan harian, sehingga diperlukan proses perataan agar sinyal data menjadi lebih representatif. Melalui proses rolling mean 7, setiap nilai pada suatu tanggal dihitung sebagai rata-rata dari tujuh nilai kunjungan harian terakhir secara berurutan. Dengan penerapan rolling mean ini, dataset menjadi lebih halus dan konsisten tanpa menghilangkan kecenderungan pola utama deret waktu.

Secara matematis, rolling mean dengan jendela 7 dinyatakan dengan rumus:

$$RM_t = \frac{1}{7} \sum_{i=0}^6 y_{t-i} \quad (3.1)$$

RM_t menyatakan nilai rolling mean pada waktu ke- t , y_{t-i} menyatakan nilai jumlah pengunjung pada periode ke- t hingga enam periode sebelumnya, dan angka 7 menunjukkan ukuran jendela perataan yang digunakan. Rumus tersebut menunjukkan bahwa setiap titik data baru merupakan hasil rata-rata dari tujuh observasi terakhir sehingga menghasilkan deret waktu yang lebih halus.

Setelah proses rolling mean 7 selesai, diperoleh tabel data kunjungan yang telah melalui proses smoothing dan siap digunakan dalam tahap pemodelan serta evaluasi pada proses peramalan berikutnya. Tabel contoh hasil rolling mean 7 tersebut ditampilkan sebagai berikut:

Tabel 3. 4 Sampel Rolling Mean 7

Date	Total Pengunjung	Rolling Mean 7
6/17/2022	14	14
6/18/2022	2	8
6/19/2022	3	6.333333333
6/20/2022	0	4.75
6/21/2022	15	6.8
6/22/2022	0	5.666666667
6/23/2022	4	5.428571429

3.1.2.4 Transformasi dan Normalisasi Data

Tahap transformasi dan normalisasi data dilakukan untuk menyiapkan data hasil rolling mean agar memiliki distribusi dan skala yang lebih sesuai untuk proses pembelajaran model deret waktu berbasis deep learning. Tujuan dari proses ini adalah untuk mengurangi kemencengan distribusi data, menekan pengaruh nilai ekstrem, serta menyeragamkan rentang nilai agar proses pelatihan model menjadi lebih stabil. Data kunjungan yang telah melalui proses smoothing masih dapat memiliki sebaran yang tidak seimbang, sehingga diperlukan transformasi dan normalisasi sebelum digunakan sebagai masukan model. Pada penelitian ini, proses transformasi dan normalisasi dihitung hanya berdasarkan data training, kemudian parameter yang diperoleh diterapkan pada data validasi dan data pengujian. Pendekatan ini dilakukan untuk menjaga skenario pemodelan tetap realistis dan mencegah terjadinya data leakage. Dengan penerapan transformasi dan normalisasi, dataset menjadi lebih representatif dan mendukung proses pembelajaran model secara optimal.

Transformasi data dilakukan menggunakan fungsi logaritmik yang secara umum dirumuskan sebagai:

$$y_t' = \log(y_t + 1) \quad (3.2)$$

y_t menyatakan nilai data pada periode ke- t dan y_t' menyatakan nilai hasil transformasi logaritmik. Penambahan konstanta 1 dilakukan untuk menghindari nilai tak terdefinisi ketika terdapat nilai 0 pada data. Transformasi logaritmik berfungsi untuk mengecilkan rentang nilai yang terlalu lebar dan mengurangi tingkat skewness sehingga distribusi data menjadi lebih seimbang.

Setelah transformasi logaritmik, dilakukan normalisasi menggunakan metode standarisasi Z-Score dengan rumus:

$$z_t = \frac{y_t' - \mu}{\sigma} \quad (3.3)$$

z_t adalah nilai hasil normalisasi pada periode ke- t , y_t' adalah nilai data setelah transformasi logaritmik, μ adalah nilai rata-rata data training, dan σ adalah standar deviasi data training. Nilai rata-rata dan standar deviasi dihitung hanya dari data training, lalu digunakan kembali untuk menormalisasi data validasi dan data pengujian agar tidak terjadi kebocoran informasi antar pembagian data.

Sebagai contoh perhitungan, misalkan nilai jumlah pengunjung hasil rolling mean pada tanggal 6/17/2022 adalah 14. Tahap pertama dilakukan transformasi logaritmik menggunakan rumus $y_t' = \log(y_t + 1)$ untuk mengurangi kemencengan distribusi dan menekan pengaruh nilai ekstrem. Dengan demikian diperoleh nilai transformasi $y_t' = \log(14 + 1) = \log(15) = 2,7081$ (menggunakan log natural). Nilai hasil transformasi ini kemudian dinormalisasi menggunakan standarisasi Z-Score dengan rumus $z_t = \frac{y_t' - \mu}{\sigma}$, di mana μ adalah rata-rata dan σ adalah standar deviasi yang dihitung hanya dari data training. Misalkan dari data training diperoleh rata-rata sebesar 2,30 dan standar deviasi sebesar 0,40, maka nilai normalisasi untuk

data tersebut adalah $z_t = \frac{2,7081-2,30}{0,40} = 1,0203$. Hasil normalisasi inilah yang selanjutnya digunakan sebagai nilai input pada proses pelatihan model.

3.1.3 Data Splitting

Setelah tahap preprocessing selesai dilakukan, langkah selanjutnya adalah melakukan pembagian data (data splitting) sebagai bagian dari skenario pengujian model. Pembagian data ini bertujuan untuk menilai sejauh mana model N-BEATS mampu melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya serta untuk mengoptimalkan proses pelatihan model.

Dalam penelitian ini, dataset dibagi menjadi tiga bagian utama, yaitu training set, validation set, dan testing set. Pembagian menjadi tiga subset dilakukan karena model N-BEATS menerapkan mekanisme early stopping, sehingga diperlukan data validasi untuk memantau performa model selama proses pelatihan dan menentukan kapan proses pelatihan dihentikan untuk mencegah overfitting.

Training set digunakan untuk melatih model agar dapat mempelajari pola dan hubungan dari data historis kunjungan museum. Validation set digunakan untuk mengevaluasi performa model pada setiap epoch pelatihan serta sebagai acuan dalam penerapan early stopping. Sementara itu, testing set digunakan pada tahap akhir untuk mengukur kinerja model secara objektif terhadap data yang tidak terlibat dalam proses pelatihan maupun validasi.

Adapun skenario pembagian data yang digunakan dalam penelitian ini dapat dilihat pada Tabel berikut.


Tabel 3. 5 Splitting Data

No	Skenario Split	Training	Validation	Testing
1	70:15:15	70%	15%	15%
2	80:10:10	80%	10%	10%
3	90:05:05	90%	5%	5%

3.1.4 Implementasi Metode N-Beats

Tahap implementasi metode N-BEATS (Neural Basis Expansion Analysis for Interpretable Time Series Forecasting) merupakan proses penerapan konsep model ke dalam bentuk sistem yang dapat melakukan prediksi jumlah kunjungan Museum Mpu Purwa. Pada tahap ini, dilakukan serangkaian langkah mulai dari inisialisasi parameter model, pemrosesan data masukan, pembentukan basic block, hingga menghasilkan nilai forecast sebagai hasil prediksi. Implementasi ini bertujuan untuk mengubah rancangan teoretis model menjadi sistem yang dapat diuji dan dievaluasi menggunakan data penelitian.

Gambaran umum mengenai alur proses implementasi metode N-BEATS ditunjukkan pada flowchart berikut.



Gambar 3. 3 Implementasi N-Beats

Secara umum, proses kerja N-BEATS diawali dengan memasukkan data periode T dan parameter model seperti horizon, jumlah blok, lapisan, tumpukan, serta dimensi hidden layer. Data tersebut kemudian diproses melalui jaringan fully connected dengan fungsi aktivasi ReLU untuk menghasilkan representasi data yang optimal. Selanjutnya, setiap basic block menghasilkan dua keluaran, yaitu backcast

yang memperbaiki kesalahan prediksi sebelumnya, dan forecast yang menghasilkan nilai prediksi baru. Proses ini diulang hingga seluruh blok dan tumpukan selesai, yang mana hasil akhirnya berupa total forecast yang menjadi output model. Tahapan ini menjadi dasar untuk analisis performa dan evaluasi model pada bagian berikut.

a. Proses *Fully Connected Layers*

Dalam Pada tahap ini, block N-BEATS melakukan proses transformasi internal menggunakan Fully Connected Layer (FC Layer) atau lapisan terhubung penuh. Lapisan ini berfungsi untuk mengubah data input menjadi representasi laten melalui kombinasi linier antara bobot (weight) dan bias, yang kemudian dilewatkan ke dalam fungsi aktivasi non-linier seperti ReLU (Rectified Linear Unit). Proses ini memungkinkan model untuk menangkap hubungan kompleks dan pola tersembunyi di dalam data deret waktu historis yang digunakan sebagai masukan.

Sebelum memasuki tahap transformasi, terlebih dahulu ditentukan beberapa parameter penting, seperti panjang *lookback window* (jumlah data historis yang digunakan sebagai input), panjang *forecast horizon* (jumlah periode ke depan yang diprediksi), serta pembentukan pasangan data input-output (X, Y) dari dataset. Penentuan parameter ini sangat penting karena memengaruhi kualitas representasi pola historis yang dapat dipelajari oleh model.

Dalam block N-BEATS, operasi transformasi linier dilakukan menggunakan parameter bobot dan bias yang sama (*shared parameters*) di

seluruh lapisan dalam satu block. Hal ini memastikan bahwa seluruh proses pembentukan representasi laten tetap konsisten dan dioptimasi secara bersama selama pelatihan.

Sebagai contoh, pada perhitungan berikut digunakan dua tahap operasi linier (dua *layer*) dengan fungsi aktivasi ReLU untuk menggambarkan proses transformasi yang terjadi didalam satu block N-BEATS. Hasil dari transformasi pertama (h_1) akan diproses kembali pada tahap kedua (h_2) menggunakan parameter yang sama, hingga diperoleh representasi laten akhir (θ) yang digunakan untuk membentuk komponen *backcast* dan *forecast*. Digunakan data kunjungan museum pada tanggal 17 – 23 Juni sebagai input, sedangkan tanggal 24 Juni dipakai sebagai target keluaran untuk proses prediksi.

Tabel 3. 6 Sampel Dataset

Tanggal	Jumlah Pengunjung	Peran dalam Model
6/17/2022	14	X_1
6/18/2022	8	X_2
6/19/2022	6.333333333	X_3
6/20/2022	4.75	X_4
6/21/2022	6.8	X_5
6/22/2022	5.666666667	X_6
6/23/2022	5.428571429	X_7
6/24/2022	4.571428571	Y

Penulisan input historis dan output dapat direpresentasikan sebagai berikut.

$$X = \begin{bmatrix} 14 \\ 8 \\ 6.3333 \\ 4.75 \\ 6.8 \\ 5.6667 \\ 5.4286 \end{bmatrix}, Y = [4.5714]$$

Pada percobaan ini, jumlah neuron ditetapkan empat ($\theta \in \mathbb{R}^4$).

Bobot dan bias ditentukan secara acak sebagai berikut:

Matriks $W_1 \in \mathbb{R}^{4 \times 7}$

$$W_1 = \begin{bmatrix} 0.1 & 0.2 & -0.1 & 0.05 & 0.1 & 0.0 & 0.2 \\ -0.05 & 0.1 & 0.2 & 0.1 & -0.1 & 0.05 & 0.0 \\ 0.2 & -0.1 & 0.05 & 0.1 & 0.2 & -0.05 & 0.1 \\ 0.0 & 0.1 & 0.1 & -0.05 & 0.05 & 0.2 & 0.1 \end{bmatrix}$$

Vektor bias $b_1 = [0.5 \quad -0.2 \quad 0.1 \quad 0.0]$

Maka perhitungan lapisan pertama:

$$h_1 = ReLU(W_1 X + b_1) \quad (3.4)$$

Substitusi X ke persamaan menghasilkan:

$$W_1 X = \begin{bmatrix} 3.5741 \\ 2.3481 \\ 4.3088 \\ 1.8463 \end{bmatrix}, \quad h_1 = ReLU \begin{bmatrix} 4.0741 \\ 2.1481 \\ 4.4088 \\ 1.8463 \end{bmatrix} = \begin{bmatrix} 4.0741 \\ 2.1481 \\ 4.4088 \\ 1.8463 \end{bmatrix}$$

Hasil dari transformasi pertama (h_1) selanjutnya diproses kembali menggunakan parameter yang sama (W_1, b_1) untuk menghasilkan representasi laten pada layer terakhir (h_2):

$$h_2 = ReLU(W_1 h_1 + b_1) \quad (3.5)$$

Substitusi nilai h_1 ke persamaan menghasilkan:

$$W_1 h_1 = \begin{bmatrix} 0.4869 \\ 0.9441 \\ 1.4217 \\ 0.5453 \end{bmatrix}, \quad h_2 = ReLU \begin{bmatrix} 0.9860 \\ 0.7441 \\ 1.5217 \\ 0.5453 \end{bmatrix} = \begin{bmatrix} 0.9860 \\ 0.7441 \\ 1.5217 \\ 0.5453 \end{bmatrix}$$

Hasil layer terakhir (h_2) menjadi representasi laten (θ) yang selanjutnya akan digunakan sebagai dasar dalam membentuk komponen *backcast* dan *forecast* pada blok N-BEATS.

b. Prediksi Backcast dan Forecast

Pada tahap berikutnya, representasi laten θ yang dihasilkan dari proses *Fully Connected Layer* diproyeksikan ke dalam dua komponen utama, yaitu *backcast* dan *forecast*. Proyeksi ini dilakukan melalui operasi linier dengan menggunakan matriks bobot V_b dan V_f serta bias masing-masing persamaan. Proyeksi ke *backcast* dan *forecast* dilakukan dengan persamaan linear:

$$g^f(\theta_l^f) = V_f \theta + b^f \quad (3.6)$$

$$g^b(\theta_l^b) = V_b \theta + b^b \quad (3.7)$$

Dengan matriks proyeksi sebagai berikut:

$$V_b \in \mathbb{R}^{7 \times 4}$$

$$V_b = \begin{bmatrix} 0.2 & 0.1 & 0.0 & -0.1 \\ 0.05 & 0.2 & -0.05 & 0.1 \\ 0.1 & 0.0 & 0.1 & 0.05 \\ 0.0 & 0.1 & 0.2 & -0.1 \\ 0.15 & -0.05 & 0.05 & 0.1 \\ 0.1 & 0.1 & 0.0 & 0.2 \\ 0.05 & 0.0 & 0.15 & -0.05 \end{bmatrix}, b^b = 0$$

$$V_f \in \mathbb{R}^{1 \times 4} = [0.1 \quad 0.2 \quad 0.05 \quad 0.1], \text{ dengan } b^f = 0$$

Maka diperoleh:

$$g^b(\theta) = \begin{bmatrix} 0.2171 \\ 0.1766 \\ 0.2780 \\ 0.3242 \\ 0.2413 \\ 0.2821 \\ 0.2503 \end{bmatrix}, g^f(\theta) = [0.37804]$$

Setelah dilakukan proses perhitungan *backcast* dan *forecast*, nilai tersebut merupakan keluaran akhir dari basic block pertama, yang

selanjutnya akan menjadi masukan pada block berikutnya dalam arsitektur N-BEATS untuk memperbaiki prediksi terhadap target aktual.

c. Residual Connection antar Block

Dalam arsitektur N-BEATS, *residual connection* pada block merupakan mekanisme yang bekerja setelah proses *Fully Connected Layer* menghasilkan representasi laten. Setiap block memiliki dua keluaran utama, yaitu *backcast* dan *forecast*. *Backcast* $g^b(\theta)$ berfungsi merekonstruksi input historis dengan tujuan menjelaskan pola data yang sudah ada, sedangkan *forecast* $g^f(\theta)$ digunakan untuk menghasilkan prediksi pada horizon waktu ke depan. Setelah block pertama menghasilkan *backcast*, nilai tersebut dikurangi dari input awal X , sehingga terbentuk residual, yang dihitung dengan persamaan:

$$r = X - g^b(\theta) \quad (3.8)$$

Residual ini kemudian menjadi masukan bagi block berikutnya, sehingga setiap block bertugas memperbaiki sisa kesalahan yang belum dapat dijelaskan oleh block sebelumnya. Sebagai contoh Pada implementasi dengan data:

$$X = [14 \quad 8 \quad 6.3333 \quad 4.75 \quad 6.8 \quad 5.6667 \quad 5.4286]$$

Perhitungan menghasilkan *backcast* sebagai berikut.

$$g^b(\theta) = \begin{bmatrix} 0.2171 \\ 0.1766 \\ 0.2780 \\ 0.3242 \\ 0.2413 \\ 0.2821 \\ 0.2503 \end{bmatrix}$$

Berdasarkan hasil *backcast* tersebut, dilakukan perhitungan *residual* dengan cara mengurangkan nilai *backcast* dari data input historis pada setiap elemen. Perhitungan ini bertujuan untuk melihat sejauh mana block pertama mampu merekonstruksi pola data masukan. Rincian perhitungan *residual* pada setiap elemen dapat dilihat pada Tabel 3.7 berikut.

Tabel 3. 7 Perhitungan Residual

Elemen	X_i	$g^b(\theta)_i$	$r_i = X_i - g^b(\theta)_i$
1	14	0.2171	13.7829
2	8	0.1766	7.8234
3	6.3333	0.2780	6.0553
4	4.75	0.3242	4.4258
5	6.8	0.2413	6.5587
6	5.6667	0.2821	5.3846
7	5.4286	0.2503	5.1783

Berdasarkan perhitungan pada tabel tersebut didapatkan nilai residual sebagai berikut.

$$r = \begin{bmatrix} 13.7829 \\ 7.8234 \\ 6.0553 \\ 4.4258 \\ 6.5587 \\ 5.3846 \\ 5.1783 \end{bmatrix}$$

Nilai positif pada residual menandakan bahwa model masih kurang dalam menangkap pola input pada titik tersebut, sedangkan nilai negatif menandakan adanya estimasi berlebih. Nilai residual inilah yang menjadi input bagi block kedua, sehingga block selanjutnya dapat fokus memperbaiki kesalahan yang tersisa. Proses ini terus berlanjut hingga block terakhir, dan hasil *forecast* akhir diperoleh dari penjumlahan seluruh *forecast* tiap block.

d. Global Forecast

Setelah melalui mekanisme *residual connection*, keluaran akhir dari model N-BEATS diperoleh melalui pendekatan *global forecast*. Artinya, hasil prediksi pada horizon yang ditentukan merupakan penjumlahan seluruh *forecast* yang dihasilkan dari setiap block. Secara matematis dapat dituliskan sebagai berikut.

$$\hat{y} = \sum_{i=1}^B g_i^f(\theta_i) \quad (3.9)$$

dengan B adalah jumlah block, dan $g_i^f(\theta_i)$ adalah *forecast* yang dihasilkan oleh block ke- i .

Pada perhitungan awal block pertama, diperoleh nilai *forecast* sebesar 3.2775. Nilai ini kemudian akan ditambahkan dengan hasil *forecast* dari block-block berikutnya. Namun, berdasarkan hasil perhitungan lanjutan, nilai global forecast akhir untuk horizon yang ditentukan tetap sebesar:

$$\hat{Y} = 0.3780$$

Setelah model menghasilkan nilai prediksi $\hat{Y}$ dan diketahui nilai aktual Y , tahap selanjutnya adalah menghitung *loss* atau kesalahan antara keduanya. Pada penelitian ini digunakan fungsi *Smooth L1 Loss (Huber Loss)*, yang dirumuskan sebagai berikut.

$$L(\hat{Y}, Y) = \begin{cases} \frac{1}{2} (Y - \hat{Y})^2 & \text{jika } |Y - \hat{Y}| < 1 \\ |Y - \hat{Y}| - \frac{1}{2} & \text{jika } |Y - \hat{Y}| \geq 1 \end{cases} \quad (3.10)$$

Jika nilai aktual kunjungan adalah $Y = 4.5714$, maka diperoleh $e = 4.5714 - 0.3780 = 4.1934$ karena $|e| = 4.1934 > 1$ Maka digunakan bagian linear dari Huber:

$$L = |e| - 0.5$$

$$L = 4.1934 - 0.5$$

$$L = 3.6934$$

Agar model dapat belajar dan memperbaiki kesalahannya, dilakukan proses *backpropagation*, yaitu mekanisme propagasi balik gradien dari lapisan keluaran menuju lapisan-lapisan terdalam. Proses ini bertujuan memperbarui bobot dan bias pada seluruh jalur jaringan mulai dari *forecast* dan *backcast*, hingga jaringan *Fully Connected Layer* yang membentuk representasi laten (θ). Dengan cara ini, model secara bertahap menyesuaikan setiap parameter berdasarkan kontribusinya terhadap kesalahan prediksi, sehingga hasil *forecast* pada iterasi berikutnya semakin mendekati nilai aktual.

Proses *backpropagation* pada model N-BEATS dengan fungsi *Huber Loss* dijelaskan sebagai berikut:

1. Perhitungan Gradien terhadap Output (*Forecast*)

Turunan fungsi Huber terhadap nilai prediksi $\hat{Y}$ dihitung berdasarkan tanda perbedaan antara hasil prediksi dan nilai sebenarnya. Nilai gradien ini menunjukkan arah perubahan bobot yang diperlukan untuk memperkecil kesalahan.

Sebagai contoh, jika $\hat{Y} = 0.3780$ dan $Y = 4.5714$, maka selisihnya -4.1934 , sehingga $\frac{\partial L}{\partial \hat{Y}} = -1$. Artinya, arah gradien bernilai negatif, menandakan bahwa model perlu meningkatkan nilai output agar mendekati nilai aktual.

2. Gradien terhadap Bobot dan Bias pada Jalur Forecast

Hubungan antara vektor laten θ dan hasil prediksi (*forecast*) dinyatakan dengan $g^f(\theta_l^f) = V_f \theta + b^f$. Kemudian, turunan fungsi *loss* terhadap parameter V_f diperoleh dengan menggunakan *chain rule*:

$$\frac{\partial L}{\partial V_f} = \frac{\partial L}{\partial g_f} \cdot \frac{\partial g_f}{\partial L} \quad (3.11)$$

Karena $\frac{\partial g_f}{\partial V_f} = \theta^T$ dan $\frac{\partial L}{\partial g_f} = \text{sign}(\hat{Y} - Y)$, maka:

$$\frac{\partial L}{\partial V_f} = \text{sign}(\hat{Y} - Y) \cdot \theta^T \quad (3.12)$$

Sedangkan untuk bias:

$$\frac{\partial L}{\partial b_f} = \text{sign}(\hat{Y} - Y) \quad (3.13)$$

Sebagai contoh, jika $\theta = [0.9860, 0.7441, 1.5217, 0.5453]^T$ dan $\text{sign}(\hat{Y} - Y) = -1$, maka:

$$\frac{\partial L}{\partial V_f} = -[0.9860, 0.7441, 1.5217, 0.5453]^T$$

yang berarti seluruh komponen θ_i memberikan kontribusi negatif terhadap kesalahan, karena nilai prediksi masih terlalu kecil dibanding nilai sebenarnya.

3. Gradien terhadap Jalur *Backcast*

Jalur *backcast* digunakan untuk memperbaiki *residual* dari input yang belum dapat dijelaskan oleh *forecast* sebelumnya. Hubungan antara θ dan keluaran *backcast* dirumuskan dengan $g_b(\theta) = V_b\theta + b_b$

dengan perhitungan *residual* sebagai $r = X - g_b(\theta)$.

Karena perubahan pada $g_b(\theta)$ berlawanan arah dengan *residual*, maka turunan terhadap *loss* adalah:

$$\frac{\partial L}{\partial g_b} = -\frac{\partial L}{\partial r} \quad (3.14)$$

Selanjutnya, turunan terhadap bobot V_b adalah:

$$\frac{\partial L}{\partial V_b} = \frac{\partial L}{\partial g_b} \cdot \frac{\partial g_b}{\partial V_b} = (-1) \cdot \theta^T = -\theta^T \quad (3.15)$$

dan terhadap bias:

$$\frac{\partial L}{\partial b_b} = -1 \quad (3.16)$$

Sebagai ilustrasi, jika $V_b(t) = [0.2, 0.1, 0.0, -0.1]$ dan laju pembelajaran (α) sebesar 0.001, maka pembaruan parameter dilakukan dengan rumus:

$$V_b(t+1) = V_b(t) - \alpha \frac{\partial L}{\partial V_b}$$

$$V_b(t+1) = [0.2, 0.1, 0.0, -0.1] - 0.001(-\theta^T)$$

$$V_b(t+1) = [0.200986, 0.1007441, 0.0015217, -0.0994547]$$

Peningkatan nilai bobot menunjukkan bahwa model sedang menyesuaikan diri agar mampu menghasilkan *backcast* yang lebih akurat untuk mengurangi *residual error*.

4. Gradien terhadap *FC Layer*

Vektor laten θ yang digunakan dalam kedua jalur (*forecast* dan *backcast*) dihasilkan oleh *FC Layer*. Oleh karena itu, gradien dari fungsi *loss* juga harus diturunkan terhadap parameter *FC Layer* agar seluruh model dapat diperbarui secara end-to-end.

Turunan *loss* terhadap θ diperoleh sebagai kombinasi dari dua jalur utama:

$$\frac{\partial L}{\partial \theta} = \frac{\partial L}{\partial g_f} \cdot \frac{\partial g_f}{\partial \theta} + \frac{\partial L}{\partial g_b} \cdot \frac{\partial g_b}{\partial \theta} \quad (3.17)$$

Dengan $\frac{\partial g_f}{\partial \theta} = V_f$ dan $\frac{\partial g_b}{\partial \theta} = V_b$, maka:

$$\frac{\partial L}{\partial \theta} = \text{sign}(\hat{Y} - Y)V_f - V_b \quad (3.18)$$

Gradien ini kemudian digunakan untuk memperbarui bobot (W_1) dan bias (b_1) pada *FC Layer* melalui hubungan:

$$\frac{\partial L}{\partial W_1} = \frac{\partial L}{\partial \theta} \cdot \frac{\partial \theta}{\partial W_1} \quad (3.19)$$

Setelah seluruh gradien diperoleh melalui proses backpropagation, tahap selanjutnya adalah melakukan pembaruan parameter jaringan. Pada penelitian ini digunakan algoritma optimisasi Adam (Adaptive Moment Estimation) karena mampu mempercepat konvergensi dan menjaga stabilitas pembelajaran pada model deep learning.

Perhitungan Adam dilakukan sebagai berikut:

a. Estimasi momen pertama (momentum):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1)g_t \quad (3.20)$$

b. Estimasi momen kedua (RMS term):

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) v_t \quad (3.21)$$

Dengan $g_t = \frac{\partial L}{\partial \theta}$ adalah gradien pada iterasi ke-t. β_1 dan β_2 adalah parameter peluruhan (umumnya 0.9 dan 0.999). Karena momen pertama dan kedua pada awalnya bernilai nol, dilakukan koreksi bias:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.22)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.23)$$

Selanjutnya parameter diperbarui dengan:

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (3.24)$$

Dengan α adalah learning rate dan ϵ merupakan konstanta kecil untuk menghindari pembagian nol. Melalui mekanisme ini, pembaruan parameter tidak hanya mempertimbangkan besar gradien saat ini, tetapi juga riwayat gradien sebelumnya, sehingga proses pelatihan menjadi lebih stabil dan adaptif terhadap variasi skala gradien.

3.1.5 Evaluasi Model

Dalam Pengukuran kinerja model peramalan pada penelitian ini menggunakan tiga metrik utama, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Symmetric Mean Absolute Percentage Error* (sMAPE). Ketiga metrik tersebut berfungsi untuk menilai tingkat akurasi model dalam memprediksi jumlah kunjungan Museum Mpu Purwa berdasarkan data historis.

Penggunaan ketiga metrik ini memberikan pemahaman yang komprehensif mengenai sejauh mana hasil prediksi mendekati nilai aktual serta kemampuan model dalam mengenali pola data deret waktu.

Metrik Root Mean Square Error (RMSE) merupakan akar kuadrat dari MSE yang menghasilkan ukuran kesalahan dalam satuan yang sama dengan data aslinya. RMSE mengukur rata-rata deviasi antara nilai aktual dan hasil prediksi, serta memberikan penalti lebih besar terhadap kesalahan yang bernilai tinggi. Rumus RMSE dapat dituliskan sebagai berikut.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.25)$$

dengan Y_t nilai aktual pada waktu ke- t , $\hat{Y}_t$ merupakan nilai prediksi, dan n merupakan jumlah data pengujian. Nilai RMSE yang lebih kecil menunjukkan bahwa model memiliki tingkat kesalahan rata-rata yang rendah, menandakan bahwa hasil prediksi cukup akurat terhadap data aktual.

Mean Absolute Error (MAE) menghitung rata-rata kesalahan absolut antara nilai aktual dan hasil prediksi tanpa memperhatikan arah kesalahan, sehingga memberikan gambaran seberapa jauh prediksi model dari data sebenarnya. Secara matematis, MAE dirumuskan sebagai berikut.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (3.26)$$

dengan n merupakan jumlah data pengujian, Y_t nilai aktual pada waktu ke- t , dan $\hat{Y}_t$ merupakan nilai hasil prediksi pada waktu ke- t . Nilai MAE yang lebih kecil menunjukkan bahwa model memiliki tingkat kesalahan rata-rata yang rendah, menandakan bahwa hasil prediksi cukup akurat terhadap data aktual.

Symmetric Mean Absolute Percentage Error (sMAPE) digunakan untuk mengukur tingkat kesalahan dalam bentuk persentase yang bersifat simetris terhadap nilai aktual dan nilai prediksi. Berbeda dengan MAPE yang hanya membandingkan terhadap nilai aktual, sMAPE mempertimbangkan rata-rata nilai aktual dan prediksi sehingga lebih stabil ketika terdapat nilai yang mendekati nol.

Rumus sMAPE dinyatakan sebagai berikut.

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{\left(\frac{X_t + F_t}{2}\right)} \times 100\% \quad (3.27)$$

Nilai sMAPE dinyatakan dalam persentase. Semakin kecil nilai sMAPE, maka semakin kecil tingkat kesalahan prediksi relatif terhadap nilai aktual.

Melalui penggunaan MAE, RMSE, dan sMAPE secara bersamaan, evaluasi model menjadi lebih objektif dan menyeluruh. MAE memberikan gambaran rata-rata kesalahan absolut, RMSE menekankan penalti pada kesalahan besar, sedangkan sMAPE menunjukkan tingkat kesalahan dalam bentuk persentase yang bersifat simetris. Dengan demikian, performa model N-BEATS dapat dinilai secara komprehensif dalam konteks penelitian ini.

3.2 Skenario Pengujian

Dalam penelitian ini, proses pengujian dilakukan untuk menilai performa model N-BEATS dalam melakukan peramalan jumlah kunjungan Museum Mpu Purwa. Pengujian dilakukan melalui dua tahap utama, yaitu skenario pembagian data dan tuning hyperparameter, dengan tujuan memperoleh konfigurasi model yang paling optimal dan memiliki tingkat kesalahan prediksi terendah berdasarkan nilai RMSE, MAE, sMAPE.

Tahap pertama adalah pembagian data (data splitting) yang merupakan komponen penting dalam proses pelatihan model, karena perbandingan antara data latih, data validasi, dan data uji sangat memengaruhi kemampuan generalisasi model terhadap data baru. Dalam penelitian ini, dataset dibagi menjadi tiga bagian, yaitu data training, validation, dan testing seperti yang ditunjukkan pada Tabel 3.8 berikut.

Tabel 3. 8 Skenario Pengujian

Skenario	Persentase Data Training	Persentase Data Validation	Persentase Data Testing
1	70%	15%	15%
2	80%	10%	10%
3	90%	5%	5%

Tahap berikutnya adalah tuning hyperparameter, yang bertujuan untuk mengoptimalkan kinerja arsitektur model N-BEATS. Proses ini dilakukan menggunakan pendekatan grid search, di mana setiap kombinasi nilai hyperparameter diuji untuk menemukan konfigurasi paling sesuai dengan karakteristik data deret waktu kunjungan museum. Beberapa parameter yang diuji meliputi panjang lookback window, panjang forecast horizon, jumlah stack, jumlah block, jumlah layer per block, serta learning rate yang digunakan pada proses pelatihan model. Rincian nilai pengujian disajikan pada Tabel 3.9 berikut.

Tabel 3. 9 Skenario Tuning Hyperparameter

Hyperparameter	Nilai Hyperparameter
Lookback window (T)	14, 30
Forecast horizon (H)	1
Jumlah stack	1
Jumlah block	1, 2
Jumlah layer per block	1
Learning rate	0.001, 0.0005

Melalui skenario pada Tabel 3.9, setiap nilai dalam masing-masing hyperparameter akan dikombinasikan menggunakan metode grid search untuk memperoleh konfigurasi model terbaik. Panjang lookback window (T) menentukan banyaknya periode historis yang digunakan sebagai masukan model, sedangkan forecast horizon (H) menunjukkan jumlah periode ke depan yang diprediksi. Jumlah stack dan block berperan dalam menentukan kedalaman arsitektur N-BEATS dalam menangkap pola tren dan variasi pada data deret waktu. Jumlah layer per block memengaruhi kompleksitas representasi fitur yang dipelajari oleh model.

Selain itu, learning rate menentukan kecepatan pembaruan bobot selama proses pelatihan. Nilai learning rate yang terlalu besar dapat menyebabkan proses pelatihan tidak stabil, sedangkan nilai yang terlalu kecil dapat memperlambat konvergensi model. Kombinasi hyperparameter dengan nilai error terendah pada tahap evaluasi akhir pada data testing akan dipilih sebagai model terbaik.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Preprocessing Data

Tahapan preprocessing data merupakan langkah awal dalam pengolahan dataset sebelum digunakan pada proses pemodelan menggunakan model N-BEATS. Preprocessing dilakukan untuk memastikan bahwa data time series yang digunakan memiliki kualitas yang baik, bersifat kontinu, serta sesuai dengan kebutuhan pemodelan deep learning. Dataset yang digunakan dalam penelitian ini berupa data harian jumlah pengunjung Museum Mpu Purwa yang diperoleh dari file Microsoft Excel dengan atribut timestamp dan jumlah pengunjung. Secara umum, preprocessing data pada penelitian ini terdiri atas empat tahapan utama, yaitu data cleaning, agregasi harian dan penyelarasan waktu, smoothing data menggunakan rolling mean 7 hari, serta transformasi dan normalisasi data.

4.1.1 Data Cleaning

Tahap pertama dalam preprocessing data adalah data cleaning, yang bertujuan untuk memastikan bahwa dataset berada dalam kondisi terstruktur, konsisten, dan sesuai untuk analisis deret waktu. Dataset awal yang diperoleh dari file Excel memiliki beberapa atribut, namun dalam penelitian ini hanya digunakan dua kolom utama, yaitu timestamp dan jumlah pengunjung. Pemilihan ini dilakukan karena kedua atribut tersebut merupakan komponen utama dalam pemodelan time series, dimana timestamp berfungsi sebagai indeks waktu dan jumlah pengunjung

sebagai variabel target yang akan diprediksi. Kolom yang tidak relevan dengan tujuan penelitian, seperti Timestamp, Nama (Name), Asal Sekolah/Instansi/Negara Asal (Institution or Native Country), Alamat/Domisili (Address), Kritik (Critics), Saran (Suggestions), serta Kesan (Impression) tidak disertakan dalam proses analisis.

Pada tahap ini dilakukan konversi atribut timestamp ke dalam format tanggal yang seragam agar setiap observasi memiliki urutan waktu yang jelas dan dapat diproses secara kronologis. Selain itu, atribut jumlah pengunjung dikonversi ke dalam tipe data numerik guna memastikan seluruh proses komputasi dapat dilakukan dengan akurat. Data yang tidak memiliki informasi tanggal dihapus karena tidak memenuhi karakteristik data deret waktu. Melalui proses pembersihan ini, dataset menjadi lebih ringkas, relevan, dan siap digunakan pada tahapan agregasi serta pemodelan menggunakan N-BEATS.

4.1.2 Agregasi Harian

Setelah tahap data cleaning, data selanjutnya diproses melalui tahap agregasi harian. Data awal yang diperoleh masih berada dalam bentuk pencatatan berbasis waktu rinci (jam, menit, dan detik), sehingga dalam satu tanggal yang sama terdapat beberapa entri dengan nilai jumlah pengunjung yang berbeda-beda. Tabel berikut merupakan kondisi sebelum data memasuki proses agregasi.

Tabel 4. 1 Data Sebelum Agregasi

Timestamp	Jumlah Pengunjung (Number of Visitors)
6/17/2022 13:27:57	2
6/17/2022 14:20:21	1
6/17/2022 14:20:51	1
...	...

7/20/2025 13:56:25	3
7/20/2025 13:59:27	3
7/20/2025 14:37:52	2

Kondisi ini menunjukkan bahwa data masih memiliki interval waktu yang belum seragam dan belum sesuai dengan kebutuhan analisis deret waktu harian. Oleh karena itu, dilakukan proses agregasi harian untuk menyederhanakan data dan menyeragamkan interval waktu.

Melalui proses agregasi, seluruh data yang memiliki tanggal yang sama digabungkan dengan cara menjumlahkan seluruh kunjungan dalam satu hari sehingga diperoleh total jumlah pengunjung harian. Hasil dari proses ini menghasilkan satu nilai total untuk setiap tanggal, seperti pada tabel berikut.

Tabel 4. 2 Data Setelah Agregasi

Date	Total Pengunjung Harian
6/17/2022	14
6/18/2022	2
6/19/2022	3
...	...
7/18/2025	12
7/19/2025	100
7/20/2025	37

Setelah proses agregasi, data selanjutnya diselaraskan dengan membentuk urutan tanggal yang lengkap agar deret waktu bersifat kontinu. Tanggal yang tidak memiliki data kunjungan tetap dimasukkan ke dalam deret waktu dan diberi nilai 0, yang merepresentasikan kondisi tidak adanya pengunjung museum pada hari tersebut. Pendekatan ini dilakukan untuk menjaga konsistensi interval waktu harian serta memastikan tidak terdapat jeda tanggal dalam deret waktu, sehingga data siap digunakan pada tahap analisis dan pemodelan deret waktu selanjutnya.

4.1.3 Rolling Mean 7

Setelah data kunjungan museum difinalisasi dalam bentuk data harian yang kontinu, tahap selanjutnya adalah melakukan proses *smoothing* data menggunakan metode rolling mean dengan window 7 hari. Penerapan rolling mean bertujuan untuk menghaluskan fluktuasi data harian yang bersifat ekstrem serta mengurangi noise yang dapat mengganggu proses pembelajaran model. Dalam data kunjungan museum, variasi jumlah pengunjung sering kali dipengaruhi oleh faktor harian seperti perbedaan antara hari kerja dan akhir pekan, sehingga pola mingguan menjadi karakteristik yang penting untuk ditangkap oleh model.

Hasil dari proses *rolling mean* 7 hari berupa data kunjungan museum yang telah mengalami penghalusan dan digunakan sebagai dasar pada tahap transformasi dan normalisasi selanjutnya. Tabel hasil rolling mean 7 hari disajikan pada Lampiran 1 yang berisi hasil perhitungan nilai rata-rata bergerak berdasarkan data jumlah pengunjung harian.

4.1.4 Transformasi dan Normalisasi Data

Tahap terakhir dalam preprocessing data adalah transformasi dan normalisasi. Data hasil rolling mean selanjutnya ditransformasikan menggunakan fungsi logaritmik untuk mengurangi tingkat kemencengan (*skewness*) pada distribusi data serta menekan pengaruh nilai ekstrem. Transformasi ini bertujuan agar pola data menjadi lebih seimbang dan lebih mudah dipelajari oleh model deep learning.

Setelah transformasi logaritmik, dilakukan proses normalisasi menggunakan metode standardisasi Z-Score. Normalisasi dilakukan agar data

memiliki skala yang seragam sehingga dapat mempercepat proses konvergensi selama pelatihan model dan meningkatkan stabilitas pembelajaran. Untuk menghindari terjadinya *data leakage*, nilai rata-rata dan standar deviasi yang digunakan dalam proses normalisasi dihitung hanya berdasarkan data training. Tabel data hasil transformasi logaritmik dan normalisasi disajikan untuk menunjukkan perubahan nilai data sebelum dan sesudah dilakukan transformasi dan standardisasi.

Tabel 4. 3 Data Setelah Transformasi dan Normalisasi

Date	Pengunjung Harian	Total Pengunjung Rolling7	Logaritmik	Normalisasi
6/17/2022	14	14	2.708050201	-0.605930074
6/18/2022	2	8	2.197224577	-1.172329254
6/19/2022	3	6.333333333	1.992430165	-1.399403587
...	...	...	...	...
7/18/2025	12	16	2.833213344	-0.467150227
7/19/2025	100	28.71428571	3.391627931	0.152015197
7/20/2025	37	32.14285714	3.500827223	0.273094459

4.2 Hasil *Data Splitting*

Pada penelitian ini, proses pembagian data dilakukan menjadi tiga bagian, yaitu data *training*, *validation*, dan *testing*. Pembagian menjadi tiga subset dilakukan karena model N-BEATS menggunakan mekanisme *early stopping*, sehingga diperlukan data validasi untuk memantau performa model selama proses pelatihan. Data *training* digunakan untuk melatih model, data *validation* digunakan untuk mengevaluasi kinerja model pada setiap epoch dan menentukan kapan pelatihan dihentikan, sedangkan data *testing* digunakan untuk mengukur performa akhir model terhadap data yang belum pernah dilihat sebelumnya.

Total data setelah melalui tahap agregasi harian dan pembentukan deret waktu kontinu berjumlah 1130 data. Pembagian dilakukan berdasarkan urutan waktu (*time-based split*) tanpa pengacakan data, guna menjaga karakteristik deret waktu dan menghindari kebocoran informasi dari masa depan ke masa lalu. Beberapa skenario rasio pembagian data digunakan untuk menganalisis pengaruh proporsi data terhadap performa model. Berikut merupakan hasil pembagian data pada masing-masing rasio:

Tabel 4. 4 Hasil Data Splitting

Rasio (Train:Val:Test)	Σ Data Training	Σ Data Validation	Σ Data Testing
70:15:15	791	170	169
80:10:10	904	113	113
90:05:05	1017	57	56

Berdasarkan Tabel 4.4, pada rasio 70:15:15, data dibagi menjadi 791 data training, 170 data validation, dan 169 data testing. Rasio ini memberikan porsi evaluasi yang cukup besar sehingga proses pemantauan dan pengujian model menjadi lebih representatif.

Pada rasio 80:10:10, jumlah data training meningkat menjadi 904 data, dengan 113 data validation dan 113 data testing. Penambahan data pelatihan bertujuan agar model memiliki lebih banyak pola historis untuk dipelajari, sementara data evaluasi tetap tersedia dalam jumlah yang memadai.

Sementara itu, pada rasio 90:05:05, sebagian besar data digunakan sebagai data training, yaitu sebanyak 1017 data, dengan 57 data validation dan 56 data testing. Rasio ini dipilih untuk menguji apakah peningkatan jumlah data pelatihan secara signifikan dapat meningkatkan kemampuan model dalam menangkap pola

deret waktu, meskipun jumlah data evaluasi menjadi lebih terbatas. Dengan menggunakan beberapa variasi rasio tersebut, penelitian ini dapat menganalisis pengaruh proporsi data pelatihan terhadap performa model serta menentukan pembagian data yang paling optimal untuk prediksi kunjungan museum.

4.3 Hasil Pengujian Model N-Beats

Setelah proses pembagian data dan pelatihan model dilakukan, tahap selanjutnya adalah pengujian model N-BEATS untuk mengevaluasi kemampuan model dalam memprediksi jumlah pengunjung museum. Pengujian ini dilakukan menggunakan beberapa skenario yang dibedakan berdasarkan konfigurasi pembagian data dan pengaturan hyperparameter model. Evaluasi kinerja model dilakukan dengan membandingkan nilai prediksi terhadap data aktual pada data testing menggunakan beberapa metrik evaluasi kesalahan. Hasil dari pengujian ini disajikan secara bertahap pada setiap skenario untuk menganalisis performa model serta menentukan konfigurasi terbaik dalam memprediksi deret waktu pola kunjungan museum.

4.3.1 Hasil Pengujian Skenario 1

Pengujian pada skenario 1 dilakukan dengan pembagian data sebesar 70% sebagai data latih, 15% sebagai data validasi, dan 15% sebagai data uji. Skenario ini bertujuan untuk mengevaluasi kemampuan model N-BEATS dalam memprediksi jumlah kunjungan Museum Mpu Purwa dengan proporsi data latih yang lebih besar, sehingga model diharapkan mampu mempelajari pola historis data secara lebih optimal.

Pada skenario ini dilakukan delapan percobaan dengan variasi hyperparameter yang meliputi panjang *lookback* (14 dan 30), jumlah *blocks* (1 dan 2), serta *learning rate* (0.001 dan 0.0005). Parameter *horizon*, *stacks*, dan *layers* dibuat tetap untuk menjaga konsistensi pengujian. Rincian konfigurasi hyperparameter untuk setiap percobaan disajikan pada tabel berikut.

Tabel 4. 5 Tabel Percobaan Skenario Pengujian 70:15:15

Percobaan	Hyperparameter					
	Lookback	Horizon	Stacks	Blocks	Layers	Learning_Rate
1	14	1	1	1	1	0.001
2	14	1	1	1	1	0.0005
3	14	1	1	2	1	0.001
4	14	1	1	2	1	0.0005
5	30	1	1	1	1	0.001
6	30	1	1	1	1	0.0005
7	30	1	1	2	1	0.001
8	30	1	1	2	1	0.0005

Hasil pengujian setiap konfigurasi model pada skenario pembagian data 70:15:15 dievaluasi menggunakan tiga metrik kesalahan, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Symmetric Mean Absolute Percentage Error (SMAPE). Nilai hasil evaluasi untuk seluruh percobaan disajikan pada tabel berikut.


Tabel 4. 6 Hasil Evaluasi RMSE, MAE, dan SMAPE Skenario Pengujian 1

Percobaan	RMSE	MAE	SMAPE
1	10.21	6.20	25.84%
2	10.77	6.63	26.59%
3	13.43	7.85	28.33%
4	11.45	6.86	26.60%
5	8.21	5.29	27.40%
6	8.71	5.65	28.34%
7	9.27	5.84	27.76%
8	8.17	5.34	27.56%

Berdasarkan tabel hasil evaluasi, nilai kesalahan prediksi pada Skenario Pengujian 1 (70:15:15) menunjukkan variasi yang cukup signifikan antar konfigurasi. Secara umum, penggunaan lookback 30 menghasilkan performa yang lebih baik dibandingkan lookback 14, ditunjukkan oleh nilai RMSE yang menurun dari kisaran di atas 10 menjadi sekitar 8–9, serta MAE yang turun dari kisaran 6–7 menjadi sekitar 5. Hal ini mengindikasikan bahwa data historis yang lebih panjang membantu model dalam menangkap pola kunjungan secara lebih optimal.

Di sisi lain, pengaruh learning rate dan jumlah blocks tidak menunjukkan pola yang sepenuhnya konsisten. Learning rate 0.0005 cenderung memberikan hasil yang lebih stabil, namun tidak selalu lebih baik dibandingkan 0.001. Sementara itu, penambahan jumlah blocks, khususnya pada lookback 14, justru meningkatkan nilai kesalahan, sedangkan pada lookback 30 pengaruhnya tidak terlalu signifikan. Hal ini menunjukkan bahwa peningkatan kompleksitas model perlu diimbangi dengan kombinasi parameter yang tepat agar tidak menyebabkan deviasi prediksi yang lebih besar.

Perbandingan antara nilai aktual dan nilai prediksi pada data uji untuk setiap konfigurasi model ditampilkan dalam grafik aktual vs prediksi. Grafik-grafik tersebut memperlihatkan kemampuan model dalam mengikuti pola tren, fluktuasi, serta lonjakan jumlah pengunjung.



Gambar 4. 1 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 1


Pada Percobaan 1 dengan parameter Lookback 14, Blocks 1, dan Learning Rate 0.001, grafik menunjukkan bahwa pada awal periode pengujian nilai aktual berada pada tingkat yang cukup tinggi, yaitu di atas 100. Setelah itu, nilai tersebut mengalami penurunan yang sangat tajam hingga mendekati kisaran 10–15. Garis prediksi mampu mengikuti arah penurunan tersebut, namun pada beberapa titik masih terlihat perbedaan yang cukup jelas, terutama saat terjadi perubahan yang sangat cepat dari nilai tinggi ke nilai rendah. Pada bagian awal ini, nilai prediksi beberapa kali berada sedikit lebih rendah dibandingkan nilai aktual.

Pada bagian tengah grafik (sekitar indeks 50–100), nilai aktual mulai menunjukkan fluktuasi yang lebih besar dengan beberapa kenaikan dan penurunan yang cukup tajam, termasuk satu puncak yang melebihi 100. Garis prediksi secara umum dapat mengikuti pola perubahan tersebut. Model mampu menangkap kapan terjadi kenaikan maupun penurunan, tetapi besarnya prediksi belum selalu sama dengan nilai aktual. Pada beberapa puncak, nilai prediksi sedikit lebih rendah

daripada nilai aktual, sedangkan pada beberapa titik terendah, nilai prediksi terlihat sedikit lebih tinggi.

Pada bagian akhir periode pengujian, nilai aktual cenderung berada pada kisaran 15–40 dengan perubahan yang tidak terlalu tajam. Pada bagian ini, garis prediksi terlihat lebih dekat dengan garis aktual, meskipun masih terdapat sedikit perbedaan pada beberapa titik, terutama ketika terjadi kenaikan secara tiba-tiba.

Secara kuantitatif, Percobaan 1 menghasilkan nilai RMSE sebesar 10.21, MAE sebesar 6.20, dan SMAPE sebesar 25.84%. Nilai ini menunjukkan bahwa model sudah mampu mengikuti pola umum pergerakan data, tetapi kesalahan prediksi masih cukup besar. Hal ini terutama terjadi pada bagian data yang memiliki perubahan sangat tajam atau lonjakan nilai yang tinggi.



Gambar 4. 2 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 1


Pada Percobaan 2 dengan parameter Lookback 14, Blocks 1, dan Learning Rate 0.0005, grafik menunjukkan bahwa di awal periode nilai aktual sangat tinggi (di atas 100), kemudian turun dengan cepat hingga mendekati kisaran 10–15. Garis prediksi sudah bisa mengikuti arah penurunan ini, tetapi di beberapa titik awal

nilainya masih lebih rendah dibandingkan nilai aktual, terutama saat terjadi penurunan yang sangat cepat.

Pada bagian tengah grafik, nilai aktual mulai naik turun dengan cukup tajam dan terdapat satu lonjakan besar hingga lebih dari 100. Garis prediksi mampu mengikuti pola tersebut, artinya model bisa mengenali kapan terjadi kenaikan dan penurunan. Namun, hasil prediksi belum sepenuhnya tepat. Pada beberapa puncak, nilai prediksi masih sedikit lebih rendah dari nilai aktual. Selain itu, saat terjadi penurunan setelah lonjakan, prediksi terlihat sedikit terlambat mengikuti sehingga tidak langsung mencapai nilai terendah seperti data aktual.

Pada bagian akhir, nilai aktual berada di kisaran 15–40 dengan perubahan yang lebih stabil. Di bagian ini, jarak antara garis prediksi dan aktual terlihat lebih dekat dan konsisten. Meskipun masih ada sedikit perbedaan, terutama saat terjadi kenaikan mendadak, secara umum prediksi sudah cukup mengikuti pola data.

Secara angka, Percobaan 2 menghasilkan RMSE 10.77, MAE 6.63, dan SMAPE 26.59%. Nilai ini sedikit lebih besar dibandingkan Percobaan 1, yang berarti akurasinya sedikit menurun. Hal ini menunjukkan bahwa penggunaan learning rate yang lebih kecil (0.0005) pada percobaan ini belum mampu meningkatkan performa model.



Gambar 4. 3 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 1


Pada Percobaan 3 dengan parameter Lookback 14, Blocks 2, dan Learning Rate 0.001, grafik menunjukkan bahwa di awal periode nilai aktual sangat tinggi (di atas 100), kemudian turun dengan cepat hingga mendekati kisaran 10–15. Garis prediksi sudah mengikuti arah penurunan tersebut, tetapi di beberapa titik awal masih terdapat perbedaan yang cukup besar. Pada bagian ini, nilai prediksi cenderung lebih rendah dibandingkan nilai aktual, terutama saat nilai masih berada di puncak.

Pada bagian tengah grafik, nilai aktual mulai mengalami naik turun yang cukup tajam, termasuk satu lonjakan besar yang kembali mencapai lebih dari 100. Garis prediksi mampu mengikuti pola tersebut, sehingga model sudah bisa mengenali kapan terjadi kenaikan dan penurunan. Namun, hasil prediksi belum sepenuhnya akurat. Pada beberapa puncak, nilai prediksi lebih tinggi dari aktual,

sedangkan pada beberapa titik terendah, nilai prediksi sedikit lebih rendah. Hal ini menunjukkan masih ada selisih yang cukup terlihat di bagian tengah.

Pada bagian akhir, nilai aktual berada pada kisaran 15–40 dengan perubahan yang lebih stabil. Di bagian ini, garis prediksi terlihat lebih dekat dengan garis aktual dan mengikuti pola dengan cukup baik, meskipun masih ada sedikit perbedaan pada beberapa titik.

Secara angka, Percobaan 3 menghasilkan RMSE 13.43, MAE 7.85, dan SMAPE 28.33%, yang merupakan nilai error paling besar dibandingkan percobaan sebelumnya. Hal ini menunjukkan bahwa penambahan jumlah block menjadi 2 pada konfigurasi ini justru belum meningkatkan akurasi model. Secara keseluruhan, model sudah mampu mengikuti pola umum data, tetapi masih kurang tepat dalam memprediksi nilai secara akurat, terutama pada bagian awal dan saat terjadi lonjakan besar di tengah data.



Gambar 4. 4 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 1


Pada Percobaan 4 dengan parameter Lookback 14, Blocks 2, dan Learning Rate 0.0005, grafik menunjukkan bahwa di awal periode nilai aktual sangat tinggi

(di atas 110), kemudian turun dengan cepat hingga mendekati kisaran 10–15. Garis prediksi sudah mengikuti arah penurunan tersebut, tetapi pada beberapa titik awal masih terlihat perbedaan yang cukup jelas. Pada bagian ini, nilai prediksi cenderung lebih rendah dibandingkan nilai aktual, terutama sebelum penurunan besar terjadi. Setelah nilai mulai stabil di kisaran rendah, selisih antara prediksi dan aktual menjadi lebih kecil.

Pada bagian tengah grafik, nilai aktual mengalami naik turun yang cukup tajam dengan beberapa kenaikan dan satu lonjakan besar hingga di atas 100. Garis prediksi mampu mengikuti pola tersebut, sehingga model sudah bisa menangkap arah perubahan data. Namun, hasil prediksi belum sepenuhnya tepat. Pada beberapa puncak, nilai prediksi masih sedikit lebih rendah dari nilai aktual, sedangkan pada beberapa titik terendah, nilai prediksi terlihat sedikit lebih tinggi. Perbedaan ini lebih terlihat saat terjadi perubahan nilai yang cepat.

Pada bagian akhir, nilai aktual berada pada kisaran 15–40 dengan fluktuasi yang lebih stabil. Di bagian ini, garis prediksi terlihat lebih dekat dengan garis aktual dan mengikuti pola dengan cukup konsisten, meskipun masih ada sedikit selisih pada beberapa titik.

Secara angka, Percobaan 4 menghasilkan RMSE 11.45, MAE 6.86, dan SMAPE 26.60%. Hasil ini menunjukkan bahwa performa model masih belum lebih baik dibandingkan Percobaan 1 dan 2. Penambahan jumlah block menjadi 2 dan penggunaan learning rate yang lebih kecil belum memberikan peningkatan akurasi yang signifikan.



Gambar 4. 5 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 1


Pada Percobaan 5 dengan parameter Lookback 30, Blocks 1, dan Learning Rate 0.001, grafik menunjukkan bahwa di awal periode nilai aktual berada di sekitar 80, kemudian turun dengan cepat hingga mendekati angka 10, bahkan sempat sangat rendah di sekitar indeks 30–40. Garis prediksi mampu mengikuti arah penurunan ini dengan cukup baik. Meskipun pada beberapa titik awal prediksi sedikit lebih rendah dari nilai aktual, setelah data berada di kondisi stabil, perbedaan antara keduanya menjadi kecil.

Pada bagian tengah grafik, nilai aktual mulai naik dan mengalami fluktuasi yang cukup besar, termasuk satu lonjakan tinggi yang melebihi 100. Garis prediksi mampu mengikuti pola naik-turun ini dengan cukup baik, termasuk menangkap lonjakan tersebut. Pada beberapa titik, prediksi bisa sedikit lebih tinggi atau lebih rendah dari nilai aktual, tetapi secara umum keduanya terlihat cukup dekat.

Pada bagian akhir, nilai aktual berada di kisaran 15–40 dengan perubahan yang tidak terlalu tajam. Garis prediksi tetap mengikuti pola tersebut dengan jarak

yang relatif kecil, walaupun masih ada sedikit perbedaan pada beberapa titik, terutama saat terjadi kenaikan mendadak.

Secara angka, Percobaan 5 menghasilkan RMSE 8.21, MAE 5.29, dan SMAPE 27.40%. Nilai RMSE dan MAE ini lebih rendah dibandingkan Percobaan 1–4, yang berarti tingkat kesalahan prediksi menjadi lebih kecil. Hal ini menunjukkan bahwa penggunaan lookback yang lebih panjang (30) membantu model dalam memahami pola data dengan lebih baik.




Gambar 4. 6 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 1

Pada Percobaan 6 dengan parameter Lookback 30, Blocks 1, dan Learning Rate 0.0005, grafik menunjukkan bahwa di awal periode nilai aktual berada di sekitar 80, kemudian turun dengan cepat hingga mendekati angka 10, bahkan sempat sangat rendah di sekitar indeks 30–40. Garis prediksi mampu mengikuti arah penurunan ini dengan cukup baik. Pada beberapa titik awal, prediksi terlihat sedikit lebih rendah dari nilai aktual, tetapi setelah data mulai stabil, jarak antara keduanya menjadi kecil.

Pada bagian tengah grafik, nilai aktual mulai meningkat dan mengalami fluktuasi yang cukup tajam, termasuk satu lonjakan besar yang mencapai lebih dari 100. Garis prediksi mampu mengikuti pola naik dan turun ini, termasuk menangkap adanya lonjakan tersebut. Namun, pada titik puncak tertinggi, nilai prediksi masih sedikit di bawah nilai aktual. Selain itu, setelah lonjakan, pada beberapa titik rendah prediksi terlihat sedikit lebih tinggi dari nilai aktual, sehingga masih ada selisih saat terjadi perubahan yang cepat.

Pada bagian akhir, nilai aktual berada di kisaran 15–40 dengan fluktuasi yang tidak terlalu besar. Di bagian ini, garis prediksi mengikuti pola dengan cukup baik dan jaraknya relatif dekat, meskipun masih ada sedikit perbedaan pada beberapa titik.

Secara angka, Percobaan 6 menghasilkan RMSE 8.71, MAE 5.65, dan SMAPE 28.34%. Jika dibandingkan dengan Percobaan 5, nilai error pada percobaan ini sedikit lebih besar. Hal ini menunjukkan bahwa penggunaan learning rate yang lebih kecil (0.0005) pada konfigurasi ini belum mampu meningkatkan akurasi model.




Gambar 4. 7 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 1

Pada Percobaan 7 dengan parameter Lookback 30, Blocks 2, dan Learning Rate 0.001, grafik menunjukkan bahwa di awal periode nilai aktual berada di sekitar 80, kemudian turun dengan cepat hingga mendekati angka 10, bahkan sempat sangat rendah di sekitar indeks 30–40. Garis prediksi mampu mengikuti arah penurunan ini dengan cukup baik. Pada beberapa titik awal, prediksi terlihat sedikit lebih tinggi dari nilai aktual, tetapi setelah memasuki fase nilai rendah, perbedaan antara keduanya menjadi kecil.

Pada bagian tengah grafik, nilai aktual mulai naik dan mengalami fluktuasi yang cukup besar, termasuk beberapa kenaikan dan satu lonjakan tinggi yang melebihi 100 di sekitar indeks 80. Garis prediksi mampu mengikuti pola naik-turun ini dan juga menangkap adanya lonjakan tersebut. Namun, pada beberapa titik terlihat bahwa prediksi kadang sedikit lebih tinggi dari nilai aktual, dan di titik lain bisa sedikit lebih rendah. Perbedaan ini lebih terlihat saat terjadi perubahan nilai yang cepat, sehingga jarak antara kedua garis menjadi tidak selalu sama.

Pada bagian akhir, nilai aktual berada di kisaran 15–40 dengan fluktuasi yang lebih stabil. Di bagian ini, garis prediksi mengikuti pola dengan cukup baik dan terlihat cukup dekat dengan garis aktual, meskipun masih ada sedikit selisih pada beberapa titik.

Secara angka, Percobaan 7 menghasilkan RMSE 9.27, MAE 5.84, dan SMAPE 27.76%. Hasil ini menunjukkan bahwa performa model sudah lebih baik dibandingkan percobaan dengan lookback 14 (Percobaan 1–4), tetapi masih sedikit kurang baik dibandingkan Percobaan 5 yang memiliki error paling kecil.



Gambar 4. 8 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 1

Pada awal grafik, nilai aktual berada di sekitar 80, lalu turun dengan cepat hingga mendekati angka 10, bahkan sempat sangat rendah di sekitar indeks 30–40. Garis prediksi mampu mengikuti arah penurunan ini dengan cukup baik. Pada beberapa titik awal, prediksi terlihat sedikit lebih tinggi dari nilai aktual, tetapi setelah data mulai stabil, jarak antara keduanya menjadi kecil.

Pada bagian tengah grafik, nilai aktual mulai naik dan mengalami fluktuasi yang cukup tajam, termasuk satu lonjakan besar yang melebihi 100 di sekitar indeks 80. Garis prediksi mampu mengikuti pola naik-turun ini dan juga menangkap adanya lonjakan tersebut. Namun, pada titik puncak tertinggi, nilai prediksi masih berada di bawah nilai aktual. Selain itu, setelah lonjakan, pada beberapa titik rendah prediksi terlihat sedikit lebih tinggi dari nilai aktual, sehingga masih ada selisih saat terjadi perubahan yang cepat.

Pada bagian akhir, nilai aktual berada di kisaran 15–40 dengan fluktuasi yang lebih stabil. Di bagian ini, garis prediksi mengikuti pola dengan cukup baik

dan terlihat cukup dekat dengan garis aktual, meskipun masih ada sedikit perbedaan pada beberapa titik.

Percobaan 8 menghasilkan RMSE 8,17, MAE 5,34, dan SMAPE 27,56%. Nilai RMSE dan MAE ini tergolong rendah dibandingkan sebagian besar percobaan lainnya, yang menunjukkan bahwa kesalahan prediksi cukup kecil. Namun, nilai SMAPE yang masih di atas 27% menunjukkan bahwa kesalahan relatif masih cukup terlihat, terutama saat terjadi lonjakan besar.

Secara keseluruhan, hasil Skenario Pengujian 1 menunjukkan bahwa variasi parameter lookback, jumlah block, dan learning rate memberikan pengaruh yang signifikan terhadap tingkat kesalahan prediksi, baik secara visual maupun kuantitatif. Nilai error yang dihasilkan merepresentasikan besarnya deviasi antara prediksi dan data aktual, sehingga semakin tinggi nilai RMSE, MAE, dan SMAPE menunjukkan semakin besar ketidaksesuaian model terhadap pola data uji.

Pada Percobaan 1 hingga 4 (lookback 14), grafik prediksi secara umum sudah mampu mengikuti arah tren utama data. Namun, saat terjadi perubahan yang sangat tajam, terutama pada lonjakan besar di bagian tengah data uji, terlihat perbedaan yang cukup jelas antara nilai aktual dan prediksi. Perbedaan ini muncul karena hasil prediksi belum mampu menyamai tinggi atau rendahnya nilai aktual secara tepat. Hal tersebut juga terlihat dari nilai RMSE yang berada di atas 10 dan SMAPE di atas 25%, yang menunjukkan bahwa tingkat kesalahan masih cukup besar. Di antara percobaan tersebut, Percobaan 3 menghasilkan error tertinggi (RMSE 13,43; MAE 7,85; SMAPE 28,33%), sehingga dapat disimpulkan bahwa

model masih kesulitan dalam mengikuti perubahan data yang cepat ketika menggunakan lookback window yang lebih pendek.

Memasuki Percobaan 5 hingga 8 (lookback 30), pola prediksi terlihat lebih stabil dan lebih mendekati pergerakan aktual, khususnya pada fase fluktuasi menengah hingga akhir periode pengujian. Deviasi amplitudo pada titik ekstrem cenderung lebih kecil dibandingkan kelompok lookback 14. Secara kuantitatif, Percobaan 5 menunjukkan akurasi tertinggi dalam Skenario Pengujian 1 dengan nilai RMSE sebesar 8,21 dan MAE sebesar 5,29, yang merupakan nilai terendah di antara seluruh percobaan. Hal ini sejalan dengan visualisasi grafik yang menunjukkan jarak antar garis yang relatif lebih rapat, termasuk pada fase kenaikan signifikan di bagian tengah. Dapat disimpulkan bahwa peningkatan lookback window menjadi 30 dengan 1 block dan learning rate 0,001 memberikan performa paling optimal pada Skenario Pengujian 1.

4.3.2 Hasil Pengujian Skenario 2

Pengujian pada skenario 2 dilakukan dengan pembagian data sebesar 80% sebagai data latih, 10% sebagai data validasi, dan 10% sebagai data uji. Proporsi data latih yang lebih besar pada skenario ini bertujuan untuk memberikan kesempatan yang lebih luas bagi model N-BEATS dalam mempelajari pola historis kunjungan Museum Mpu Purwa, sehingga diharapkan dapat menghasilkan prediksi yang lebih stabil.

Pada skenario ini dilakukan delapan percobaan dengan variasi hyperparameter yang meliputi panjang lookback (14 dan 30), jumlah blocks (1 dan

2), serta learning rate (0.001 dan 0.0005). Parameter lain seperti horizon, stacks, dan layers ditetapkan tetap untuk menjaga konsistensi pengujian. Rincian konfigurasi hyperparameter pada setiap percobaan disajikan pada Tabel Skenario Pengujian 80:10:10 berikut.

Tabel 4. 7 Tabel Percobaan Skenario Pengujian 80:10:10

Percobaan	Hyperparameter					
	Lookback	Horizon	Stacks	Blocks	Layers	Learning Rate
1	14	1	1	1	1	0.001
2	14	1	1	1	1	0.0005
3	14	1	1	2	1	0.001
4	14	1	1	2	1	0.0005
5	30	1	1	1	1	0.001
6	30	1	1	1	1	0.0005
7	30	1	1	2	1	0.001
8	30	1	1	2	1	0.0005

Tabel skenario pengujian menunjukkan bahwa seluruh percobaan disusun secara sistematis untuk mengamati pengaruh variasi panjang data historis (*lookback*), kompleksitas model melalui jumlah *blocks*, serta laju pembelajaran (*learning rate*) terhadap kinerja prediksi model. Dengan struktur pengujian yang seragam, perbedaan hasil yang diperoleh dapat dikaitkan langsung dengan perubahan hyperparameter yang digunakan.


Tabel 4. 8 Hasil Evaluasi RMSE, MAE, dan SMAPE Skenario Pengujian 2

Percobaan	RMSE	MAE	SMAPE
1	9.72	6.18	17.81%
2	9.57	5.96	17.32%
3	9.81	6.37	17.47%
4	9.97	6.34	18.12%
5	9.31	6.26	18.46%
6	9.11	6.09	18.52%
7	10.09	6.37	18.61%
8	9.28	6.21	18.88%

Berdasarkan tabel hasil evaluasi, nilai kesalahan prediksi pada skenario 80:10:10 berada pada rentang yang relatif berdekatan untuk seluruh konfigurasi. Secara umum, konfigurasi dengan lookback 30 cenderung menghasilkan nilai RMSE yang lebih rendah dibandingkan dengan lookback 14, yang menunjukkan bahwa penggunaan data historis yang lebih panjang membantu model dalam menangkap pola kunjungan jangka menengah.

Variasi learning rate 0.0005 menunjukkan kecenderungan menghasilkan kesalahan yang lebih stabil dibandingkan learning rate 0.001, terutama pada konfigurasi lookback 30. Sementara itu, penambahan jumlah *blocks* meningkatkan sensitivitas model terhadap perubahan data, namun pada beberapa konfigurasi justru diikuti oleh peningkatan kesalahan akibat prediksi yang terlalu tinggi atau terlalu rendah pada titik-titik tertentu.

Untuk memberikan gambaran yang lebih jelas mengenai perilaku hasil prediksi pada setiap konfigurasi, pembahasan selanjutnya disajikan melalui grafik perbandingan antara nilai aktual dan nilai prediksi pada data uji. Grafik tersebut digunakan untuk menunjukkan kesesuaian pola, arah perubahan, serta respons model terhadap fluktuasi jumlah kunjungan pada masing-masing percobaan.



Gambar 4. 9 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 2


Percobaan 1 dengan parameter lookback 14 dan learning rate 0.001, grafik menunjukkan bahwa model sudah mampu mengikuti pola umum pergerakan jumlah pengunjung. Garis prediksi (putus-putus) terlihat cukup searah dengan garis aktual, baik saat terjadi kenaikan maupun penurunan.

Bagian awal hingga tengah grafik, terlihat bahwa nilai aktual mengalami beberapa kenaikan dan penurunan, termasuk satu lonjakan tinggi di sekitar indeks 35–40 yang mencapai lebih dari 100. Model mampu menangkap adanya lonjakan ini, namun pada beberapa titik nilai prediksi tidak selalu sama dengan nilai aktual. Kadang prediksi sedikit lebih tinggi, dan di titik lain sedikit lebih rendah. Selain itu, garis prediksi terlihat lebih “naik turun” (lebih tajam) dibandingkan garis aktual.

Pada bagian setelah lonjakan, nilai aktual cenderung menurun dan kemudian bergerak di kisaran yang lebih rendah. Di bagian ini, prediksi masih mengikuti pola yang sama, tetapi tetap terdapat sedikit perbedaan, terutama saat terjadi perubahan yang cukup cepat. Sementara itu, pada bagian akhir grafik, nilai aktual berada di kisaran sekitar 15–40 dengan fluktuasi yang tidak terlalu besar. Di

bagian ini, jarak antara garis prediksi dan aktual terlihat lebih dekat dan stabil dibandingkan bagian sebelumnya.

Secara kuantitatif, Percobaan 1 menghasilkan RMSE 9.72, MAE 6.18, dan SMAPE 17.81%. Nilai ini menunjukkan bahwa masih terdapat selisih antara hasil prediksi dan data aktual, terutama pada titik dengan perubahan nilai yang tinggi. Model mampu mengikuti arah naik dan turun data, tetapi belum mampu memperkirakan nilai secara tepat pada beberapa titik, khususnya saat terjadi lonjakan. Perbedaan ini terlihat dari nilai prediksi yang tidak selalu sama dengan nilai aktual, baik pada puncak maupun saat penurunan.




Gambar 4. 10 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 2

Pada grafik terlihat bahwa garis prediksi (oranye putus-putus) sudah mengikuti arah pergerakan data aktual (biru), baik saat terjadi kenaikan maupun penurunan. Pada bagian awal hingga tengah, pola naik dan turun dapat diikuti dengan cukup baik. Namun, pada beberapa titik masih terlihat perbedaan yang cukup jelas. Misalnya, pada puncak tertinggi di sekitar indeks 35–40, nilai prediksi tidak mencapai nilai aktual (lebih rendah dari puncak sebenarnya). Setelah itu, pada

beberapa bagian, nilai prediksi kadang sedikit lebih tinggi atau lebih rendah dari nilai aktual, sehingga selisihnya terlihat bergantian.

Secara angka, percobaan ini menghasilkan RMSE 9.57, MAE 5.96, dan SMAPE 17.32%, yang merupakan hasil terbaik pada skenario ini. Nilai MAE yang kecil menunjukkan bahwa rata-rata selisih antara prediksi dan aktual tidak terlalu besar. Selain itu, nilai RMSE yang tidak jauh dari MAE menunjukkan bahwa tidak ada kesalahan yang sangat besar, meskipun pada beberapa titik puncak masih terdapat perbedaan. Nilai SMAPE sebesar 17.32% menunjukkan bahwa secara persentase, kesalahan prediksi masih ada, tetapi tidak terlalu tinggi jika dibandingkan dengan fluktuasi data yang cukup tajam.




Gambar 4. 11 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 2

Pada Percobaan 3 dengan parameter lookback 14, block 2, dan learning rate 0.001, grafik menunjukkan bahwa model sudah mampu mengikuti arah pergerakan data aktual. Pola naik dan turun pada data dapat diikuti dengan cukup baik, terutama pada bagian awal hingga pertengahan. Namun, pada beberapa titik terlihat perbedaan antara nilai prediksi dan aktual. Pada bagian yang mengalami kenaikan

tajam, termasuk di sekitar puncak tertinggi, nilai prediksi cenderung lebih tinggi dari nilai aktual. Selain itu, perubahan pada garis prediksi terlihat lebih tajam dibandingkan data aktual, sehingga grafik prediksi tampak lebih naik-turun.

Perbedaan ini menunjukkan bahwa hasil prediksi belum selalu sesuai dengan nilai aktual, terutama saat terjadi perubahan yang cepat. Pada beberapa titik, prediksi bisa lebih tinggi, dan pada titik lain bisa lebih rendah, sehingga selisih antara keduanya masih terlihat.

Secara angka, Percobaan 3 menghasilkan RMSE 9.81, MAE 6.37, dan SMAPE 17.47%. Nilai ini menunjukkan bahwa masih terdapat selisih antara hasil prediksi dan data aktual, terutama pada titik dengan perubahan yang besar. Model dapat mengikuti pola data, tetapi belum mampu memperkirakan nilai dengan tepat pada beberapa titik, terutama saat terjadi kenaikan atau penurunan yang tajam.




Gambar 4. 12 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 2

Pada Percobaan 4 dengan parameter lookback 14, block 2, dan learning rate 0.0005, grafik menunjukkan bahwa model mampu mengikuti arah umum pergerakan data, namun terdapat beberapa perbedaan yang cukup jelas pada

beberapa bagian. Pada bagian awal, terlihat bahwa selisih antara nilai prediksi dan aktual cukup besar. Garis prediksi beberapa kali berada jauh di atas atau di bawah nilai aktual, sehingga belum dapat mengikuti nilai dengan baik pada fase ini.

Memasuki bagian tengah, terdapat lonjakan besar di sekitar indeks 35–40. Pada titik ini, nilai prediksi mampu menangkap adanya lonjakan dan mencapai nilai yang mendekati puncak aktual. Namun, setelah lonjakan tersebut, pada fase penurunan terlihat bahwa prediksi tidak selalu mengikuti nilai aktual secara tepat. Pada beberapa titik, prediksi sedikit lebih tinggi, dan pada titik lain sedikit lebih rendah. Pada bagian selanjutnya, pola naik dan turun masih dapat diikuti oleh model, tetapi selisih antara prediksi dan aktual tetap terlihat, terutama saat terjadi perubahan nilai yang cukup cepat. Pada bagian akhir, nilai aktual cenderung lebih stabil, dan garis prediksi terlihat lebih dekat dengan garis aktual, meskipun masih terdapat perbedaan kecil di beberapa titik.

Secara angka, Percobaan 4 menghasilkan RMSE 9.97, MAE 6.34, dan SMAPE 18.12%. Nilai ini menunjukkan bahwa masih terdapat selisih antara hasil prediksi dan data aktual, dengan kesalahan yang cukup terlihat pada beberapa bagian, terutama di awal dan saat terjadi perubahan yang signifikan.




Gambar 4. 13 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 2

Pada Percobaan 5 dengan parameter lookback 30, block 1, dan learning rate 0.001, grafik menunjukkan bahwa garis prediksi sudah mengikuti arah pergerakan data aktual dengan cukup baik. Dibandingkan dengan lookback 14, pola prediksi terlihat lebih stabil dan lebih mengikuti bentuk data, terutama pada bagian awal hingga pertengahan.

Pada bagian awal, garis prediksi cukup dekat dengan nilai aktual, meskipun pada beberapa titik masih terdapat selisih, baik sedikit lebih tinggi maupun lebih rendah. Namun, perbedaannya tidak terlalu besar dan pola pergerakan masih searah. Memasuki bagian tengah, terlihat beberapa kenaikan dan satu puncak yang cukup tinggi. Pada bagian ini, garis prediksi mampu mengikuti pola tersebut, tetapi pada beberapa titik nilai prediksi terlihat sedikit lebih tinggi dari nilai aktual. Setelah puncak, saat terjadi penurunan, garis prediksi tidak selalu mengikuti penurunan secara tepat. Pada beberapa titik, penurunan pada prediksi terlihat lebih lambat dibandingkan data aktual.

Pada bagian selanjutnya, fluktuasi masih dapat diikuti dengan cukup baik, tetapi tetap terdapat selisih di beberapa titik, terutama saat terjadi perubahan nilai yang cukup cepat. Selanjutnya, pada bagian akhir, nilai aktual cenderung lebih stabil pada kisaran tertentu, dan garis prediksi mengikuti pola tersebut dengan cukup dekat, meskipun masih terdapat perbedaan kecil di beberapa titik.

Secara angka, Percobaan 5 menghasilkan RMSE 9.31, MAE 6.26, dan SMAPE 18.46%. Nilai ini menunjukkan bahwa masih terdapat selisih antara hasil prediksi dan data aktual. Meskipun beberapa kesalahan besar berkurang, perbedaan tetap terlihat pada beberapa bagian, terutama saat terjadi perubahan nilai.




Gambar 4. 14 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 2

Pada Percobaan 6 dengan parameter lookback 30, block 1, dan learning rate 0.0005, grafik menunjukkan bahwa garis prediksi mampu mengikuti arah umum pergerakan data aktual. Pola naik dan turun masih dapat diikuti dengan cukup baik, terutama pada bagian awal hingga pertengahan.

Pada bagian awal, terlihat bahwa selisih antara nilai prediksi dan aktual cukup jelas. Pada beberapa titik, prediksi berada di bawah nilai aktual, kemudian

pada titik lain bisa berada di atas, sehingga perbedaan terlihat cukup sering terjadi meskipun arah pergerakan tetap sama. Memasuki bagian tengah, terdapat beberapa kenaikan dan satu puncak tinggi di sekitar indeks 20–25. Pada titik ini, nilai prediksi mampu mencapai puncak yang mendekati nilai aktual. Namun, sebelum dan sesudah puncak tersebut, terlihat bahwa prediksi tidak selalu mengikuti perubahan nilai secara tepat. Pada beberapa bagian, prediksi tampak lebih tinggi dari aktual, dan pada bagian lain sedikit lebih rendah. Setelah puncak, saat terjadi penurunan tajam, garis prediksi tidak langsung mengikuti penurunan sedalam data aktual. Hal ini menyebabkan selisih yang cukup terlihat pada fase penurunan tersebut. Pada bagian akhir, nilai aktual bergerak lebih stabil pada kisaran tertentu. Garis prediksi mengikuti pola ini dengan cukup baik dan jaraknya relatif dekat, meskipun masih terdapat selisih kecil di beberapa titik.

Secara angka, Percobaan 6 menghasilkan RMSE 9.11, MAE 6.09, dan SMAPE 18.52%. Nilai ini menunjukkan bahwa masih terdapat selisih antara hasil prediksi dan data aktual, dengan beberapa perbedaan yang cukup terlihat terutama pada bagian awal dan setelah puncak.




Gambar 4. 15 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 2

Pada Percobaan 7 dengan parameter lookback 30, block 2, dan learning rate 0.001, grafik menunjukkan bahwa garis prediksi masih dapat mengikuti arah umum pergerakan data aktual. Pola naik dan turun terlihat searah, terutama pada bagian awal hingga pertengahan.

Pada bagian awal, terlihat bahwa nilai prediksi sudah mengikuti pola perubahan data, namun masih terdapat selisih yang cukup jelas di beberapa titik. Prediksi kadang berada di atas nilai aktual, dan pada titik lain berada di bawahnya. Memasuki bagian tengah, terdapat kenaikan yang cukup tinggi hingga mencapai puncak di sekitar indeks 20–25. Pada titik ini, nilai prediksi mampu menangkap adanya puncak, tetapi tidak selalu sama dengan nilai aktual. Pada beberapa bagian sebelum dan sesudah puncak, prediksi terlihat lebih tinggi dari aktual, sehingga selisih terlihat cukup jelas. Setelah puncak, saat terjadi penurunan, garis prediksi tidak selalu mengikuti penurunan secara tepat. Pada beberapa titik, prediksi masih berada di atas nilai aktual ketika nilai aktual sudah turun, sehingga terlihat adanya perbedaan pada fase transisi ini. Pada bagian tengah hingga akhir, fluktuasi masih dapat diikuti, tetapi selisih antara prediksi dan aktual tetap terlihat. Pada beberapa titik, prediksi lebih tinggi, dan pada titik lain lebih rendah, sehingga jarak antar garis tidak konsisten.

Secara kuantitatif, Percobaan 7 menghasilkan RMSE 10.09, MAE 6.37, dan SMAPE 18.61%. Nilai ini menunjukkan bahwa masih terdapat selisih yang cukup besar antara hasil prediksi dan data aktual, terutama pada bagian dengan perubahan nilai yang signifikan.



Gambar 4. 16 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 2

Pada Percobaan 8 (lookback 30, block 2, learning rate 0.0005), grafik menunjukkan bahwa garis prediksi sudah mengikuti arah pergerakan data aktual pada sebagian besar waktu, tetapi masih terdapat beberapa perbedaan yang cukup terlihat di beberapa bagian.

Di bagian awal, perbedaan antara prediksi dan aktual terlihat cukup jelas. Pada beberapa titik pertama, nilai prediksi cenderung lebih rendah dibandingkan nilai aktual, sehingga jarak antar garis cukup besar. Namun setelah beberapa waktu, prediksi mulai mendekati pola aktual dan bergerak lebih searah. Memasuki bagian pertengahan, terlihat adanya kenaikan hingga puncak tertinggi. Pada bagian ini, garis prediksi mampu mengikuti pola kenaikan tersebut, tetapi pada titik puncak, nilai prediksi sedikit lebih tinggi dari nilai aktual. Setelah itu, saat terjadi penurunan, prediksi tidak selalu langsung mengikuti penurunan aktual secara tepat, sehingga masih terlihat selisih pada beberapa titik. Pada bagian setelah puncak hingga akhir, pola data cenderung lebih stabil dengan fluktuasi sedang. Di bagian ini, garis prediksi terlihat lebih dekat dengan garis aktual dibandingkan

sebelumnya. Meskipun begitu, masih ada beberapa titik di mana prediksi sedikit lebih tinggi atau lebih rendah, terutama saat terjadi perubahan nilai yang cukup cepat.

Secara umum, grafik Percobaan 8 menunjukkan kestabilan prediksi yang lebih baik dibandingkan Percobaan, yang mengindikasikan bahwa kombinasi *block* 2 dengan *learning rate* 0.0005 memberikan proses pembelajaran yang lebih stabil. Penyesuaian *learning rate* yang lebih kecil berkontribusi terhadap stabilitas model, sehingga kesalahan prediksi pada titik-titik ekstrem dapat diminimalkan dan pola pergerakan data dapat direpresentasikan dengan lebih seimbang.

Secara keseluruhan, hasil pada Skenario Pengujian 2 (80:10:10) menunjukkan bahwa semua percobaan menghasilkan nilai error yang tidak jauh berbeda. Nilai MAE berada pada rentang 5.96 hingga 6.37 dan RMSE berada pada rentang 9.11 hingga 10.09, sedangkan SMAPE berada pada kisaran 17.32% hingga 18.88%, sehingga perbedaan performa antar konfigurasi tidak terlalu besar. Pada lookback 14 (Percobaan 1–4), model sudah mampu mengikuti arah naik dan turun data. Namun, pada beberapa titik dengan perubahan nilai yang besar, seperti saat terjadi kenaikan tinggi atau penurunan tajam, hasil prediksi masih berbeda cukup jelas dari data aktual. Hal ini terlihat dari nilai error yang cenderung lebih tinggi dibandingkan beberapa percobaan lain. Di antara kelompok ini, Percobaan 4 memiliki error yang paling besar, sedangkan Percobaan 3 menunjukkan perubahan prediksi yang lebih tidak stabil pada beberapa bagian.

Pada lookback 30 (Percobaan 5–8), hasil prediksi terlihat lebih stabil dalam mengikuti pola data, terutama setelah bagian dengan lonjakan besar. Nilai RMSE

pada beberapa percobaan juga lebih kecil dibandingkan sebagian besar percobaan lookback 14, misalnya pada Percobaan 6 yang memiliki RMSE paling rendah yaitu 9.11. Namun, jika dilihat dari SMAPE, nilainya tidak lebih baik dan bahkan sedikit lebih tinggi, yang berarti secara persentase selisih prediksi terhadap data masih cukup terlihat. Ketika jumlah block ditambah pada Percobaan 7, grafik prediksi menjadi lebih tidak stabil dan perbedaan dengan data aktual lebih sering muncul, terutama pada titik perubahan yang besar.

Berdasarkan seluruh hasil tersebut, Percobaan 2 (lookback 14, block 1, learning rate 0.0005) menghasilkan nilai error paling kecil, yaitu RMSE 9.57, MAE 5.96, dan SMAPE 17.32%. Grafik pada percobaan ini menunjukkan bahwa prediksi mengikuti pola data dengan cukup konsisten dan tidak menunjukkan selisih yang terlalu besar pada sebagian besar titik. Oleh karena itu, pada pembagian data 80:10:10, konfigurasi ini memberikan hasil yang paling mendekati data aktual dibandingkan percobaan lainnya.

4.3.3 Hasil Pengujian Skenario 3

Pengujian pada skenario 3 dilakukan dengan pembagian data sebesar 90% sebagai data latih, 5% sebagai data validasi, dan 5% sebagai data uji. Proporsi ini memberikan porsi data latih yang lebih besar dibandingkan skenario sebelumnya, sehingga model memiliki lebih banyak data historis untuk mempelajari pola deret waktu.

Pada skenario ini dilakukan delapan percobaan dengan variasi hyperparameter yang meliputi panjang lookback (14 dan 30), jumlah blocks (1 dan 2), serta learning rate (0.001 dan 0.0005). Parameter horizon, stacks, dan layers

dibuat tetap untuk menjaga konsistensi antarpercobaan. Rincian konfigurasi setiap percobaan pada skenario pengujian 90:05:05 disajikan pada tabel berikut.

Tabel 4. 9 Tabel Percobaan Skenario Pengujian 90:05:05

Percobaan	Hyperparameter					
	Lookback	Horizon	Stacks	Blocks	Layers	Learning_Rate
1	14	1	1	1	1	0.001
2	14	1	1	1	1	0.0005
3	14	1	1	2	1	0.001
4	14	1	1	2	1	0.0005
5	30	1	1	1	1	0.001
6	30	1	1	1	1	0.0005
7	30	1	1	2	1	0.001
8	30	1	1	2	1	0.0005

Berdasarkan Tabel 4.9, terdapat delapan kombinasi parameter yang diuji untuk melihat pengaruh variasi panjang *lookback*, jumlah *blocks*, dan *learning rate* terhadap kinerja model N-BEATS. Setiap konfigurasi kemudian dievaluasi menggunakan tiga metrik kesalahan, yaitu MAE, RMSE, dan SMAPE. Hasil perhitungan nilai kesalahan untuk masing-masing percobaan ditampilkan pada Tabel 4.10.


Tabel 4. 10 Hasil Evaluasi RMSE, MAE, SMAPE Skenario Pengujian 3

Percobaan	RMSE	MAE	SMAPE
1	6.13	3.62	13.48%
2	6.55	4.00	14.91%
3	6.19	3.88	14.45%
4	6.29	3.84	13.99%
5	4.93	3.32	13.56%
6	4.78	3.14	12.57%
7	4.81	3.11	12.30%
8	5.17	3.44	13.91%

Berdasarkan Tabel 4.10, nilai kesalahan prediksi pada skenario 90:05:05 berada pada rentang yang lebih rendah dan lebih konsisten dibandingkan skenario sebelumnya. Konfigurasi dengan lookback 30 (Percobaan 5–8) menghasilkan performa yang lebih baik dibandingkan lookback 14 (Percobaan 1–4), ditunjukkan oleh penurunan RMSE dari kisaran 6,13–6,55 menjadi 4,78–5,17, serta MAE dari 3,62–4,00 menjadi 3,11–3,44. Hal ini menunjukkan bahwa penggunaan data historis yang lebih panjang mampu meningkatkan kemampuan model dalam menangkap pola kunjungan sehingga kesalahan prediksi dapat ditekan.

Jika ditinjau lebih rinci berdasarkan kombinasi hyperparameter pada Tabel 4.9, pengaruh learning rate dan jumlah blocks tidak sepenuhnya konsisten. Pada lookback 14, learning rate 0.001 (Percobaan 1) justru menghasilkan error lebih rendah dibandingkan 0.0005 (Percobaan 2), sedangkan pada lookback 30, learning rate 0.0005 (Percobaan 6) memberikan hasil terbaik dengan RMSE 4,78 dan MAE 3,14. Sementara itu, penambahan blocks dari 1 menjadi 2 tidak selalu meningkatkan performa; pada beberapa konfigurasi (misalnya Percobaan 7) menghasilkan MAE terendah sebesar 3,11, namun pada konfigurasi lain (Percobaan 8) justru meningkatkan kesalahan. Hal ini menunjukkan bahwa performa model sangat dipengaruhi oleh interaksi antar hyperparameter, bukan oleh satu parameter saja.

Untuk melihat bagaimana pola prediksi mengikuti data aktual pada masing-masing konfigurasi, analisis selanjutnya disajikan melalui grafik perbandingan nilai aktual dan prediksi pada data uji untuk percobaan 1 sampai dengan percobaan 8.




Gambar 4. 17 Grafik Aktual dan Prediksi Percobaan 1 Skenario Pengujian 3

Pada Percobaan 1 dengan konfigurasi lookback 14, horizon 1, stack 1, block 1, layer 1, dan learning rate 0.001, grafik menunjukkan bahwa model N-BEATS sudah dapat mengikuti arah pola data, tetapi belum sepenuhnya tepat dalam memprediksi besar perubahannya. Pada bagian awal data uji, terlihat perbedaan yang cukup jelas antara nilai aktual dan prediksi. Prediksi cenderung lebih rendah dari nilai aktual dan belum stabil dalam mengikuti perubahan yang terjadi di awal. Saat terjadi kenaikan tajam, prediksi ikut naik, namun tidak selalu sesuai, kadang terlalu tinggi atau sedikit terlambat mengikuti pola sebenarnya.

Pada bagian Tengah grafik, prediksi mulai lebih mengikuti pola naik dan turun dari data aktual. Meskipun arah pergerakannya sudah sesuai, perbedaan nilai masih terlihat. Saat data aktual turun tajam, prediksi hanya turun sedikit. Begitu juga saat data naik, prediksi tidak setinggi nilai aktual. Hal ini menunjukkan bahwa model cenderung menghasilkan prediksi yang lebih halus, sehingga perubahan yang sangat tinggi atau rendah tidak tertangkap dengan baik. Sedangkan pada bagian akhir, hasil prediksi terlihat semakin mendekati data aktual, terutama ketika

pola data lebih stabil. Namun, saat terjadi perubahan yang cukup cepat, prediksi masih sedikit tertinggal atau tidak sama dengan nilai aktual.

Secara kuantitatif, hasil evaluasi menunjukkan nilai RMSE sebesar 6.13 yang menandakan adanya kesalahan prediksi yang cukup terasa pada beberapa titik dengan selisih besar. Nilai MAE sebesar 3.62 menunjukkan bahwa secara rata-rata kesalahan absolut per titik relatif lebih kecil, sehingga sebagian besar prediksi masih berada cukup dekat dengan nilai aktual. Nilai SMAPE sebesar 13.48% mengindikasikan bahwa kesalahan relatif terhadap skala data masih berada pada tingkat menengah, dengan kontribusi utama berasal dari titik-titik awal dan perubahan nilai yang tajam.



Gambar 4. 18 Grafik Aktual dan Prediksi Percobaan 2 Skenario Pengujian 3


Pada Percobaan 2 dengan konfigurasi lookback 14, horizon 1, stack 1, block 1, layer 1, dan learning rate 0.0005, grafik menunjukkan bahwa model N-BEATS sudah mampu mengikuti arah naik dan turun data, namun hasil prediksi masih sering berbeda dari nilai aktual. Pada bagian awal periode pengujian, nilai prediksi terlihat sedikit lebih rendah dari nilai aktual pada titik pertama, kemudian

meningkat cukup cepat dan pada beberapa titik justru berada di atas nilai aktual. Hal ini menunjukkan bahwa model merespons kenaikan awal dengan cukup kuat, tetapi belum tepat dalam menyesuaikan besarnya nilai.

Pada bagian tengah, pola prediksi sudah mengikuti arah pergerakan data aktual, baik saat naik maupun turun. Namun, perbedaan nilai masih cukup jelas. Saat data aktual meningkat, prediksi sering kali lebih tinggi dari nilai sebenarnya. Sebaliknya, saat terjadi penurunan yang tajam, prediksi tidak turun sedalam data aktual. Kondisi ini membuat garis prediksi terlihat lebih “bergelombang” dan kadang tidak seimbang dengan perubahan pada data asli. Pada bagian akhir, prediksi masih mengikuti pola data yang relatif stabil, tetapi selisih antara prediksi dan aktual tetap muncul pada beberapa titik. Terutama saat terjadi perubahan mendadak, prediksi terlihat sedikit terlambat atau tidak sama dengan nilai aktual. Secara kuantitatif, Percobaan 2 menghasilkan nilai RMSE sebesar 6.55, yang merupakan nilai tertinggi dibandingkan percobaan lain pada skenario ini. Nilai tersebut mengindikasikan adanya beberapa titik dengan kesalahan prediksi yang cukup besar, sesuai dengan deviasi visual yang tampak pada awal dan pertengahan grafik. Nilai MAE sebesar 4.00 menunjukkan bahwa rata-rata selisih absolut prediksi terhadap nilai aktual lebih besar dibandingkan Percobaan 1. Nilai SMAPE sebesar 14.91% mencerminkan tingkat kesalahan relatif yang juga paling tinggi, menandakan bahwa ketidaktepatan prediksi terjadi secara konsisten pada beberapa segmen data uji.

Berdasarkan analisis visual dan kuantitatif, Percobaan 2 pada skenario pengujian 90:05:05 mampu mengikuti pola umum data kunjungan museum dengan

cukup baik, tetapi menghasilkan deviasi yang lebih besar baik pada puncak maupun lembah grafik. Penggunaan *learning rate* 0.0005 pada konfigurasi ini menyebabkan model menghasilkan prediksi yang kurang stabil dalam merepresentasikan besarnya perubahan nilai, sehingga performa keseluruhan berada di bawah Percobaan 1 pada skenario yang sama.



Gambar 4. 19 Grafik Aktual dan Prediksi Percobaan 3 Skenario Pengujian 3

Pada Percobaan 3 dengan konfigurasi lookback 14, horizon 1, stack 1, block 2, layer 1, dan learning rate 0.001, grafik menunjukkan bahwa model N-BEATS sudah mampu mengikuti arah naik dan turun data dengan cukup baik. Pada bagian awal periode pengujian, nilai prediksi terlihat mendekati nilai aktual, meskipun pada beberapa titik masih sedikit lebih rendah sebelum kemudian naik mengikuti pola kenaikan data. Hal ini menunjukkan bahwa model cukup cepat menyesuaikan diri terhadap pola awal, meskipun belum sepenuhnya tepat dalam menentukan nilainya.


Pada bagian awal hingga pertengahan, perbedaan antara prediksi dan aktual mulai terlihat lebih jelas. Saat terjadi kenaikan, nilai prediksi cenderung sedikit

lebih tinggi dari nilai aktual. Sebaliknya, saat terjadi penurunan, prediksi bisa turun lebih dalam atau tidak sama dengan nilai aktual. Pola ini menunjukkan bahwa prediksi menjadi lebih sensitif terhadap perubahan, sehingga garis prediksi terlihat lebih tajam dibandingkan data aktual. Memasuki bagian pertengahan hingga akhir, model masih mampu mengikuti arah tren data, termasuk saat terjadi penurunan dan kondisi yang relatif stabil. Namun, perbedaan nilai masih muncul pada beberapa titik, terutama ketika terjadi perubahan kecil maupun perubahan yang cukup cepat. Prediksi terkadang terlalu tinggi saat data naik dan tidak cukup rendah saat data turun, sehingga belum sepenuhnya akurat dalam menggambarkan besar perubahan yang terjadi.

Perubahan jumlah block dari 1 menjadi 2 pada percobaan ini memberikan efek pada peningkatan sensitivitas model terhadap pola data. Model menjadi lebih responsif terhadap perubahan jangka pendek, sehingga mampu menangkap fluktuasi dengan lebih detail. Namun, dampaknya adalah prediksi menjadi lebih tajam dan cenderung berlebihan (terlalu tinggi saat naik dan terlalu rendah saat turun). Hal ini menyebabkan selisih antara nilai prediksi dan aktual masih cukup besar pada beberapa titik.

Secara kuantitatif, Percobaan 3 menghasilkan nilai RMSE sebesar 6.19, yang menunjukkan adanya beberapa kesalahan prediksi dengan selisih cukup besar pada titik-titik tertentu, sejalan dengan fluktuasi prediksi yang tampak pada grafik. Nilai MAE sebesar 3.88 mengindikasikan bahwa rata-rata kesalahan absolut berada pada tingkat sedang, lebih besar dibandingkan Percobaan 1 tetapi masih lebih rendah dibandingkan Percobaan 2. Nilai SMAPE sebesar 14.45% mencerminkan

tingkat kesalahan relatif yang cukup tinggi, menunjukkan bahwa deviasi antara prediksi dan aktual terjadi secara konsisten pada beberapa segmen data uji.



Gambar 4. 20 Grafik Aktual dan Prediksi Percobaan 4 Skenario Pengujian 3


Pada Percobaan 4 dengan konfigurasi lookback 14, horizon 1, stack 1, block 2, layer 1, dan learning rate 0.0005, grafik menunjukkan bahwa model N-BEATS sudah mampu mengikuti arah naik dan turun data dengan cukup baik. Pada bagian awal periode pengujian, nilai prediksi terlihat mendekati nilai aktual, namun pada puncak awal terlihat prediksi lebih tinggi dibandingkan nilai aktual. Hal ini menunjukkan bahwa model merespons kenaikan dengan cukup kuat, tetapi masih berlebihan dalam menentukan nilai puncaknya.

Pada bagian awal hingga pertengahan, perbedaan antara prediksi dan aktual terlihat lebih jelas. Prediksi cenderung naik lebih tinggi saat terjadi kenaikan dan turun lebih dalam saat terjadi penurunan. Akibatnya, garis prediksi terlihat lebih tajam dan lebih berfluktuasi dibandingkan data aktual. Ini menunjukkan bahwa model menjadi cukup sensitif terhadap perubahan data, tetapi belum mampu menjaga kestabilan nilai prediksi. Memasuki bagian pertengahan hingga akhir,

model masih dapat mengikuti arah tren data, termasuk saat terjadi penurunan tajam dan kondisi yang relatif stabil setelahnya. Namun, selisih antara prediksi dan aktual masih sering muncul. Pada beberapa titik, prediksi berada sedikit di atas nilai aktual, dan pada titik lain berada di bawahnya. Hal ini menunjukkan bahwa model belum konsisten dalam menyesuaikan besar perubahan nilai, meskipun arah pergerakan sudah sesuai.

Perubahan konfigurasi pada percobaan ini, yaitu penggunaan 2 block dan learning rate yang lebih kecil (0.0005), memberikan efek pada cara model belajar pola data. Penambahan block membuat model lebih peka terhadap perubahan, sehingga prediksi menjadi lebih tajam. Sementara itu, learning rate yang lebih kecil membuat proses penyesuaian model menjadi lebih lambat, sehingga prediksi terlihat belum sepenuhnya stabil dan masih sering terlalu tinggi atau terlalu rendah.

Dari sisi kuantitatif, Percobaan 4 menghasilkan nilai RMSE sebesar 6.29, yang menunjukkan bahwa masih terdapat kesalahan prediksi dengan selisih yang cukup besar pada beberapa titik waktu, selaras dengan fluktuasi prediksi yang terlihat pada grafik. Nilai MAE sebesar 3.84 menunjukkan bahwa rata-rata kesalahan absolut berada pada tingkat sedang dan relatif mendekati Percobaan 3. Sementara itu, nilai SMAPE sebesar 13.99% mengindikasikan tingkat kesalahan relatif yang sedikit lebih rendah dibandingkan Percobaan 3, meskipun masih menunjukkan adanya perbedaan yang konsisten antara nilai prediksi dan nilai aktual.




Gambar 4. 21 Grafik Aktual dan Prediksi Percobaan 5 Skenario Pengujian 3

Pada Percobaan 5 dengan konfigurasi lookback 30, horizon 1, stack 1, block 1, layer 1, dan learning rate 0.001, grafik menunjukkan bahwa model N-BEATS mampu mengikuti arah pergerakan data dengan cukup baik dan terlihat lebih stabil dibandingkan penggunaan lookback yang lebih pendek. Pada bagian awal periode pengujian, prediksi sudah mengikuti tren kenaikan data aktual, meskipun pada beberapa titik nilainya masih sedikit berbeda, kadang lebih tinggi atau lebih rendah dari nilai sebenarnya. Namun secara umum, pola kenaikan dapat ditangkap dengan baik.

Pada bagian pertengahan hingga akhir, prediksi terlihat lebih halus dan stabil dibandingkan data aktual. Ketika terjadi kenaikan atau penurunan kecil, prediksi cenderung tidak berubah terlalu drastis. Akibatnya, pada beberapa titik prediksi berada sedikit di atas atau di bawah nilai aktual. Kondisi ini menunjukkan bahwa model lebih fokus pada pola umum dan kurang sensitif terhadap perubahan kecil atau fluktuasi yang cepat. Penggunaan lookback yang lebih panjang (30 hari), memberikan efek yang cukup jelas pada hasil prediksi. Model menjadi lebih stabil

dan mampu menangkap pola jangka panjang dengan lebih baik, sehingga kesalahan prediksi secara umum menjadi lebih kecil. Namun, dampaknya adalah model menjadi kurang peka terhadap perubahan yang cepat atau mendadak, sehingga pada beberapa titik prediksi terlihat lebih halus dan tidak mengikuti fluktuasi data secara detail.

Percobaan ini menghasilkan RMSE sebesar 4.93, MAE sebesar 3.32, dan SMAPE sebesar 13.56%. Nilai RMSE dan MAE yang lebih rendah dibandingkan percobaan dengan *lookback* 14 menunjukkan bahwa penggunaan *lookback* 30 mampu meningkatkan akurasi rata-rata prediksi secara absolut. Sementara itu, nilai SMAPE yang masih berada di atas 13% mengindikasikan bahwa kesalahan relatif terhadap skala data masih muncul, khususnya pada titik-titik perubahan tajam yang terlihat pada grafik.



Gambar 4. 22 Grafik Aktual dan Prediksi Percobaan 6 Skenario Pengujian 3

Pada Percobaan 6 dengan konfigurasi *lookback* 30, horizon 1, stack 1, block 1, layer 1, dan learning rate 0.0005, grafik menunjukkan bahwa model N-BEATS mampu mengikuti arah pergerakan data dengan cukup baik dan terlihat lebih stabil.


Pada bagian awal periode pengujian, prediksi sudah mengikuti tren kenaikan data aktual, meskipun pada beberapa titik nilainya sedikit lebih tinggi dibandingkan nilai aktual. Hal ini menunjukkan bahwa model dapat menangkap pola kenaikan, tetapi masih sedikit berlebihan dalam menentukan besarnya nilai. Pada sekitar indeks 8 hingga 10, ketika terjadi penurunan yang cukup tajam, prediksi juga ikut turun mengikuti arah data aktual. Namun, terlihat adanya sedikit keterlambatan (lag), di mana penurunan pada prediksi tidak langsung sama dengan penurunan aktual dan pada beberapa titik justru turun lebih dalam setelah nilai aktual mulai stabil. Hal ini menunjukkan bahwa model membutuhkan waktu untuk menyesuaikan diri terhadap perubahan yang terjadi secara cepat.

Pada bagian pertengahan hingga akhir, data aktual cenderung lebih stabil dengan perubahan yang tidak terlalu besar. Pada bagian ini, prediksi terlihat lebih halus dan cukup dekat dengan nilai aktual. Namun, pada beberapa titik ketika terjadi kenaikan atau penurunan kecil, prediksi tampak sedikit tertinggal dibandingkan nilai aktual. Kondisi ini menunjukkan adanya lag kecil, di mana model tidak langsung merespons perubahan jangka pendek secara tepat waktu.

Penggunaan lookback 30 dan learning rate yang lebih kecil (0.0005), memberikan efek yang cukup positif. Lookback yang panjang membantu model memahami pola jangka panjang sehingga prediksi menjadi lebih stabil, namun juga menyebabkan model kurang cepat dalam merespons perubahan mendadak, sehingga muncul efek lag. Sementara itu, learning rate yang lebih kecil membuat proses pembelajaran lebih halus dan tidak terlalu agresif. Kombinasi ini membuat

prediksi lebih dekat dengan nilai aktual secara umum, tetapi tetap menyisakan keterlambatan dalam mengikuti perubahan cepat.

Hasil evaluasi kuantitatif Percobaan 6 menghasilkan RMSE sebesar 4.78, MAE sebesar 3.14, dan SMAPE sebesar 12.57%. Nilai RMSE dan MAE yang lebih rendah dibandingkan Percobaan 5 menunjukkan adanya peningkatan akurasi absolut setelah penurunan *learning rate*. Selain itu, nilai SMAPE yang juga lebih kecil mengindikasikan bahwa kesalahan relatif terhadap skala data menjadi lebih rendah.




Gambar 4. 23 Grafik Aktual dan Prediksi Percobaan 7 Skenario Pengujian 3

Pada Percobaan 7 dengan konfigurasi lookback 30, horizon 1, stack 1, block 2, layer 1, dan learning rate 0.001, grafik menunjukkan bahwa pada awal periode pengujian terdapat perbedaan arah antara nilai aktual dan prediksi. Pada indeks awal, nilai aktual terlihat cenderung naik, namun prediksi justru turun terlebih dahulu. Hal ini menunjukkan adanya keterlambatan (lag) pada model dalam merespons perubahan arah data. Prediksi masih mengikuti pola sebelumnya sehingga belum langsung menyesuaikan dengan kondisi terbaru pada data uji.

Pada bagian pertengahan, model sudah mampu mengikuti pola naik dan turun data dengan lebih baik. Ketika terjadi penurunan tajam sekitar indeks 8–10, prediksi juga ikut turun mengikuti arah data aktual. Namun, masih terlihat sedikit lag, di mana penurunan prediksi tidak langsung sama dengan penurunan aktual dan membutuhkan beberapa titik untuk menyesuaikan. Pada bagian tengah hingga akhir, data cenderung lebih stabil. Pada segmen ini, prediksi terlihat cukup dekat dengan nilai aktual, meskipun masih terdapat selisih kecil pada beberapa titik. Saat terjadi perubahan kecil, prediksi terkadang sedikit tertinggal atau sedikit lebih tinggi dari nilai aktual, yang menunjukkan bahwa model belum sepenuhnya konsisten dalam mengikuti perubahan jangka pendek.

Perubahan konfigurasi pada percobaan ini, yaitu penggunaan lookback yang lebih panjang dan penambahan jumlah block menjadi 2, membuat model lebih mampu menangkap pola data secara umum. Namun, efeknya adalah model menjadi sedikit lambat dalam merespons perubahan mendadak di awal (lag), dan setelah itu cenderung memberikan prediksi yang terlalu tinggi saat terjadi kenaikan.

Nilai evaluasi kuantitatif pada percobaan ini menghasilkan MAE sebesar 3.11 dan SMAPE sebesar 12.30%, yang menunjukkan bahwa secara rata-rata kesalahan absolut dan relatif tergolong rendah. Akan tetapi, nilai RMSE sebesar 4.81 mengindikasikan bahwa masih terdapat beberapa kesalahan yang cukup besar pada titik-titik tertentu, terutama di awal periode pengujian saat prediksi mengalami penurunan dan kenaikan tajam.



Gambar 4. 24 Grafik Aktual dan Prediksi Percobaan 8 Skenario Pengujian 3

Pada Percobaan 8 dengan konfigurasi lookback 30, horizon 1, stack 1, block 2, layer 1, dan learning rate 0.0005, grafik menunjukkan bahwa model N-BEATS sudah mampu mengikuti arah pergerakan data, meskipun masih terdapat perbedaan nilai pada beberapa titik. Pada bagian awal periode pengujian, prediksi terlihat cukup dekat dengan nilai aktual. Namun, pada beberapa titik awal, prediksi berada sedikit di atas atau di bawah nilai aktual. Ketika data aktual mulai naik, prediksi juga ikut naik, tetapi belum selalu sama besar dengan kenaikan sebenarnya. Hal ini menunjukkan bahwa model sudah menangkap arah perubahan, tetapi belum sepenuhnya stabil dalam menentukan nilainya.

Pada bagian tengah, perbedaan antara prediksi dan aktual terlihat lebih jelas. Saat terjadi penurunan tajam sekitar indeks 8–10, prediksi juga ikut turun, tetapi terlihat sedikit terlambat (lag) dalam mengikuti perubahan tersebut. Setelah itu, pada beberapa titik kenaikan, prediksi cenderung lebih tinggi dibandingkan nilai aktual, sedangkan pada titik lain bisa lebih rendah. Selain itu, garis prediksi terlihat sedikit lebih tajam dibandingkan data aktual, terutama saat terjadi perubahan yang

cukup cepat. Hal ini menunjukkan bahwa model cukup sensitif terhadap perubahan, tetapi belum konsisten dalam menyesuaikan besar nilai. Memasuki bagian tengah hingga akhir, ketika data mulai lebih stabil, prediksi terlihat cukup dekat dengan nilai aktual.

Penggunaan lookback yang panjang (30) dan learning rate yang lebih kecil (0.0005) dengan 2 block, membuat model mampu menangkap pola data secara umum dengan cukup baik. Namun, efeknya adalah model menjadi sedikit lambat dalam merespons perubahan mendadak (lag) dan terkadang menghasilkan nilai yang tidak konsisten, bisa lebih tinggi atau lebih rendah dari nilai aktual.

Hasil evaluasi kuantitatif, Percobaan 8 menghasilkan nilai RMSE sebesar 5.17, MAE sebesar 3.44, dan SMAPE sebesar 13.91%. Nilai error tersebut menunjukkan bahwa performa model berada pada tingkat yang cukup baik, tetapi masih lebih tinggi dibandingkan beberapa percobaan lain pada skenario yang sama, terutama percobaan dengan kombinasi *learning rate* yang lebih besar.

Secara keseluruhan, hasil Skenario Pengujian 3 (90:05:05) menunjukkan bahwa performa model N-BEATS sangat dipengaruhi oleh kombinasi parameter seperti lookback window, jumlah block, dan learning rate. Pada Percobaan 1 hingga 4, grafik antara nilai aktual dan prediksi sudah menunjukkan pola yang mirip, tetapi masih terdapat perbedaan yang cukup jelas pada beberapa bagian, terutama saat terjadi perubahan nilai yang tajam.

Performa model mulai membaik pada Percobaan 5 hingga 7. Pada percobaan ini, jarak antara garis aktual dan prediksi terlihat semakin dekat. Hal ini juga didukung oleh nilai error yang semakin kecil. Di antara semua percobaan,

Percobaan 7 memberikan hasil terbaik dengan nilai RMSE sebesar 4.81, MAE sebesar 3.11, dan SMAPE sebesar 12.30%. Grafik pada percobaan ini menunjukkan bahwa model mampu mengikuti pola data dengan cukup stabil, baik saat data naik, turun, maupun saat relatif datar, meskipun masih ada sedikit perbedaan pada beberapa titik.

4.4 Pembahasan


Pada tahap pembahasan ini, dilakukan analisis terhadap hasil pengujian model N-BEATS pada seluruh skenario yang telah diterapkan untuk memahami kinerja model dalam memprediksi jumlah kunjungan museum. Dalam proses analisis tersebut, perbedaan kerapatan grafik pada tiap skenarionya perlu diperhatikan. Grafik perbandingan antara data aktual dan prediksi pada masing-masing skenario menunjukkan tingkat kerapatan yang berbeda secara visual. Perbedaan tersebut disebabkan oleh jumlah data pada bagian pengujian (testing) yang tidak sama pada setiap skenario, sesuai dengan proporsi pembagian data yang digunakan. Skenario dengan proporsi data uji yang lebih besar akan menghasilkan jumlah titik data yang lebih banyak sehingga grafik terlihat lebih rapat, sedangkan pada skenario dengan data uji yang lebih sedikit, grafik cenderung terlihat lebih renggang. Oleh karena itu, perbedaan kerapatan grafik tidak mencerminkan perbedaan performa model, melainkan merupakan konsekuensi dari perbedaan jumlah indeks data yang digunakan dalam proses pengujian.

Evaluasi dilakukan untuk menilai kemampuan model dalam memprediksi jumlah kunjungan museum dengan mempertimbangkan variasi pembagian data latih, data validasi, dan data uji. Penilaian kinerja model menggunakan tiga metrik

evaluasi utama, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Symmetric Mean Absolute Percentage Error (SMAPE), yang masing-masing memberikan sudut pandang berbeda dalam mengukur tingkat kesalahan prediksi. Penggunaan ketiga metrik ini bertujuan untuk memperoleh gambaran yang lebih komprehensif terhadap performa model, baik dari sisi kesalahan absolut, sensitivitas terhadap error ekstrem, maupun kesalahan dalam bentuk persentase relatif.


Pada pengujian ini, parameter horizon ditetapkan sebesar 1, serta jumlah stacks dan layers masing-masing ditetapkan sebesar 1 pada seluruh percobaan, sehingga tidak menjadi variabel yang dibandingkan dalam analisis. Dengan demikian, variasi hyperparameter yang dikaji difokuskan pada lookback (14 dan 30), jumlah block (1 dan 2), serta learning rate (0.001 dan 0.0005) pada setiap skenario pembagian data.

Untuk memperjelas perbandingan kinerja model, hasil evaluasi pada setiap skenario juga divisualisasikan dalam bentuk grafik MAE, RMSE, dan SMAPE. Visualisasi grafik error ini digunakan sebagai tahap awal analisis untuk memberikan gambaran umum mengenai perbedaan performa model, sebelum dilakukan pembahasan lebih lanjut terhadap nilai error pada masing-masing konfigurasi.




Gambar 4. 25 Grafik Evaluasi RMSE

Nilai RMSE menggambarkan besarnya kesalahan prediksi dengan memberikan penalti lebih besar terhadap error yang ekstrem, sehingga semakin tinggi RMSE maka semakin besar deviasi prediksi model terhadap data aktual, khususnya pada titik-titik lonjakan. Berdasarkan diagram batang RMSE, terlihat bahwa skenario 70:15:15 menghasilkan nilai kesalahan yang paling tinggi, bahkan mencapai lebih dari 13,00 pada beberapa konfigurasi hyperparameter. Hal ini menunjukkan bahwa model masih mengalami deviasi yang cukup besar ketika menghadapi perubahan nilai yang tajam. Pada skenario 80:10:10, nilai RMSE menurun ke kisaran 9,11–10,09, yang mengindikasikan adanya perbaikan kemampuan model dalam menekan kesalahan ekstrem. Sementara itu, skenario 90:05:05 menunjukkan penurunan yang sangat signifikan dengan nilai RMSE terendah sebesar 4,78 – 4,81. Nilai yang lebih rendah ini menandakan bahwa selisih kuadrat antara prediksi dan aktual semakin kecil serta model lebih stabil dalam mengikuti fluktuasi data uji.



Gambar 4. 26 Grafik Evaluasi MAE

Nilai MAE merepresentasikan rata-rata kesalahan absolut tanpa memberikan bobot lebih pada error besar, sehingga metrik ini mencerminkan besarnya kesalahan umum yang terjadi pada seluruh periode pengujian. Semakin tinggi MAE, semakin besar rata-rata selisih antara nilai prediksi dan aktual. Pada skenario 70:15:15, nilai MAE berada pada kisaran 5,30 hingga di atas 7,80, yang menunjukkan bahwa secara umum model masih menghasilkan penyimpangan yang cukup besar. Variasi nilai yang lebar antar konfigurasi juga mengindikasikan bahwa model belum stabil ketika jumlah data latih relatif terbatas. Pada skenario 80:10:10, nilai MAE berada pada rentang 6,00–6,40 dan terlihat lebih konsisten. Sementara itu, skenario 90:05:05 kembali menunjukkan performa terbaik dengan nilai MAE terendah sebesar 3,11, yang berarti rata-rata kesalahan absolut model hanya sekitar tiga satuan dari nilai aktual. Hal ini menunjukkan bahwa peningkatan proporsi data latih berkontribusi langsung terhadap penurunan kesalahan rata-rata prediksi.



Gambar 4. 27 Grafik Evaluasi SMAPE

SMAPE mengukur kesalahan dalam bentuk persentase relatif terhadap nilai aktual dan prediksi, sehingga memberikan gambaran seberapa besar deviasi prediksi secara proporsional. Nilai SMAPE yang tinggi menunjukkan bahwa kesalahan relatif model terhadap skala data masih besar. Pada skenario 70:15:15, nilai SMAPE berada di atas 25%, yang menandakan bahwa prediksi model masih menyimpang lebih dari seperempat nilai aktual secara rata-rata. Pada skenario 80:10:10, nilai SMAPE menurun ke kisaran 17 – 18%, menunjukkan adanya peningkatan akurasi relatif. Sementara itu, skenario 90:05:05 menghasilkan nilai SMAPE terendah sebesar 12,30%, yang berarti kesalahan prediksi secara persentase semakin kecil dan lebih terkendali. Penurunan ini mengindikasikan bahwa model tidak hanya lebih akurat secara absolut, tetapi juga lebih proporsional terhadap variasi skala data.

Hasil evaluasi lengkap disajikan pada tabel berikut untuk memperlihatkan pengaruh variasi parameter tersebut terhadap nilai MAE, RMSE, dan SMAPE.

Tabel 4. 11 Hasil Evaluasi Keseluruhan Model

Split	Lookback	Blocks	LR	MAE	RMSE	SMAPE
70:15:15	14	1	0.001	6.20	10.21	25.84%
			0.0005	6.63	10.77	26.59%
		2	0.001	7.85	13.43	28.33%
			0.0005	6.86	11.45	26.60%
	30	1	0.001	5.29	8.21	27.40%
			0.0005	5.65	8.71	28.34%
		2	0.001	5.84	9.27	27.76%
			0.0005	5.34	8.17	27.56%
80:10:10	14	1	0.001	6.18	9.72	17.81%
			0.0005	5.96	9.57	17.32%
		2	0.001	6.37	9.81	17.47%
			0.0005	6.34	9.97	18.11%
	30	1	0.001	6.26	9.31	18.46%
			0.0005	6.09	9.11	18.52%
		2	0.001	6.37	10.09	18.61%
			0.0005	6.21	9.28	18.88%
90:05:05	14	1	0.001	3.62	6.13	13.48%
			0.0005	3.99	6.54	14.91%
		2	0.001	3.88	6.18	14.45%
			0.0005	3.84	6.29	13.99%
	30	1	0.001	3.31	4.93	13.56%
			0.0005	3.14	4.77	12.57%
		2	0.001	3.11	4.81	12.30%
			0.0005	3.43	5.16	13.91%

Berdasarkan tabel keseluruhan hasil evaluasi, dapat diamati bahwa kinerja model N-BEATS dipengaruhi oleh kombinasi variasi hyperparameter serta skenario pembagian data yang digunakan. Pada penelitian ini, seluruh konfigurasi diuji dengan horizon = 1, stacks = 1, dan layers = 1, sehingga perbedaan performa model secara langsung dipengaruhi oleh lookback, jumlah block, learning rate, serta proporsi data latih, validasi, dan uji pada masing-masing skenario.

Ditinjau dari skenario pembagian data, terlihat bahwa skenario 90:05:05 secara konsisten menghasilkan nilai MAE, RMSE, dan SMAPE yang lebih rendah dibandingkan skenario 80:10:10 dan 70:15:15. Hal ini menunjukkan bahwa proporsi data latih yang lebih besar memberikan keuntungan bagi model dalam mempelajari pola historis deret waktu secara lebih mendalam, sehingga kesalahan prediksi pada data uji dapat ditekan. Sebaliknya, pada skenario 70:15:15, nilai error cenderung lebih tinggi, yang mengindikasikan bahwa jumlah data latih yang lebih sedikit membatasi kemampuan model dalam menangkap pola tren dan fluktuasi kunjungan museum.

Dari sisi *lookback*, penggunaan *lookback* 30 umumnya menghasilkan nilai kesalahan yang lebih rendah dibandingkan *lookback* 14 pada ketiga skenario pembagian data. Hal ini mengindikasikan bahwa informasi historis yang lebih panjang membantu model dalam mengenali pola jangka menengah, terutama pada data kunjungan yang memiliki fluktuasi dan lonjakan tertentu. Namun, peningkatan *lookback* juga perlu diimbangi dengan jumlah data latih yang memadai, yang terlihat paling optimal pada skenario 90:05:05.

Berdasarkan jumlah block, konfigurasi dengan 2 block pada beberapa kombinasi menghasilkan nilai error yang lebih rendah dibandingkan 1 block, khususnya ketika dikombinasikan dengan lookback 30. Hal ini menunjukkan bahwa penambahan block memungkinkan model mengekstraksi representasi pola yang lebih kompleks, meskipun peningkatan ini tidak selalu signifikan pada seluruh skenario pembagian data.

Sementara itu, pada learning rate, nilai 0.001 cenderung memberikan hasil yang lebih stabil dibandingkan 0.0005, terutama pada skenario dengan data latih yang besar. Learning rate yang terlalu kecil menyebabkan proses pembelajaran berjalan lebih lambat sehingga model kurang optimal dalam menyesuaikan bobot terhadap pola data, sedangkan learning rate yang lebih besar membantu percepatan konvergensi selama proses pelatihan. Hasil evaluasi menunjukkan bahwa kombinasi antara proporsi data latih yang besar, lookback yang lebih panjang, jumlah block yang memadai, serta learning rate yang sesuai berperan penting dalam menurunkan tingkat kesalahan prediksi.

Berdasarkan hasil evaluasi pada seluruh skenario pengujian, dipilih tiga konfigurasi model terbaik yang memiliki nilai kesalahan paling rendah untuk digunakan pada tahap prediksi data di masa mendatang. Ketiga model tersebut berasal dari skenario pembagian data 90:05:05. Adapun ringkasan konfigurasi dan nilai error dari ketiga model terbaik disajikan pada Tabel berikut.


Tabel 4. 12 Ringkasan Hasil Tiga Model Terbaik

Model	Lookback	Block	Learning Rate	MAE	RMSE	SMAPE
Model 1	30	2	0.001	3,11	4,81	12,30%
Model 2	30	1	0.0005	3,14	4,77	12,57%
Model 3	30	1	0.001	3,31	4,93	13,56%

Nilai pada metrik evaluasi menunjukkan kinerja model berdasarkan tiga indikator utama, yaitu MAE (Mean Absolute Error), RMSE (Root Mean Squared Error), dan SMAPE (Symmetric Mean Absolute Percentage Error), yang masing-masing memberikan perspektif berbeda dalam mengevaluasi hasil prediksi. MAE digunakan untuk mengukur rata-rata kesalahan absolut, RMSE untuk mengidentifikasi pengaruh kesalahan besar dengan memberikan penalti lebih tinggi, serta SMAPE untuk melihat kesalahan dalam bentuk persentase secara relatif terhadap nilai aktual.

Berdasarkan nilai pada tabel, ketiga model menunjukkan performa yang relatif baik dengan perbedaan nilai error yang tidak terlalu signifikan pada masing-masing metrik. Setiap model memiliki keunggulan pada metrik tertentu, sehingga belum dapat ditentukan satu model yang paling unggul hanya berdasarkan hasil evaluasi ini. Oleh karena itu, ketiga model tersebut dipertahankan sebagai kandidat terbaik untuk diuji lebih lanjut pada tahap prediksi menggunakan data di luar model.

Ketiga model yang telah melalui proses training, validation, dan testing kemudian diuji kembali menggunakan data di luar data model, yaitu dengan memanfaatkan data periode 1 hingga 31 Oktober 2025 sebagai input untuk menghasilkan prediksi selama 30 hari ke depan pada bulan November 2025. Hasil prediksi dari ketiga model tersebut selanjutnya divisualisasikan dalam bentuk grafik perbandingan antara data aktual dan data hasil prediksi.



Gambar 4. 28 Hasil Prediksi Model Terbaik 1

Berdasarkan grafik aktual dan prediksi pada skenario terbaik (skenario pengujian 3, lookback 30, block 2, learning rate 0.001), terlihat bahwa pada awal periode terdapat perbedaan yang cukup mencolok antara nilai prediksi dan data aktual. Prediksi dimulai dengan nilai yang lebih tinggi dibandingkan data aktual, kemudian mengalami penurunan tajam, sementara data aktual cenderung relatif stabil dengan sedikit fluktuasi. Hal ini menunjukkan bahwa model belum mampu menyesuaikan diri secara langsung pada kondisi awal data.


Memasuki beberapa hari berikutnya, pola prediksi mulai menunjukkan keselarasan dengan arah data aktual. Keduanya sama-sama mengalami kenaikan secara bertahap hingga mencapai titik puncak di pertengahan periode. Meskipun demikian, nilai prediksi cenderung lebih halus dan tidak sepenuhnya mengikuti detail kenaikan dan penurunan kecil yang terjadi pada data aktual.

Pada bagian akhir periode, baik data aktual maupun prediksi menunjukkan tren peningkatan yang cukup signifikan. Namun, prediksi terlihat sedikit melebihi nilai puncak dibandingkan data aktual, kemudian mengikuti pola

penurunan setelahnya. Hal ini mengindikasikan bahwa model mampu menangkap tren utama, tetapi masih terdapat selisih dalam memperkirakan besarnya perubahan.

Perbedaan antara grafik aktual dan prediksi terjadi karena model menggunakan pola historis (lookback 30) sebagai dasar pembelajaran. Akibatnya, ketika terjadi perubahan yang cukup cepat, model cenderung merespons dengan lebih lambat. Selain itu, karakteristik model yang menghasilkan prediksi lebih halus menyebabkan fluktuasi tajam pada data aktual tidak sepenuhnya terikuti oleh hasil prediksi.

Dari hasil evaluasi, model ini memiliki nilai MAE sebesar 6.13, RMSE sebesar 7.78 dan SMAPE sebesar 13.01%. Nilai error tersebut menunjukkan bahwa rata-rata selisih antara prediksi dan data aktual masih ada, namun tidak terlalu besar, sehingga model sudah cukup baik dalam mengikuti pola data.



Gambar 4. 29 Hasil Prediksi Model Terbaik 2

Berdasarkan grafik aktual dan prediksi pada model peringkat kedua (skenario pengujian 3, lookback 30, block 1, learning rate 0.0005), terlihat bahwa

pada awal periode terdapat perbedaan yang cukup jelas antara data aktual dan prediksi. Prediksi diawali dengan nilai yang cukup tinggi, kemudian mengalami penurunan tajam, sementara data aktual cenderung lebih stabil dan tidak menunjukkan penurunan sedrastis prediksi. Hal ini menunjukkan bahwa model belum mampu menyesuaikan kondisi awal data dengan baik. Memasuki beberapa hari berikutnya, pola prediksi mulai mengikuti arah data aktual. Keduanya menunjukkan tren kenaikan secara bertahap hingga pertengahan periode. Namun, pada fase ini prediksi terlihat lebih halus dan sedikit tertinggal dalam menangkap perubahan naik-turun kecil yang terjadi pada data aktual.


Pada pertengahan periode, sekitar saat data aktual mengalami penurunan cukup signifikan, prediksi juga menunjukkan arah penurunan, tetapi dengan pola yang lebih landai. Hal ini mengindikasikan bahwa model mampu mengikuti arah tren, namun tidak sepenuhnya menangkap besarnya perubahan yang terjadi.

Pada akhir periode, baik data aktual maupun prediksi mengalami kenaikan yang cukup tajam hingga mencapai puncak. Pada bagian ini, prediksi terlihat sedikit melebihi nilai dibandingkan data aktual, terutama di sekitar titik puncak. Setelah itu, keduanya sama-sama mengalami penurunan, meskipun prediksi kembali menunjukkan pola yang lebih halus dibandingkan data aktual yang turun lebih tajam.

Perbedaan antara grafik aktual dan prediksi terjadi karena model belajar dari data sebelumnya, sehingga saat terjadi kenaikan atau penurunan yang cepat, model bisa bereaksi terlalu tinggi atau terlalu lambat. Selain itu, model cenderung membuat pola yang lebih halus, sehingga perubahan yang tajam pada data aktual

tidak sepenuhnya diikuti. Hal ini menyebabkan prediksi kadang lebih tinggi saat naik dan tidak terlalu turun saat data aktual menurun tajam.

Dari hasil evaluasi, model ini memiliki nilai MAE sebesar 5.82, RMSE sebesar 7.87, dan SMAPE sebesar 12.37%. Nilai error tersebut menunjukkan bahwa secara umum model sudah cukup baik dalam mengikuti pola data, bahkan sedikit lebih baik dibandingkan model sebelumnya dari sisi MAE dan SMAPE.



Gambar 4. 30 Hasil Prediksi Model Terbaik 3

Berdasarkan grafik aktual dan prediksi pada model peringkat ketiga (skenario pengujian 3, lookback 30, block 1, learning rate 0.001), terlihat bahwa pada awal periode terdapat perbedaan antara data aktual dan prediksi. Prediksi diawali dengan nilai yang lebih tinggi, kemudian mengalami penurunan yang cukup tajam, sementara data aktual cenderung lebih stabil dengan fluktuasi kecil. Hal ini menunjukkan bahwa model belum mampu menyesuaikan kondisi awal data secara langsung. Memasuki beberapa hari berikutnya, pola prediksi mulai mengikuti arah data aktual, di mana keduanya menunjukkan tren kenaikan secara bertahap hingga mencapai titik puncak awal di pertengahan periode. Namun, pada bagian ini nilai

prediksi terlihat sedikit lebih tinggi dibandingkan data aktual, yang menunjukkan adanya kecenderungan overestimasi saat terjadi kenaikan.

Pada pertengahan periode, ketika data aktual mengalami penurunan yang cukup signifikan, prediksi juga menunjukkan arah penurunan yang sama. Meskipun demikian, penurunan pada prediksi terlihat lebih landai dan halus dibandingkan data aktual yang turun lebih tajam. Hal ini mengindikasikan bahwa model mampu menangkap arah tren, tetapi belum sepenuhnya akurat dalam memperkirakan besarnya perubahan.

Memasuki akhir periode, baik data aktual maupun prediksi mengalami kenaikan yang cukup tajam hingga mencapai puncak tertinggi. Pada fase ini, prediksi kembali terlihat sedikit melebihi nilai dibandingkan data aktual, terutama di sekitar titik puncak. Setelah itu, keduanya sama-sama menunjukkan tren penurunan, namun prediksi kembali bergerak lebih halus dibandingkan data aktual. Secara keseluruhan, pola prediksi pada model ini sudah mampu mengikuti tren utama, baik saat terjadi kenaikan maupun penurunan. Namun, perbedaan antara grafik aktual dan prediksi tetap terjadi karena model belajar dari data sebelumnya, sehingga saat ada perubahan yang cepat, model bisa bereaksi terlalu tinggi (overestimasi) atau tidak cukup dalam mengikuti penurunan. Selain itu, hasil prediksi cenderung lebih halus, sehingga lonjakan atau penurunan tajam pada data aktual tidak sepenuhnya ditangkap oleh model.

Dari hasil evaluasi, model ini memiliki nilai MAE sebesar 5.15, RMSE sebesar 6.69 dan SMAPE sebesar 11.31%. Nilai error tersebut menunjukkan bahwa

model ini memiliki performa yang lebih baik dibandingkan model sebelumnya, karena selisih antara prediksi dan data aktual relatif lebih kecil.

Berdasarkan perbandingan nilai error dari ketiga model, diperoleh ringkasan sebagai berikut:

Tabel 4. 13 Hasil Evaluasi Menggunakan Data Terbaru

Model	MAE	RMSE	SMAPE
Model 1	6.13	7.78	13.01%
Model 2	5.82	7.87	12.37%
Model 3	5.15	6.69	11.31%

Nilai pada tabel menunjukkan bahwa Model 3 memiliki nilai error paling rendah pada ketiga metrik evaluasi, baik dari sisi MAE, RMSE, maupun SMAPE. Hal ini mengindikasikan bahwa model tersebut mampu menghasilkan prediksi dengan selisih yang lebih kecil terhadap data aktual, baik dalam rata-rata kesalahan absolut, kesalahan yang sensitif terhadap nilai ekstrem, maupun kesalahan dalam bentuk persentase. Model 2 menunjukkan performa yang cukup baik dengan nilai MAE dan SMAPE yang lebih rendah dibandingkan Model 1, namun memiliki nilai RMSE yang sedikit lebih tinggi, yang menunjukkan masih adanya pengaruh kesalahan besar pada beberapa titik. Sementara itu, Model 1 memiliki nilai error yang relatif lebih tinggi dibandingkan dua model lainnya, sehingga performanya cenderung kurang optimal dalam meminimalkan kesalahan prediksi.

Berdasarkan perbandingan grafik aktual dan prediksi, ketiga model pada dasarnya telah mampu mengikuti arah tren utama data, baik pada fase kenaikan maupun penurunan. Namun, pada awal periode seluruh model menunjukkan ketidakmampuan dalam menyesuaikan kondisi awal data, yang ditandai dengan perbedaan cukup mencolok antara nilai prediksi dan aktual. Memasuki pertengahan

periode, pola prediksi mulai mengikuti tren data aktual dengan lebih baik, meskipun masih terdapat kecenderungan hasil prediksi yang lebih halus dan tidak sepenuhnya menangkap fluktuasi kecil maupun perubahan yang tajam. Pada beberapa kondisi, model juga menunjukkan kecenderungan overestimasi saat terjadi kenaikan serta menghasilkan penurunan yang lebih landai dibandingkan data aktual.

Perbedaan tersebut terjadi karena model melakukan pembelajaran berdasarkan pola historis dengan pendekatan lookback 30, sehingga respons terhadap perubahan yang terjadi secara cepat menjadi kurang optimal. Selain itu, karakteristik model yang menghasilkan prediksi lebih halus menyebabkan fluktuasi ekstrem pada data aktual tidak sepenuhnya terakomodasi. Di antara ketiga model yang diuji menggunakan data diluar data *training*, *validation* dan *testing*, Model 3 dengan konfigurasi lookback 30, block 1, dan learning rate 0.001 menunjukkan kemampuan terbaik dalam menyeimbangkan antara mengikuti tren utama dan meminimalkan kesalahan prediksi, dengan nilai MAE sebesar 5.15, RMSE sebesar 6.69, dan SMAPE sebesar 11.31%, sehingga dapat dipilih sebagai model dengan performa paling optimal dalam penelitian ini. Nilai hasil prediksi dari model terbaik tersebut disajikan secara lengkap pada Lampiran 2.

4.5 Integrasi Islam

Integrasi nilai-nilai Islam dalam penelitian ini didasarkan pada ajaran Al-Qur'an dan hadis yang menekankan pentingnya perencanaan masa depan, ketelitian dalam bekerja, serta evaluasi berkelanjutan terhadap aktivitas yang telah dilakukan. Hal ini sejalan dengan firman Allah Swt. dalam Surah Al-Hasyr ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ ﴿١٨﴾
 اللَّهُ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ ﴿١٩﴾

“Wahai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok. Bertakwalah kepada Allah. Sesungguhnya Allah Mahateliti terhadap apa yang kamu kerjakan.” (Qs. Al-Hasyr:18)

Ayat tersebut mengandung perintah agar manusia melakukan evaluasi terhadap perbuatan yang telah dilakukan sebagai bekal untuk masa depan. Dalam tafsir Ibnu Katsir dijelaskan bahwa ayat ini mendorong setiap individu untuk menimbang dan memperhitungkan amal perbuatannya secara sadar dan terencana sebelum menghadapi masa yang akan datang. Konsep ini relevan dengan penelitian prediksi kunjungan Museum MPU Purwa, di mana data historis jumlah pengunjung dianalisis secara sistematis untuk memprediksi kondisi di masa mendatang. Dengan demikian, aktivitas peramalan (forecasting) dalam penelitian ini mencerminkan prinsip Islam tentang pentingnya perencanaan berbasis evaluasi data masa lalu.

Selanjutnya, prinsip keteraturan waktu sebagai dasar analisis deret waktu tercermin dalam Surah Al-Isra ayat 12, sebagaimana firman Allah Swt.:

جَعَلْنَا اللَّيْلَ وَالنَّهَارَ آيَاتَيْنِ فَمَحْوُودَ آيَةٍ اللَّيْلِ وَجَعَلْنَا آيَةَ النَّهَارِ مُبْصِرَةً لِّتَبْتَغُوا فَضْلًا مِّن رَّبِّكُمْ وَلِتَعْلَمُوا عَدَدَ السِّنِينَ وَالْحِسَابِ ۚ وَكُلَّ شَيْءٍ فَصَّلْنَاهُ تَفْصِيلًا ﴿١٢﴾

“Kami jadikan malam dan siang sebagai dua tanda (kebesaran Kami). Kami hapuskan tanda malam dan Kami jadikan tanda siang itu terang benderang agar kamu (dapat) mencari karunia dari Tuhanmu dan mengetahui bilangan tahun serta perhitungan (waktu). Segala sesuatu telah Kami terangkan secara terperinci.” (QS. Al-Isra:12)

Dalam tafsir Ibnu Katsir dijelaskan bahwa pergantian siang dan malam merupakan sarana bagi manusia untuk mengetahui perhitungan waktu dan

mengatur aktivitas kehidupannya secara teratur. Ayat ini memiliki keterkaitan erat dengan konsep time series, di mana data disusun berdasarkan urutan waktu yang teratur. Oleh karena itu, penggunaan metode Neural Basis Expansion Analysis for Interpretable Time Series Forecasting (N-BEATS) dalam penelitian ini selaras dengan prinsip Al-Qur'an tentang keteraturan waktu dan perhitungan yang sistematis.

Nilai ketelitian dan kesungguhan dalam proses penelitian juga diperkuat oleh hadis Rasulullah saw. yang diriwayatkan dari Aisyah r.a.:

إِنَّ اللَّهَ يُحِبُّ إِذَا عَمِلَ أَحَدُكُمْ عَمَلًا أَنْ يُتْقِنَهُ

“Sesungguhnya Allah menyukai apabila seseorang melakukan sesuatu pekerjaan, dia melakukannya dengan itqan (tekun, cermat, dan sempurna).” (Hadis Riwayat al-Baihaqi)

Hadis ini menegaskan bahwa Allah Swt. mencintai pekerjaan yang dilakukan dengan itqan, yaitu tepat, teliti, dan sungguh-sungguh. Prinsip ini menjadi landasan etis dalam penerapan metode N-BEATS yang menuntut ketelitian tinggi dalam tahap praproses data, pemilihan parameter, pelatihan model, hingga evaluasi hasil prediksi. Dengan menerapkan prinsip itqan, penelitian ini berupaya menghasilkan model prediksi yang akurat, transparan, dan dapat dipertanggungjawabkan secara ilmiah.

Selain itu, konsep pembelajaran dari kesalahan dan perbaikan berkelanjutan tercermin dalam hadis Rasulullah saw. yang diriwayatkan dari Abu Hurairah r.a.:

لَا يُلْدَغُ الْمُؤْمِنُ مِنْ جُحْرٍ وَاحِدٍ مَرَّتَيْنِ

Rasulullah ﷺ bersabda, *“Seorang mukmin tidak disengat dua kali dari satu lubang.” (Muttafaq ‘alaih).*

Hadis ini mengandung makna bahwa seorang mukmin tidak sepatutnya mengulangi kesalahan yang sama, melainkan mengambil pelajaran dari pengalaman sebelumnya. Prinsip ini sejalan dengan proses evaluasi dalam penelitian prediksi, di mana kesalahan peramalan diukur menggunakan metrik evaluasi seperti MAE, MSE, dan RMSE untuk meningkatkan performa model. Dengan demikian, mekanisme evaluasi dan perbaikan model N-BEATS mencerminkan nilai Islam tentang pembelajaran berkelanjutan dan peningkatan kualitas berdasarkan pengalaman masa lalu.

Secara keseluruhan, integrasi nilai-nilai Islam dalam penelitian ini menunjukkan bahwa pendekatan ilmiah modern dalam bidang prediksi deret waktu sejalan dengan ajaran Islam. Prinsip perencanaan masa depan, keteraturan waktu, ketelitian dalam bekerja, serta evaluasi berkelanjutan yang diterapkan dalam metode N-BEATS merupakan implementasi nilai-nilai Islam yang bersumber dari Al-Qur'an dan hadis Nabi Muhammad saw.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model prediksi kunjungan Museum Mpu Purwa menggunakan metode N-BEATS berhasil dibangun dan mampu memprediksi pola kunjungan dengan cukup baik. Hasil evaluasi menunjukkan bahwa kinerja model dipengaruhi oleh kombinasi hyperparameter dan proporsi pembagian data, di mana skenario 90:05:05 memberikan performa yang lebih optimal dibandingkan skenario lainnya. Penggunaan lookback 30 terbukti efektif dalam menangkap pola historis data, sementara variasi block dan learning rate memberikan pengaruh terhadap kemampuan model dalam menyesuaikan kompleksitas pola yang terbentuk.

Berdasarkan hasil pengujian lanjutan menggunakan data di luar data testing, model terbaik diperoleh pada konfigurasi lookback 30, block 1, dan learning rate 0.001 dengan nilai MAE sebesar 5.15, RMSE sebesar 6.69, dan SMAPE sebesar 11.31%. Hasil ini menunjukkan bahwa model mampu menghasilkan prediksi dengan tingkat kesalahan yang relatif rendah serta memiliki kemampuan generalisasi yang baik terhadap data baru. Secara keseluruhan, model mampu mengikuti tren utama data, baik pada saat terjadi kenaikan maupun penurunan. Namun, model masih menunjukkan keterbatasan dalam merespons perubahan yang terjadi secara tiba-tiba, yang ditandai dengan kecenderungan overestimasi pada titik

puncak serta pola prediksi yang lebih halus sehingga tidak sepenuhnya menangkap fluktuasi ekstrem pada data aktual.

5.2 Saran

Pengembangan penelitian di bidang prediksi deret waktu, khususnya dalam konteks peramalan jumlah kunjungan museum menggunakan metode deep learning, masih memiliki ruang eksplorasi yang luas baik dari sisi data, metode, maupun strategi evaluasi. Oleh karena itu, beberapa saran yang dapat dipertimbangkan untuk penelitian selanjutnya adalah sebagai berikut:

1. Menambahkan variabel eksternal seperti hari libur nasional, musim liburan, kondisi cuaca, atau data promosi untuk menganalisis pengaruh faktor eksternal terhadap jumlah kunjungan museum.
2. Melakukan perbandingan dengan metode peramalan lain seperti LSTM, GRU, Transformer-based model, maupun ARIMA guna memperoleh analisis komparatif performa model.
3. Mengeksplorasi konfigurasi hyperparameter yang lebih beragam, seperti variasi jumlah stack, block, layer, hidden units, learning rate, dan epoch untuk melihat pengaruhnya terhadap stabilitas dan tingkat error prediksi.

DAFTAR PUSTAKA

- Agustin, Y. H., Satria, E., & Siti Nursifa, F. (2025). Prediksi Jumlah Pengunjung Pariwisata Di Kabupaten Garut Menggunakan Algoritma Regresi Linear. *Jurnal Algoritma*, 22(1), 569–581. <https://doi.org/10.33364/Algoritma/V.22-1.1807>
- Alfajriani, A., Wati, M., & Puspitasari, N. (2020). Penerapan Metode Fuzzy Time Series Chen Dan Hsu Dalam Memprediksi Kunjungan Wisatawan Di Museum Mulawarman. *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 4(2), 144. <https://doi.org/10.30872/Jurti.V4i2.5802>
- Ardiansyah, A. F., Saputra, A., Chatrine, C., Avesina, D. R., Natalia, D., Primandana, D. F., Pramesti, F. D., Ilyas, L. C., Rizqathallah, M. R., Arafah, R., & Satino, S. (2024). Analisis Peran Museum Seni Jakarta Di Kota Tua Dalam Mempertahankan Dan Melestarikan Warisan Budaya. *Buletin Antropologi Indonesia*, 1(2), 9. <https://doi.org/10.47134/Bai.V1i2.2611>
- Dinas Pendidikan Dan Kebudayaan Kota Malang. (2025). *Museum Mpu Purwa*. Sistem Registrasi Nasional Museum Kemdikbud. <https://10.24.26.63/Museum/Profile/Museum+Mpu+Purwa?Page=2>
- Hodson, T. O. (2022). Root-Mean-Square Error (RMSE) Or Mean Absolute Error (MAE): When To Use Them Or Not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/Gmd-15-5481-2022>
- Lim, B., & Zohren, S. (2021). Time-Series Forecasting With Deep Learning: A Survey. *Philosophical Transactions Of The Royal Society A: Mathematical, Physical And Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/Rsta.2020.0209>
- Marpaung, K. T. P., Rusgiyono, A., & Wilandari, Y. (2023). Perbandingan Metode Holt Winter's Exponential Smoothing Dan Extreme Learning Machine Untuk Peramalan Jumlah Barang Yang Dimuat Pada Penerbangan Domestik Di Bandara Utama Soekarno Hatta. *Jurnal Gaussian*, 11(3), 439–446. <https://doi.org/10.14710/J.Gauss.11.3.439-446>
- Motavali, A., Yow, K.-C., Hansmeier, N., & Chao, T.-C. (2023). DSA-BEATS: Dual Self-Attention N-BEATS Model For Forecasting COVID-19 Hospitalization. *IEEE Access*, 11, 137352–137365. <https://doi.org/10.1109/ACCESS.2023.3318931>
- Muhamad Harun Zein, Novanto Yudistira, & Putra Pandu Adikara. (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>
- Nafi'iyah, N. (2020). Algoritma SVM Untuk Memprediksi Pengunjung Wisata Musium Di Jakarta. *KERNEL: Jurnal Riset Inovasi Bidang Informatika Dan Pendidikan Informatika*, 1(1), 33–41. <https://doi.org/10.31284/J.Kernel.2020.V1i1.1156>

- Naik, B. S., Karthik, V. C., Manjunatha, B., Veershetty, G. H., H. N., Varshini, B. S., P. H., & Rao, S. G. (2024). Stock Price Forecasting Using N-Beats Deep Learning Architecture. *Journal Of Scientific Research And Reports*, 30(9), 483–494. <https://doi.org/10.9734/Jsrr/2024/V30i92373>
- Oreshkin, B. N., Carpov, D., Chapados, N., & Bengio, Y. (2019a). *N-BEATS: Neural Basis Expansion Analysis For Interpretable Time Series Forecasting* (Version 4). Arxiv. <https://doi.org/10.48550/ARXIV.1905.10437>
- Oreshkin, B. N., Carpov, D., Chapados, N., & Bengio, Y. (2019b). *N-BEATS: Neural Basis Expansion Analysis For Interpretable Time Series Forecasting* (Version 4). Arxiv. <https://doi.org/10.48550/ARXIV.1905.10437>
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., ... Ziel, F. (2022). Forecasting: Theory And Practice. *International Journal Of Forecasting*, 38(3), 705–871. <https://doi.org/10.1016/J.Ijforecast.2021.11.001>
- Rusmiyati, Murwaningrum, D., Aprianingrum, A. Y., & Haryanti, P. (2018). *Katalog Museum Indonesia* (Cetakan Pertama). Direktorat Pelestarian Cagar Budaya Dan Permuseuman, Direktorat Jenderal Kebudayaan, Kementerian Pendidikan Dan Kebudayaan.
- Sepira, A., Estikowati, E., Alvianna, S., & Lasarudin, A. (2024). Pengaruh Promosi Sosial Media Terhadap Minat Berkunjung Di Museum Mpu Purwa Kota Malang. *Jurnal Pariwisata Tourista*, 4(1), 22–26. <https://doi.org/10.26905/Jt.V4i1.13503>
- Shumway, R. H., & Stoffer, D. S. (2011). *Time Series Analysis And Its Applications*. Springer New York. <https://doi.org/10.1007/978-1-4419-7865-3>
- Xu, K., Zhang, J., Huang, J., Tan, H., Jing, X., & Zheng, T. (2024). Forecasting Visitor Arrivals At Tourist Attractions: A Time Series Framework With The N-BEATS For Sustainable Tourism. *Sustainability*, 16(18), 8227. <https://doi.org/10.3390/Su16188227>
- Zbezhkhovska, U., & Chumachenko, D. (2025). Smoothing Techniques For Improving COVID-19 Time Series Forecasting Across Countries. *Computation*, 13(6), 136. <https://doi.org/10.3390/Computation13060136>

LAMPIRAN

Lampiran 1

Hasil Rolling Mean 7 Data Harian

Tanggal	Total Pengunjung Harian	Total Pengunjung Rolling7
6/17/2022	14	14
6/18/2022	2	8
6/19/2022	3	6.333333333
6/20/2022	0	4.75
6/21/2022	15	6.8
6/22/2022	0	5.666666667
6/23/2022	4	5.428571429
6/24/2022	8	4.571428571
6/25/2022	15	6.428571429
6/26/2022	106	21.14285714
6/27/2022	0	21.14285714
6/28/2022	4	19.57142857
6/29/2022	12	21.28571429
6/30/2022	14	22.71428571
7/1/2022	21	24.57142857
7/2/2022	22	25.57142857
7/3/2022	8	11.57142857
7/4/2022	4	12.14285714
7/5/2022	12	13.28571429
7/6/2022	23	14.85714286
7/7/2022	95	26.42857143
7/8/2022	8	24.57142857
7/9/2022	0	21.42857143
7/10/2022	0	20.28571429
7/11/2022	0	19.71428571
7/12/2022	10	19.42857143
7/13/2022	15	18.28571429
7/14/2022	1	4.857142857
7/15/2022	44	10
7/16/2022	27	13.85714286
7/17/2022	20	16.71428571
7/18/2022	0	16.71428571
7/19/2022	0	15.28571429
7/20/2022	34	18
7/21/2022	7	18.85714286
7/22/2022	47	19.28571429

Tanggal	Total Pengunjung Harian	Total Pengunjung Rolling7
...	...	...
6/13/2025	18	39.14285714
6/14/2025	30	43.42857143
6/15/2025	29	47.57142857
6/16/2025	0	47.57142857
6/17/2025	19	24.42857143
6/18/2025	19	23.14285714
6/19/2025	118	33.28571429
6/20/2025	16	33
6/21/2025	7	29.71428571
6/22/2025	10	27
6/23/2025	0	27
6/24/2025	17	26.71428571
6/25/2025	23	27.28571429
6/26/2025	173	35.14285714
6/27/2025	0	32.85714286
6/28/2025	27	35.71428571
6/29/2025	20	37.14285714
6/30/2025	0	37.14285714
7/1/2025	32	39.28571429
7/2/2025	27	39.85714286
7/3/2025	12	16.85714286
7/4/2025	22	20
7/5/2025	16	18.42857143
7/6/2025	26	19.28571429
7/7/2025	4	19.85714286
7/8/2025	32	19.85714286
7/9/2025	29	20.14285714
7/10/2025	25	22
7/11/2025	28	22.85714286
7/12/2025	11	22.14285714
7/13/2025	13	20.28571429
7/14/2025	0	19.71428571
7/15/2025	45	21.57142857
7/16/2025	11	19
7/17/2025	20	18.28571429
7/18/2025	12	16
7/19/2025	100	28.71428571
7/20/2025	37	32.14285714

Lampiran 2

Hasil Prediksi Model Terbaik

Tanggal	Aktual	Prediksi
11/6/2025	34.42857143	40.94556548
11/7/2025	35.28571429	32.01953152
11/8/2025	34.71428571	38.38776362
11/9/2025	39.42857143	38.34057296
11/10/2025	39.85714286	37.30148074
11/11/2025	40.28571429	36.26238851
11/12/2025	38.42857143	39.11679238
11/13/2025	39.57142857	38.61467079
11/14/2025	41.28571429	50.34647216
11/15/2025	45.28571429	46.93854267
11/16/2025	47.71428571	49.23781104
11/17/2025	44.71428571	47.86427724
11/18/2025	41.71428571	46.49074343
11/19/2025	36.85714286	43.52648207
11/20/2025	35.14285714	39.67500236
11/21/2025	36.14285714	38.7026155
11/22/2025	42.42857143	39.73707101
11/23/2025	38	41.02683938
11/24/2025	47.28571429	40.09290318
11/25/2025	56.57142857	39.15896698
11/26/2025	62.14285714	61.80565528
11/27/2025	55.71428571	68.33074651
11/28/2025	54.85714286	61.34617216
11/29/2025	51.85714286	60.03235274
11/30/2025	42.14285714	53.6474422