

**IMPLEMETASI *ARTIFICIAL INTELLIGENCE* UNTUK
PREDIKSI HARGA PANGAN PADA APLIKASI *MOBILE* DI
KOTA PANGKALPINANG**

PROYEK AKHIR

Laporan akhir ini dibuat dan diajukan untuk memenuhi salah satu syarat
Kelulusan Sarjana Terapan/Diploma III Politeknik Manufaktur Negeri Bangka
Belitung



Disusun Oleh :

Khemal Fasyah Ishaq

NIM : 1062215

POLITEKNIK MANUFAKTUR NEGERI

BANGKA BELITUNG

TAHUN 2024/2025

LEMBAR PENGESAHAN

**IMPLEMETASI *ARTIFICIAL INTELLIGENCE* UNTUK PREDIKSI
HARGA PANGAN PADA APLIKASI *MOBILE* DI KOTA
PANGKALPINANG**

Oleh :

Khemal Fasyah Ishaq NIM : 1062215

Laporan akhir ini disetujui dan disahkan sebagai salah satu syarat kelulusan
Program Sarjana Terapan Politeknik Manufaktur Negeri Bangka Belitung

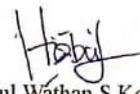
Menyetujui,

Pembimbing 1



Riki Afriansyah M.T
NIP. 199004042019031013

Pembimbing 2



M. Hizbul Wathan S.Kom., M.Kom.
NIP. 198904182024061001

Penguji 1



Indra Irawan, M. Kom.
NIP. 199507312024061002

Penguji 2



Putri Armilia Prayesy, M. Kom.
NIP. 199501042024062001

PERNYATAAN BUKAN PLAGIAT

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Khemal Fasyah Ishaq NIM : 1062215

Dengan Judul : Implemetasi *Artificial Intelligence* Untuk Prediksi
Harga Pangan pada Aplikasi Mobile di Kota
Pangkalpinang

Menyatakan bahwa laporan akhir ini adalah hasil kerja kami sendiri dan bukan merupakan plagiat. Pernyataan ini (penulis) buat dengan sebenarnya dan bila ternyata dikemudian hari ternyata melanggar pernyataan ini, (penulis) bersedia menerima sanksi yang berlaku.

Sungailiat, 15 September 2025

Nama Mahasiswa

1. Khemal Fasyah Ishaq

Tanda Tangan



ABSTRAK

Fluktuasi harga pangan di Kota Pangkalpinang merupakan tantangan signifikan yang memengaruhi stabilitas ekonomi dan daya beli masyarakat. Untuk mengatasi hal ini, penelitian ini bertujuan merancang, membangun, dan mengevaluasi sistem prediksi harga pangan berbasis *Artificial Intelligence* (AI) yang diimplementasikan dalam sebuah aplikasi mobile. Metodologi yang diterapkan menggunakan pendekatan per-komoditas untuk 40 jenis bahan pangan dengan membandingkan dua model *machine learning*: XGBoost yang dioptimalkan secara otomatis dengan Optuna dan Gated Recurrent Unit (GRU). Data harga historis harian dari 1 Januari 2024 hingga 28 Mei 2025 diperoleh dari API Sistem Informasi Perdagangan Kota Pangkalpinang (SIPGK). Hasil evaluasi menggunakan *Time Series Cross-Validation* menunjukkan bahwa model XGBoost secara signifikan lebih unggul, dengan performa terbaik pada 33 dari 40 komoditas (82,5%). Keunggulan ini terbukti dominan pada komoditas dengan volatilitas harga tinggi, di mana kemampuan XGBoost dalam memanfaatkan fitur-fitur rekayasa sangat efektif. Sebagai bukti konsep, model-model terbaik untuk setiap komoditas telah berhasil diintegrasikan ke dalam *backend* API dan disajikan melalui aplikasi mobile berbasis Flutter, yang membuktikan bahwa pendekatan AI per-komoditas adalah strategi yang akurat untuk sistem prediksi harga pangan di tingkat lokal.

Kata kunci: Prediksi Harga Pangan, XGBoost, GRU, Aplikasi *Mobile*, Kota Pangkalpinang

ABSTRACT

Food price fluctuation in Pangkalpinang City is a significant challenge that affects economic stability and public purchasing power. To address this, an accurate and easily accessible prediction system is necessary. This research aims to design, build, and evaluate an Artificial Intelligence (AI)-based food price prediction system implemented in a mobile application. The study employs a per-commodity approach for 40 types of food items, comparing two machine learning models: XGBoost, optimized with Optuna, and Gated Recurrent Unit (GRU). Historical daily price data from January 1, 2024, to May 28, 2025, was obtained from the Pangkalpinang City Trade Information System (SIPGK) API. Evaluation using Time Series Cross-Validation shows that the XGBoost model is significantly superior, achieving the best performance on 33 out of 40 commodities (82.5%). This advantage is particularly dominant for commodities with high price volatility, where XGBoost's ability to effectively leverage engineered features proved decisive. As a proof-of-concept, the best-performing model for each commodity was successfully integrated into a backend API and delivered through a Flutter-based mobile application, providing users with intuitive price prediction visualizations. This study demonstrates that a per-commodity AI approach is an effective and accurate strategy for developing local-level food price prediction systems.

Keywords: Food Price Prediction, XGBoost, GRU, Mobile Application, Pangkalpinang City

KATA PENGANTAR

Dengan memanjatkan puji syukur penulis panjatkan Kehadiran Tuhan Yang Maha Esa , berkat rahmat dan karunia Nya penulis dapat menyelesaikan Laporan Proyek Akhir denga judul “Implementasi *Artificial Intelligence* Untuk Prediksi Harga Pangan pada Aplikasi *Mobile* di Kota Pangkalpinang”. Di dalam penulisan laporan ini, penulis telah mendapatkan bantuan pemikiran serta dorongan dari berbagai pihak. Oleh karena itu dalam kesempatan ini penulis ingin mengucapkan terimakasih yang sebesar-besarnya kepada:

1. Bapak I Made Andik Setiawan, M.Eng, Ph.D selaku Direktur Politeknik Manufaktur Negeri Bangka Belitung.
2. Ibu Yang Agita Rindri, M.Eng selaku Ka. Jurusan Informatika dan Bisnis di Politeknik Manufaktur Negeri Bangka Belitung.
3. Bapak Sidhiq Andriyanto, M.Kom selaku Ka. Prodi D4 Teknologi Rekayasa Perangkat Lunak di Politeknik Manufaktur Negeri Bangka Belitung.
4. Ibu Linda Fujiyanti, M.Ti selaku dosen wali kelas TRPL A.
5. Bapak Riki Afriansyah M.T selaku Dosen Pembimbing I Proyek Akhir di Politeknik Manufaktur Negeri Bangka Belitung.
6. Bapak M. Hizbul Wathan S.Kom., M.Kom. Dosen Pembimbing II Proyek Akhir di Politeknik Manufaktur Negeri Bangka Belitung.
7. Kepada kedua orang tua penulis yang telah memberikan dukungan dan doa di setiap langkah penyusunan proyek akhir ini.
8. Teman-teman seperjuangan penulis yang telah bersama-sama memberikan motivasi selama perkuliahan awal semester hingga penyusunan proyek akhir ini, dan semoga sampai memperoleh gelar sarjana.
9. Semua pihak yang telah memberikan dukungan kepada penulis dalam menyelesaikan proyek akhir ini.

Penulis menyadari bahwa dalam penulisan laporan Proyek Akhir ini banyak terdapat kekurangan karena keterbatasan pengetahuan penulis tentang masalah yang penulis sampaikan. Oleh karena itu, saran dan kritik yang bersifat membangun sangat diharapkan. Terakhir, penulis berharap laporan ini dapat bermanfaat bagi membacanya, terutama untuk diri pribadi penulis maupun untuk siapa saja.

Sungailiat, September 2025

Khemal Fasyah Ishaq

DAFTAR ISI

LEMBAR PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN BUKAN PLAGIAT	ii
ABSTRAK	iv
<i>ABSTRACT</i>	v
KATA PENGANTAR.....	vi
DAFTAR ISI	vii
DAFTAR TABEL.....	x
DAFTAR GAMBAR	xi
DAFTAR LAMPIRAN	xii
BAB I PENDAHULUAN	12
1.1. Latar Belakang Masalah.....	12
1.2. Perumusan Masalah	13
1.3. Tujuan.....	13
1.4. Manfaat	14
1.5. Batasan Masalah.....	14
BAB II DASAR TEORI.....	16
2.1. Tinjauan Pustaka	16
2.2. Landasan Teori	18
2.2.1. Konsep Dasar Kecerdasan Buatan dalam Prediksi Harga.....	18
2.2.2. Faktor yang Mempengaruhi Harga Pangan.....	18
2.2.3. Metode AI Untuk Prediksi Harga.....	18
2.2.4. Metode Evaluasi Model	20
2.2.5 Metode Pengujian Sistem.....	22
2.3. Teknologi Pengembangan Sistem	23
2.3.1. Python	23
2.3.2. Dart.....	23
2.3.3 Flutter	23
2.3.3. API (Application Programming Interface).....	23
BAB III METODE PELAKSANAAN	24
3.1. Rancangan Penelitian.....	24

3.2. Variabel Penelitian	25
3.2.1. Variabel Dependen (Y).....	25
3.2.2. Variabel Independen (X)	25
3.3. Data Penelitian	26
3.3.1. Sumber Data.....	26
3.3.2. Objek dan Karakteristik Data.....	26
3.4. Proses Pengumpulan Data.....	29
3.5. Pra-pemrosesan dan Rekayasa Fitur	30
3.6. Perancangan dan Pelatihan Model	31
3.6.1. Model XGBoost Optimasi dan Validasi Tiga Fase	31
3.6.2. Model GRU Validasi dan Pelatihan Tiga Fase	32
3.7. Evaluasi Kinerja Model.....	34
3.8. Perancangan Sistem Aplikasi	37
3.8.1. Arsitektur Sistem.....	37
3.8.2. Perancangan Backend (API)	37
3.8.3. Perancangan Frontend (Aplikasi Mobile).....	38
3.9. Metodologi Pengujian Sistem Aplikasi	39
3.9.1. Perancangan Skenario Uji dengan UML.....	39
3.9.2. Pengujian Fungsional (<i>Black Box Testing</i>).....	40
3.9.3. Pengujian Penerimaan Pengguna	41
BAB IV PEMBAHASAN.....	42
4.1. Gambaran Umum Hasil Eksperimen	42
4.2. Analisis Studi Kasus dan Kinerja Model	47
4.2.1. Komoditas dengan Volatilitas Tinggi	47
4.2.1. Komoditas dengan Volatilitas Stabil	49
4.3. Pembahasan Temuan Signifikan	51
4.3.1 Implikasi Pendekatan Per-Komoditas	51
4.3.2 Analisis Kepentingan Fitur (<i>Feature Importance</i>).....	51
4.4. Implementasi Model pada Sistem Aplikasi Mobile	52
4.4.1. Integrasi Model dengan Backend API.....	52
4.4.2. Desain Antarmuka Pengguna (<i>UI/UX</i>) dan Visualisasi Hasil	53
4.4.3. Alur Kerja Sistem <i>End-to-End</i>	55

4.5. Hasil dan Analisis Pengujian Aplikasi	55
4.6. Kendala Penelitian	57
BAB V KESIMPULAN DAN SARAN.....	58
5.1. Kesimpulan	58
5.2. Saran.....	58
DAFTAR PUSTAKA	60
LAMPIRAN	64



DAFTAR TABEL

Tabel 3. 1 Daftar Komoditas	27
Tabel 3. 2 Potongan Data Mentah Komoditas Pangan (Sebelum Pra-pemrosesan)	29
Tabel 3. 3 Potongan Dataset Harga Pangan (Setelah Rekayasa Fitur).....	30
Tabel 3. 4 Data aktual dan data prediksi Cabai Merah Keriting	34
Tabel 4. 1 Perbandingan Kinerja Model XGBoost dan GRU Berdasarkan RMSE dan MAPE.....	42
Tabel 4. 2 Perbandingan Kinerja Model XGBoost dan GRU Berdasarkan R2 dan MAE.....	44
Tabel 4. 3 Perbandingan Kinerja XGBoost dan GRU untuk Cabai Merah Keriting	47
Tabel 4. 4 Perbandingan Kinerja XGBoost dan GRU untuk Garam Beryodium Halus	49
Tabel 4. 5 Halaman Inputan pada Aplikasi Mobile.....	53
Tabel 4. 6 Halaman Prediksi pada Aplikasi Mobile.....	54
Tabel 4. 7 Halaman pada Website	54
Tabel 4. 9 Ringkasan Skor Rata-Rata Hasil UAT	56

DAFTAR GAMBAR

Gambar 3. 1 Flowchart Rancangan Penelitian.....	24
Gambar 3. 2 Diaram Arsitektur Sistem.....	37
Gambar 3. 3 Wirefreme/Mockup Antarmuka Aplikasi Mobile.....	38
Gambar 3. 4 Use Case Diagram Sistem Prediksi.....	40
Gambar 3. 5 Activity Diagram Alur Proses Prediksi	40
Gambar 4. 1 Dominasi kedua Model Keseluruhan RMSE Terendah	47
Gambar 4. 2 Plot Prediksi model GRU Cabai Merah Keriting.....	48
Gambar 4. 3 Plot Predksi model XGBoost Cabai Merah Keriting	48
Gambar 4. 4 Lima Fitur Penting untuk Prediksi Harha Cabai Merah Keriting	49
Gambar 4. 5 Plot prediksi model GRU Garam Beryodium Halus.....	50
Gambar 4. 6 Plot prediksi model GRU Garam Beryodium Halus.....	50
Gambar 4. 8 Grafik Rata-Rata Skor Hasil UAT.....	57

DAFTAR LAMPIRAN

Lampiran 1 Daftar Riwayat Hidup	Error! Bookmark not defined.
Lampiran 2 Heatmap Fitur Penting per Komoditas model XGBoost	65
Lampiran 3 Pengujian Fungsional Black Box.....	12



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Pangan merupakan kebutuhan dasar manusia yang paling utama dan pemenuhannya merupakan bagian dari hak asasi manusia. Negara berkewajiban mewujudkan ketersediaan, keterjangkauan, dan pemenuhan konsumsi pangan yang cukup, aman, bermutu, dan bergizi seimbang (Virginia et al., 2021). Pangan menurut Undang-Undang Nomor 18 Tahun 2012 adalah segala sesuatu yang berasal dari produk pertanian, perkebunan, kehutanan, perikanan, peternakan, perairan baik yang diolah maupun tidak diolah yang diperuntukkan sebagai makanan atau minuman bagi konsumsi manusia, termasuk bahan tambahan pangan, bahan baku pangan dan bahan lainnya yang digunakan dalam proses penyiapan, pengolahan, dan/atau pembuatan makanan atau minuman (Fauzin, 2021). Sejak awal peradaban, pangan menjadi kebutuhan esensial yang tak tergantikan bagi manusia. Dengan kata lain tentang pangan tidak mengenal istilah *out of date* (usang) karena akan selalu *up to date* seiring kebutuhan manusia yang terus ada (Lubis & Pulungan, 2024).

Meskipun pangan adalah hak asasi, di Indonesia, harga pangan seringkali fluktuatif sehingga menghambat akses masyarakat berpenghasilan rendah. Selain itu, fluktuasi harga pangan juga mempengaruhi stabilitas ekonomi nasional dan dapat menyebabkan inflasi (Ericko et al., 2023). Fluktuasi harga pangan dapat dipengaruhi oleh berbagai faktor, seperti pasokan komoditas, kenaikan biaya input produksi, peningkatan permintaan komoditas, kondisi cuaca di lokasi produksi pertanian, adanya kebijakan pembatasan impor, dan permintaan di tingkat internasional (Bahtiar & Raswatie, 2023). Ketidakpastian dalam pergerakan harga pangan ini seringkali menyulitkan masyarakat dalam perencanaan pengeluaran mereka, serta dapat mengganggu stabilitas ekonomi, baik konsumen maupun pelaku bisnis.

Berdasarkan data dari Badan Pusat Statistik Kepulauan Bangka Belitung (BPS Kep. Babel) (*Inflasi Tahun Kalender (y-to-d) Provinsi Kepulauan Bangka Belitung Menurut Kelompok Pengeluaran (2022=100) - Tabel Statistik - Badan Pusat Statistik Provinsi Kep. Bangka Belitung, n.d.*), rata-rata inflasi di Kota Pangkalpinang pada tahun 2022 sebesar 6,07 persen, dengan rata-rata Indeks Harga Konsumen (IHK) di Provinsi Kepulauan Bangka Belitung sebesar 103,91 dan IHK di Kota Pangkalpinang 104,60 pada tahun 2024. Data ini menunjukkan bahwa tekanan inflasi di Kota Pangkalpinang cukup signifikan, terutama pada kelompok pengeluaran pangan, yang berkontribusi besar terhadap kenaikan IHK. Fluktuasi harga pada komoditas pangan seperti beras, cabai, dan minyak goreng sering kali menjadi penyebab utama ketidakstabilan harga di tingkat konsumen.

Saat ini, prediksi harga pangan masih banyak dilakukan secara manual atau menggunakan metode konvensional yang kurang akurat dan lambat dalam merespons perubahan pasar. Oleh karena itu, diperlukan suatu sistem yang dapat memprediksi harga pangan secara lebih akurat dan real-time. Perkembangan teknologi, khususnya dalam bidang *Artificial Intelligence* (AI), menawarkan solusi untuk masalah ini. Algoritma seperti *Extreme Gradient Boosting* (XGBoost) dan *Gated Recurrent Unit* (GRU) telah terbukti efektif dalam melakukan prediksi dengan tingkat akurasi yang tinggi.

Implementasi AI pada aplikasi *mobile* diharapkan dapat menjadi solusi untuk memprediksi harga pangan dengan lebih efisien, sehingga membantu masyarakat, pedagang, dan pemerintah dalam mengambil keputusan yang lebih baik. Dengan demikian, proyek ini bertujuan untuk mengembangkan aplikasi berbasis AI yang dapat memprediksi harga pangan di Kota Pangkalpinang dengan akurasi yang tinggi.

1.2. Perumusan Masalah

Berdasarkan latar belakang di atas, permasalahan yang dapat dirumuskan adalah sebagai berikut:

1. Bagaimana mengembangkan dan membandingkan performa model prediksi harga pangan menggunakan algoritma XGBoost dan Gated Recurrent Unit (GRU) berdasarkan analisis data historis harga pangan serta faktor-faktor eksternal yang memengaruhinya di Kota Pangkalpinang?
2. Bagaimana merancang dan membangun sistem prediksi harga pangan, termasuk pengujian keakuratan dan keandalannya?
3. Bagaimana mengimplementasikan sistem prediksi harga pangan tersebut ke dalam aplikasi *mobile* yang dapat menyajikan informasi harga secara *real-time* kepada pengguna di Kota Pangkalpinang?

1.3. Tujuan

Tujuan dari proyek akhir ini adalah:

1. Menganalisis, mengembangkan, dan membandingkan model prediksi harga pangan menggunakan algoritma XGBoost dan Gated Recurrent Unit (GRU) berbasis data historis harga pangan serta faktor-faktor eksternal yang memengaruhinya di Kota Pangkalpinang.
2. Merancang, membangun, dan menguji keakuratan serta keandalan sistem prediksi harga pangan yang dikembangkan.
3. Mengimplementasikan sistem prediksi harga pangan ke dalam aplikasi *mobile* yang dapat menyajikan informasi harga secara *real-time* kepada pengguna di Kota Pangkalpinang.

1.4. Manfaat

Proyek akhir ini diharapkan dapat memberikan beragam manfaat praktis bagi berbagai pihak yang berkepentingan di Kota Pangkalpinang, sebagai berikut:

1. Bagi Pedagang dan Pelaku Usaha Pangan
Panduan prediktif yang dihasilkan memungkinkan penentuan strategi pembelian dan penjualan yang lebih optimal untuk mengurangi risiko kerugian finansial, serta meningkatkan efisiensi operasional dalam rantai pasok.
2. Bagi Masyarakat Umum atau Konsumen
Aplikasi mobile ini menyediakan akses informasi harga yang *real-time* dan prediktif, memberdayakan konsumen untuk membuat keputusan pembelian yang lebih cerdas dan hemat, sekaligus meningkatkan transparansi pasar.
3. Bagi Pemerintahan Kota Pangkalpinang
Sistem ini menyediakan informasi prediksi harga yang lebih akurat sebagai dasar kuat dalam perumusan kebijakan terkait stabilitas harga, manajemen rantai pasok, dan intervensi pasar yang tepat waktu, sekaligus mendukung perencanaan strategis cadangan pangan untuk memitigasi risiko inflasi.
4. Bagi Peneliti dan Pengembang Aplikasi Selanjutnya
Penelitian ini menyajikan kerangka kerja dan metodologi yang telah teruji sebagai fondasi untuk pengembangan sistem prediksi yang lebih canggih dan membuka peluang eksplorasi penerapan *Artificial Intelligence* lebih lanjut di sektor ekonomi lokal.

1.5. Batasan Masalah

Agar penelitian ini lebih terarah dan fokus pada tujuan yang telah ditetapkan, maka perlu ditetapkan beberapa batasan masalah. Batasan-batasan dalam penelitian ini adalah sebagai berikut:

- 1) Cakupan Wilayah dan Sumber Data
Penelitian ini secara spesifik berfokus pada data harga pangan di wilayah Kota Pangkalpinang. Sumber data utama untuk harga komoditas adalah API dari Sistem Informasi Perdagangan Kota Pangkalpinang (SIPGK), sedangkan data hari libur nasional diperoleh dari API publik.
- 2) Objek dan Periode Data
Objek penelitian terbatas pada 40 komoditas pangan yang datanya tersedia. Rentang waktu data historis yang digunakan dalam penelitian ini adalah dari 1 Januari 2024 hingga 28 Mei 2025.
- 3) Metode dan Algoritma
Perbandingan model prediksi terbatas hanya pada dua algoritma, yaitu *Extreme Gradient Boosting* (XGBoost) yang dioptimalkan dengan Optuna dan *Gated Recurrent Unit* (GRU).

4) Fitur Prediksi (Variabel Independen)

Fitur yang digunakan sebagai masukan model terbatas pada fitur yang direkayasa dari data historis dan kalender, yang meliputi:

- a. Fitur lag historis (misalnya, harga H-1 dan H-7).
 - b. Fitur berbasis kalender (hari dalam seminggu, minggu dalam tahun, bulan dalam tahun).
 - c. Fitur statistik (*moving average* dan standar deviasi harga).
 - d. Fitur eksternal yang hanya terbatas pada status hari libur nasional.
- Penelitian ini tidak mengintegrasikan data eksternal krusial lainnya seperti data cuaca, volume pasokan, atau kebijakan pemerintah.

5) Penanganan Data

Data harga yang tidak tercatat pada akhir pekan dan hari libur ditangani dengan menggunakan metode interpolasi berbasis waktu untuk mengisi kekosongan data tersebut.

6) Platform Implementasi

Hasil akhir penelitian diimplementasikan dalam sebuah sistem aplikasi yang terdiri dari *backend* API dan aplikasi *mobile* berbasis Flutter. Aplikasi ini berfungsi sebagai bukti konsep dari fungsionalitas sistem prediksi.

BAB II DASAR TEORI

2.1. Tinjauan Pustaka

Berdasarkan tinjauan terhadap berbagai studi sebelumnya, dapat ditarik beberapa pola dan temuan penting terkait prediksi harga pangan menggunakan metode *machine learning* dan *deep learning*, khususnya yang relevan dengan karakteristik data deret waktu:

1) Prediksi Harga Pangan dengan Metode Tradisional dan Deep Learning

Penelitian ini menunjukkan bahwa pemilihan metode prediksi sangat krusial, terutama di tengah ketidakpastian kondisi global. (Lubis et al., 2024) menemukan bahwa metode regresi polinomial lebih efektif dalam memprediksi harga beras dibandingkan regresi linear, dengan nilai R-squared mencapai 0,7776 dan MAPE 0,27% untuk regresi polinomial, jauh melampaui regresi linear yang hanya 0,08889.

Pada *deep learning*, studi (Ericko et al., 2023) membuktikan efektivitas *Long Short-Term Memory* (LSTM) dalam memprediksi harga pangan di pasar tradisional Surabaya, meskipun terdapat variasi kinerja antar komoditas seperti gula pasir (RMSE 30, MAE 18) dan minyak goreng (RMSE 424, MAE 215). Penelitian ini juga menekankan pentingnya pembersihan *missing value* dan pemilihan parameter serta metode evaluasi yang tepat untuk hasil prediksi optimal.

2) Penerapan dan Optimasi XGBoost dalam Prediksi Harga

Algoritma *Extreme Gradient Boosting* (XGBoost) telah terbukti sangat akurat dalam berbagai konteks prediksi harga. Contohnya, penelitian tentang harga saham Bank BCA dari (Jange, 2022) menunjukkan bahwa XGBoost efektif dengan akurasi MAPE sebesar 4,01%. Fitur indikator teknikal seperti *Exponential Moving Average* (EMA) secara signifikan meningkatkan akurasi prediksi. (Astutiningsih et al., 2023) lebih lanjut mengkonfirmasi efektivitas XGBoost dalam memprediksi harga saham PT. United Tractors Tbk. dengan MAPE 3,89% melalui optimasi *hyperparameter* dan penggunaan indikator teknikal seperti EMA, SMA, RSI, dan MACD. (Digno et al., 2023) juga menemukan bahwa XGBoost memberikan nilai MSE terbaik (0.1414) dalam prediksi harga properti Airbnb, dengan seleksi fitur ElasticNet yang mampu menurunkan MSE lebih lanjut menjadi 0.1370.

3) Perbandingan dan Efektivitas GRU dalam Prediksi Deret Waktu

Gated Recurrent Unit (GRU), sebagai alternatif *deep learning* yang lebih sederhana dari LSTM, seringkali menunjukkan performa yang unggul dalam prediksi deret waktu. (Meriani & Rahmatulloh, 2024) dan (Tholib et al., 2023) secara konsisten menunjukkan bahwa GRU lebih efektif dan akurat dibandingkan LSTM dalam memprediksi harga emas. Meskipun nilai *error* (MAE, RMSE, MAPE) GRU bisa sedikit lebih tinggi pada beberapa metrik dibandingkan LSTM terbaik dalam satu studi, GRU dinilai lebih baik dalam mendekati nilai aktual. (Prayogi et al., 2024) mengonfirmasi performa baik GRU untuk prediksi harga saham Bank Central Asia, mencapai R-squared 0.983 dengan pembagian data 80:20. Lebih lanjut, (Nilsen, 2022) menemukan bahwa GRU memiliki akurasi terbaik dalam memprediksi harga saham LQ45 dibandingkan RNN dan LSTM, dengan rata-rata galat yang lebih rendah dan akurasi 52% lebih tinggi dari RNN serta 47.53% lebih tinggi dari LSTM. (Samsudin et al., 2021) juga menyimpulkan bahwa model GRU efektif untuk memprediksi harga saham bank konvensional di Indonesia.

Berdasarkan tinjauan pustaka di atas, dapat disimpulkan bahwa pemilihan metode yang tepat sangat esensial dalam memprediksi harga komoditas, baik pangan maupun saham. Metode *deep learning* seperti GRU dan *machine learning* seperti XGBoost secara konsisten menunjukkan kemampuan prediksi yang akurat untuk data deret waktu, seringkali unggul dibandingkan metode lain. Keakuratan model juga sangat dipengaruhi oleh kualitas data, pra-pemrosesan yang komprehensif, rekayasa fitur yang informatif (misalnya, indikator teknikal dan fitur kalender), serta strategi pembagian data untuk pelatihan dan pengujian yang tepat.

Meskipun banyak penelitian telah dilakukan pada prediksi harga saham dan beberapa pada harga pangan, masih terdapat celah penelitian dalam penerapan kedua algoritma terkemuka ini secara komparatif untuk data harga beragam komoditas pangan di Kota Pangkalpinang yang memiliki karakteristik volatilitas bervariasi. Penelitian ini bertujuan untuk mengisi gap tersebut dengan:

1. Melakukan analisis komparatif performa XGBoost dan GRU pada data harga pangan spesifik di Kota Pangkalpinang.
2. Mengeksplorasi dan menganalisis peran penting dari fitur-fitur eksternal dan rekayasa fitur berbasis domain dalam meningkatkan akurasi prediksi untuk konteks harga pangan.
3. Mengimplementasikan model terbaik ke dalam aplikasi *mobile* yang *real-time*, yang belum banyak ditemukan dalam penelitian serupa yang berfokus pada aplikasi praktis bagi masyarakat dan pemerintah daerah.

2.2. Landasan Teori

2.2.1. Konsep Dasar Kecerdasan Buatan dalam Prediksi Harga

Kecerdasan buatan adalah teknologi yang mensimulasikan kecerdasan manusia dalam sistem elektronik, memungkinkan mesin untuk berpikir dan bertindak seperti manusia. AI dapat digunakan dalam berbagai aplikasi, termasuk analisis data, pengenalan pola, dan pengambilan keputusan otomatis (Kusumawardani, 2019). Dalam konteks prediksi harga, AI berfungsi untuk menganalisis data historis dan mengidentifikasi pola yang dapat digunakan untuk meramalkan harga di masa depan.

2.2.2. Faktor yang Mempengaruhi Harga Pangan

Harga pangan merupakan isu penting yang dipengaruhi oleh berbagai faktor, faktor-faktor yang mempengaruhi harga pangan dapat dilihat dari berbagai aspek yang meliputi motif perilaku konsumen, faktor ekonomi, ketersediaan bahan baku, serta kondisi produksi dan distribusi. (Falatehan & Pariyasi, 2021) menyoroti motif dalam perilaku memilih pangan yang berhubungan langsung dengan ketahanan pangan di komunitas nelayan. Motif ini dipengaruhi oleh modal yang melekat pada individu dan dapat digunakan sebagai indikator ketahanan pangan, yang secara tidak langsung mempengaruhi harga pangan melalui permintaan dan preferensi konsumen.

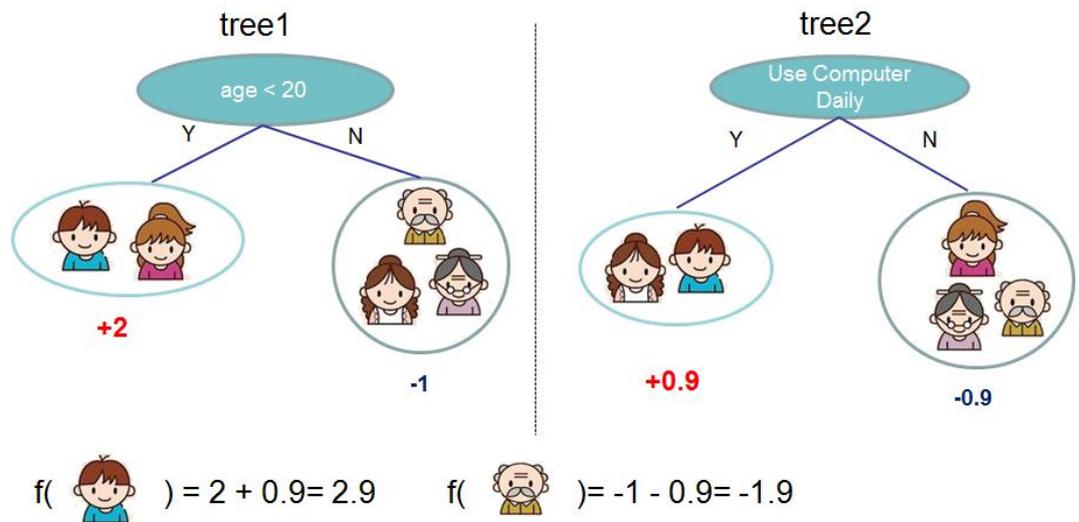
Ketersediaan bahan baku dan faktor produksi juga mempengaruhi harga pangan. (Ananda Lubis et al., 2021) meneliti pengaruh luas lahan, tenaga kerja, dan biaya sarana produksi terhadap produksi kentang, yang menunjukkan bahwa faktor produksi secara langsung mempengaruhi harga dan ketersediaan bahan pangan di pasar. Demikian pula, faktor-faktor yang mempengaruhi pendapatan petani, seperti yang diungkapkan oleh (Huda et al., 2023), turut berkontribusi terhadap harga pangan melalui tingkat produksi dan biaya produksi yang berfluktuasi.

2.2.3. Metode AI Untuk Prediksi Harga

2.2.3.1. Gradient Xtreme Boosting

Gradient Xtreme Boosting, yang dikenal juga sebagai XGBoost, merupakan salah satu algoritma *ensemble learning* yang sangat populer dan banyak digunakan dalam berbagai bidang aplikasi machine learning. Menurut (Mienye & Sun, 2022), XGBoost termasuk dalam kategori algoritma boosting yang berkembang dari metode boosting tradisional seperti *AdaBoost* dan *Gradient Boosting*, dan saat ini menjadi salah satu algoritma paling unggul dalam hal performa dan efisiensi.

Gambar 2. 1 Analogi XGBoost



Formula XGBoost

$$\hat{y}^i = \sum_{k=1}^K f_k(x_i), f_k \in F$$

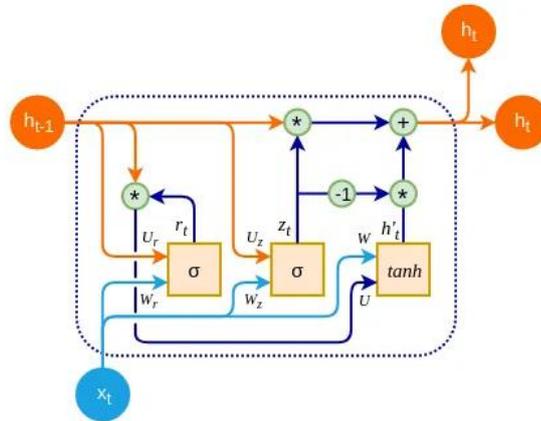
dimana:

- \hat{y}^i adalah prediksi akhir untuk data ke-i.
- K adalah jumlah total pohon.
- f_k adalah sebuah pohon keputusan independen.
- F adalah ruang dari semua kemungkinan pohon keputusan.

2.2.3.2. Gated Recurrent Unit

Gated Recurrent Unit (GRU) merupakan salah satu arsitektur dalam jaringan saraf tiruan yang dirancang untuk mengatasi masalah dalam pemodelan urutan, terutama dalam konteks data yang memiliki ketergantungan temporal. GRU diperkenalkan sebagai alternatif yang lebih sederhana dibandingkan dengan Long Short-Term Memory (LSTM), dengan tujuan untuk mengurangi kompleksitas komputasi sambil tetap mempertahankan kemampuan untuk menangkap informasi jangka Panjang (Chung et al., 2014).

Gambar 2. 2 Arsitektur GRU



Formula GRU:

$$r = \sigma(W_r \cdot X_t + U_r \cdot h(t-1) + b_r)$$

$$z = \sigma(W_z \cdot x_t + U_z \cdot h(t-1) + b_z)$$

$$h^{\sim} = \tanh(W_h \cdot X_t + r * U_h \cdot h(t-1) + b_h)$$

$$h = z * h(t-1) + (1 - z) * h^{\sim}$$

2.2.3.3. Deret Waktu (Time Series)

Deret waktu adalah analisis data yang melibatkan pengamatan yang diambil secara berurutan dalam waktu. Metode ini digunakan untuk meramalkan kebutuhan tenaga kerja di perusahaan, dengan memanfaatkan data historis untuk memprediksi tren masa depan. Dalam konteks industri, analisis deret waktu membantu dalam perencanaan strategis, proyeksi pendapatan, dan pengambilan keputusan (Yusapra Salim et al., 2024).

2.2.4. Metode Evaluasi Model

2.2.4.1. Time Series Cross Validation

Evaluasi model seringkali memiliki kelemahan jika hanya mengandalkan satu kali pembagian data latih dan uji, karena hasilnya bisa sangat sensitif terhadap kebetulan. Menurut (Bagnall et al., 2017), pendekatan ini dapat menyebabkan interpretasi hasil yang berlebihan. Untuk mengatasinya, digunakan metode *cross validation* berbasis *resampling* untuk mendapatkan estimasi kinerja yang lebih andal. Untuk data deret waktu, validasi ini harus menjaga urutan kronologis data, di mana data latih selalu mendahului data uji di setiap lipatan (*fold*).

2.2.4.2. MAPE

Hasil dari peramalan perlu dihitung tingkat kesalahan antara nilai aktual dengan data aktual dengan data prediksi. Salah satu metode yang dipakai untuk menghitung tingkat kesalahan yaitu *Mean Absolute Percentage Error* (MAPE). MAPE merupakan ukuran ketetapan relatif yang digunakan untuk mengetahui

persentase penyimpangan hasil peramalan (Jange, 2022). Adapun persamaannya adalah sebagai berikut:

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \right) \times 100\% \quad (2.3)$$

Dengan:

A_t = Nilai aktual pada waktu ke-t

F_t = Nilai peramalan pada waktu ke-t

n = Jumlah data

2.2.4.3. MAE

Mean Absolute Error (MAE) adalah salah satu metode yang digunakan untuk mengukur tingkat keakuratan model peramalan. setiap nilai diambil nilai absolutnya, sehingga nilai negatif hilang. Untuk evaluasi model peramalan, MAE lebih intuitif dalam memberikan rata-rata eror dari keseluruhan data (Meriani & Rahmatulloh, 2024). Secara rumus MAE dijelaskan sebagai berikut,

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i|$$

Dimana:

f_i = Nilai hasil peramalan

y_i = Nilai sebenarnya, dan

n = Jumlah data

2.2.4.4. R-Squared

R-Squared (R^2) adalah sebuah metrik fundamental yang mengukur proporsi varians pada variabel dependen yang dapat diprediksi atau dijelaskan oleh variabel-variabel independen dalam suatu model regresi. Nilainya berkisar dari 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan bahwa model tersebut mampu menjelaskan lebih banyak keragaman data. Sebagai contoh, nilai R^2 sebesar 0,65 berarti bahwa 65% dari variasi variabel dependen dapat dijelaskan oleh model. Meskipun tidak ada standar mutlak, dalam banyak bidang penelitian, nilai R^2 sering dikategorikan secara heuristik sebagai substansial ($\geq 0,75$), moderat ($\geq 0,50$), atau lemah ($\geq 0,25$), yang interpretasinya harus selalu disesuaikan dengan konteks dan tujuan penelitian (Hair et al., 2022).

$$SSE = \sum (Y_i - \hat{Y}_i)^2$$

$$SST = \sum (Y_i - \bar{Y})^2$$

$$R^2 = 1 - \frac{SSE}{SST}$$

Dimana *Sum of Squares Error* (SSE) memiliki fungsi untuk mengukur kesalahan penggunaan estimasi persamaan regresi. Y_i merupakan data aktual dan \hat{Y}_i merupakan data hasil prediksi, Total *Sum of Square* (SST) adalah kuadrat dari selisih nilai data aktual (Y_i) dengan nilai data testing (\hat{y}).

2.2.4.5 RMSE

RMSE merupakan besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat (Nilsen, 2022). Secara rumus MAE dijelaskan sebagai berikut,

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (f_i - y_i)^2}$$

2.2.5 Metode Pengujian Sistem

Pengujian sistem bertujuan untuk memastikan bahwa aplikasi yang dibangun telah sesuai dengan spesifikasi fungsional dan dapat diterima dengan baik oleh pengguna akhir. Pada penelitian ini, digunakan dua metode pengujian utama, yaitu *Black Box Testing* dan *User Acceptance Testing* (UAT) .

2.2.5.1 Pengujian *Black Box* (*Black Box Testing*)

Pengujian *black box* merupakan sebuah metode pengujian perangkat lunak yang mengevaluasi sistem secara eksklusif dari perspektif fungsional, tanpa mempertimbangkan desain arsitektur maupun struktur kode internal. Pada praktiknya, penguji berinteraksi dengan antarmuka sistem untuk memverifikasi bahwa setiap *input* menghasilkan *output* yang sesuai dengan spesifikasi kebutuhan. Salah satu teknik yang dapat diterapkan adalah *graph-based testing*, yang memvisualisasikan hubungan antar komponen perangkat lunak dalam bentuk grafik untuk membantu menemukan alur yang tidak valid. Dengan demikian, pengujian *black box* memegang peranan penting dalam memastikan kualitas dan kesesuaian fungsional perangkat lunak terhadap kebutuhan pengguna (Purwaningtyas & Jatmiko, 2024).

2.2.5.2 Pengujian Penerimaan Pengguna (*User Acceptance Testing - UAT*)

User Acceptance Testing adalah metode pengujian yang digunakan untuk mengevaluasi sejauh mana sistem atau aplikasi dapat diterima oleh pengguna sesuai dengan kebutuhan dan harapan mereka. Dalam konteks penelitian ini, UAT diterapkan untuk menganalisis website dengan fokus pada aspek fungsionalitas, keamanan, kehandalan, dan responsivitas. Metode ini melibatkan pengumpulan data melalui observasi, wawancara, dan kuesioner untuk menilai kepuasan pengguna dan mengidentifikasi area yang memerlukan perbaikan (Fitriastuti et al., 2024).

2.3. Teknologi Pengembangan Sistem

2.3.1. Python

Python adalah sebuah bahasa pemrograman yang memiliki sifat *interpreter*, *interactive*, *object-oriented*, dan dapat beroperasi hampir di semua platform seperti Mac, Windows, dan Linux. *Python* termasuk dalam bahasa pemrograman tingkat tinggi. *Python* termasuk bahasa pemrograman yang mudah dipelajari karena sintaks yang jelas, dapat dikombinasikan dengan penggunaan modul-modul siap pakai, dan struktur data tingkat tinggi yang efisien (Falah et al., 2023).

2.3.2. Dart

Setiap aplikasi Flutter ditulis menggunakan bahasa pemrograman Dart yang dikembangkan oleh Google. Dart awalnya dibuat untuk menggantikan JavaScript dan mengadopsi fitur-fitur modernnya seperti *async* dan *await*, namun memiliki sintaks yang mirip Java untuk memudahkan adopsi oleh pengembang. Flutter memiliki karakteristik unik di mana ia membangun ulang seluruh tampilan (*view*) pada setiap *frame*. Meskipun ini berpotensi menciptakan banyak objek sementara yang dapat membebani memori, Dart sebagai bahasa modern mengatasi masalah ini secara efisien melalui mekanisme "Generational Garbage Collection", yang dioptimalkan untuk membersihkan objek-objek berumur pendek tersebut. (Tashildar et al., 2020)

2.3.3 Flutter

Flutter adalah sebuah *framework* lintas platform dari Google yang dirilis pada tahun 2016 untuk membangun aplikasi seluler berperforma tinggi di Android, iOS, dan bahkan sistem operasi masa depan Google, Fuchsia. Keunggulannya terletak pada penggunaan *rendering engine* sendiri untuk menggambar komponen antarmuka, sehingga tidak bergantung pada *widget* bawaan perangkat dan mampu mencapai performa setara aplikasi *native*. Fitur utamanya adalah "Stateful Hot Reload", yang secara signifikan mempercepat proses pengembangan. Fitur ini memungkinkan pengembang untuk melihat perubahan kode secara instan tanpa kehilangan kondisi (*state*) aplikasi saat ini, karena pembaruan dikirim langsung ke Dart Virtual Machine (Dart VM) yang sedang berjalan. (Tashildar et al., 2020).

2.3.3. API (Application Programming Interface)

Application Programming Interface (API) adalah sebuah perantara atau jembatan komunikasi yang memungkinkan dua aplikasi perangkat lunak yang berbeda untuk saling berinteraksi dan bertukar data. API mendefinisikan serangkaian aturan, protokol, dan tools untuk membangun perangkat lunak aplikasi. Dalam konteks pengembangan aplikasi modern seperti Flutter, API sangat krusial untuk menghubungkan aplikasi di sisi klien (ponsel pengguna) dengan logika bisnis dan basis data di sisi server. Sebagai contoh, ketika sebuah aplikasi menampilkan daftar produk, aplikasi tersebut mengirimkan permintaan (*request*) melalui API ke server, dan server akan merespons (*response*) dengan mengirimkan data produk yang kemudian ditampilkan kepada pengguna (Putra et al., 2022).

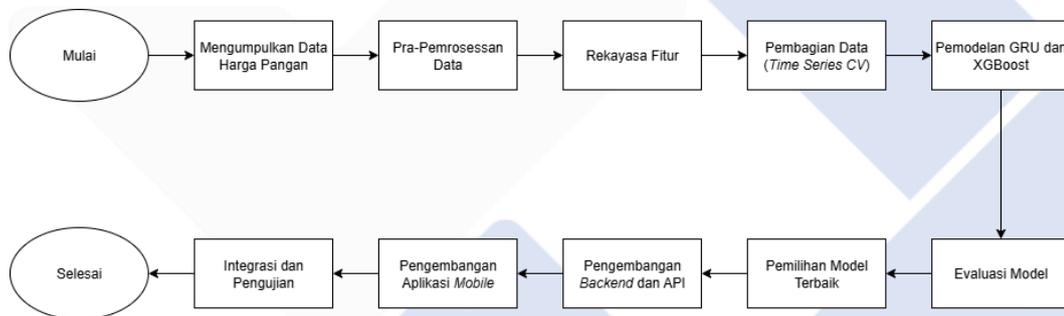
BAB III METODE PELAKSANAAN

3.1. Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk merancang, melatih dan evaluasi dua model *machine learning*, yaitu XGBoost dan GRU, dalam untuk melakukan peramalan harga pangan. Tujuan dari rancangan ini adalah untuk membandingkan kinerja kedua model secara objektif dan memilih model terbaik untuk diimplementasikan dalam aplikasi.

Alur kerja penelitian secara keseluruhan divisualisasikan dalam blok diagram pada Gambar 3.1. Proses dimulai dari tahap pengumpulan data, dilanjutkan dengan pra-pemrosesan dan rekayasa fitur, perancangan dan pelatihan model, hingga evaluasi akhir dan implementasi.

Gambar 3.1 Flowchart Rancangan Penelitian



Berdasarkan Gambar 3.1, alur penelitian dapat diuraikan sebagai berikut. Proses diawali dengan Pengumpulan Data, di mana data harga pangan historis dan data pendukung lainnya diperoleh dari sumber-sumber yang telah ditentukan. Data mentah ini kemudian masuk ke tahap Pra-pemrosesan Data, yang berfokus pada pembersihan, penanganan data kosong, dan validasi data. Setelah data bersih, dilakukan tahap Rekayasa Fitur untuk membangun variabel-variabel prediktor yang informatif dari data yang ada.

Selanjutnya, dataset yang telah diperkaya dengan fitur-fitur baru akan melalui tahap Pembagian Data. Pada tahap ini, digunakan metode *Time Series Cross-Validation* (TSCV) untuk memastikan proses evaluasi model yang robust dan sesuai dengan karakteristik data deret waktu. Data yang telah terbagi kemudian digunakan untuk Pemodelan, di mana model XGBoost (dengan optimisasi hiperparameter) dan model GRU dilatih.

Kinerja dari kedua model tersebut kemudian di-Evaluasi menggunakan metrik-metrik standar seperti RMSE dan MAPE. Hasil evaluasi ini menjadi dasar untuk tahap Pemilihan Model Terbaik, di mana model dengan performa superior dipilih secara individual untuk setiap komoditas. Model-model yang terpilih

menjadi acuan untuk tahap implementasi, yang dimulai dengan Pengembangan Backend dan API untuk menampung logika dan model. Secara paralel, dilakukan Pengembangan Aplikasi Mobile sebagai antarmuka pengguna. Tahap akhir adalah Integrasi dan Pengujian, di mana frontend dan backend dihubungkan dan diuji secara menyeluruh untuk memastikan fungsionalitas sistem berjalan sesuai harapan sebelum penelitian dinyatakan Selesai.

Setiap tahapan yang digambarkan pada Gambar 3.1 akan diuraikan secara lebih mendetail pada sub-bab berikutnya untuk memberikan pemahaman yang komprehensif mengenai metodologi yang diterapkan dalam penelitian ini.

3.2. Variabel Penelitian

Penelitian ini akan melibatkan dua jenis variable utama, yaitu variabel dependen yang akan menjadi target prediksi dan variabel independen yang berfungsi sebagai predictor. Identifikasi variabel-variabel ini merupakan langkah fundamental dalam perancangan model peramalan harga pangan.

3.2.1. Variabel Dependen (Y)

Variabel dependen pada penelitian ini adalah harga komoditas pangan di Kota Pangkalpinang, Variabel ini merupakan nilai numerik tunggal yang dinyatakan dalam satuan rupiah per kilogram atau satuan lain yang lebih relevan. Nilai variabel inilah yang menjadi sasaran atau target utama yang akan diramalkan oleh model kecerdasan buatan yang dikembangkan.

3.2.2. Variabel Independen (X)

Variabel independent merupakan sekumpulan fitur yang akan dijadikan masukan (*input*) pada model prediksi karena diduga memiliki hubungan kausalitas atau korelasional dengan variabel dependen. Variabel-variabel independen sebagai berikut:

- a) Fitur Lag Histori (*Historical Lag Features*)
Fitur ini merepresentasikan nilai-nilai harga komoditas di masa lampau untuk menangkap pola deret waktu. Contohnya adalah harga komoditas pada hari sebelumnya (H-1) dan pada tujuh hari sebelumnya (H-7) untuk menangkap pola mingguan.
- b) Fitur Berbasis Kalender (*Calendar-based features*)
Fitur ini dirancang untuk menangkap pola musiman (*seasonality*) atau siklus yang berulang dalam waktu tertentu. Contohnya meliputi hari dalam seminggu (dikonversi menjadi numerik, seperti Senin=1, Selasa=2, dst.), minggu dari tahun (nilai 1-52), dan bulan dari tahun (nilai 1-12).
- c) Fitur Statistik (*Statistical features*)
Fitur ini dihasilkan dari perhitungan statistik pada rentang waktu tertentu untuk mengidentifikasi tren lokal dan volatilitas harga. Contohnya adalah rata-rata pergerakan (*moving average*) harga komoditas selama 7 hari

terakhir dan standar deviasi harga komoditas selama 7 hari terakhir sebagai indikator volatilitas.

d) Fitur Eksternal (*External features*)

Fitur ini berasal dari sumber data eksternal yang diduga dapat memengaruhi harga pangan. Dalam penelitian ini, fitur eksternal yang digunakan adalah status hari libur nasional atau keagamaan (variabel biner: 1 jika hari libur, 0 jika hari biasa).

Kumpulan variabel independen inilah yang akan digunakan oleh model XGBoost dan GRU untuk mempelajari pola data dan menghasilkan prediksi variabel dependen.

3.3. Data Penelitian

Tahap pengumpulan data pada penelitian ini menggunakan dua jenis data sekunder yang diperoleh dari *Application Programming Interface* (API) eksternal. Penggunaan API memungkinkan proses pengambilan data dilakukan secara otomatis untuk menjamin efisiensi dan kebenaran data.

3.3.1. Sumber Data

Penelitian ini menggunakan dua sumber data premier, yaitu:

1) Data Harga Komoditas

Data di dapatkan dari API Sistem Informasi Perdagangan Kota Pangkalpinang (SIPKG), yang didapat diakses melalui alamat <https://sipgk.pangkalpinangkota.go.id>. Sumber ini menyediakan data harga harian untuk berbagai komoditas pangan di Kota Pangkalpinang.

2) Data Hari Libur Nasional

Data di dapatkan dari API publik yang bersedia di <https://api-harilibur.pages.dev/api>. Data ini digunakan sebagai fitur eksternal untuk melihat pengaruh dari hari libur terhadap perubahan harga.

3.3.2. Objek dan Karakteristik Data

3.3.2.1 Objek Penelitian

Objek utama penelitian ini adalah data deret waktu harian (*daily time series*) dari harga komoditas pangan. Penelitian ini akan menganalisis total 40 komoditas pangan yang tersedia. Beberapa contoh komoditas antara lain adalah beras, daging ayam, telur ayam, cabai, dan bawang merah. Daftar lengkap ke-40 komoditas pada Tabel.

Tabel 3. 1 Daftar Komoditas

NO	KOMODITAS
1	Bawang Bombay
2	Bawang merah lokal
3	Bawang putih honan
4	Beras medium matahari
5	Beras medium sendok
6	Beras premium 118 aaa
7	Beras premium rm
8	Cabe merah besar
9	Cabe merah keriting
10	Cabe rawit hijau
11	Cabe rawit merah
12	Daging daging ayam broiler (bersih)
13	Daging daging sapi paha belakang
14	Daging daging sapi paha depan
15	Daging daging sapi sandung lamur
16	Daging daging sapi tetelan
17	Garam beryodium halus
18	Gula pasir curah curah
19	Gula pasir curah psm
20	Ikan asin teri
21	Ikan segar kembung
22	Ikan segar tongkol

NO	KOMODITAS
23	Jeruk lokal
24	Kacang kedelai impor
25	Kacang-kacangan kacang hijau
26	Kacang-kacangan kacang tanah
27	Ketela pohon
28	Mie instant indomie rasa kari ayam
29	Minyak goreng fortune
30	Minyak goreng minyak kita
31	Pisang ambon
32	Susu bubuk dancow vanila
33	Susu bubuk sgm vanila
34	Susu kental manis merk frisian flag vanila
35	Tahu putih
36	Telur telur ayam broiler ras
37	Telur telur ayam kampung
38	Tempe
39	Tepung terigu segi tiga biru (kw medium)
40	Udang basah uk. Sedang

3.3.2.2. Rentang Waktu

Untuk memastikan konsistensi antara data harga dan data hari libur, penelitian ini menetapkan periode data yang seragam, yaitu mulai dari 1 Januari 2024 hingga 28 Mei 2025.

3.3.2.3. Karakteristik Khusus

Perlu diketahui bahwa data harga dari SIPGK hanya tercatat pada hari kerja (Senin hingga Jum'at). Karakteristik ini akan menjadi perhatian khusus pada tahap

pra-pemrosesan data untuk menangani kekosongan data pada akhir pekan dan hari libur nasional.

Tabel 3. 2 Potongan Data Mentah Komoditas Pangan (Sebelum Pra-pemrosesan)

	Date	Commodity	Price
0	2024-01-02	BAWANG BOMBAY	30000.0
1	2024-01-02	BAWANG MERAH Lokal	43333.0
2	2024-01-02	BAWANG PUTIH HONAN	42000.0
3	2024-01-02	BERAS MEDIUM Matahari	14000.0
4	2024-01-02	BERAS MEDIUM Sendok	14000.0
...
20515	2025-05-28	TELUR Telur Ayam Broiler/Ras	32300.0
20516	2025-05-28	TELUR Telur Ayam Kampung	91000.0
20517	2025-05-28	TEMPE	12500.0
20518	2025-05-28	TEPUNG TERIGU Segi Tiga Biru (kw Medium)	12667.0
20519	2025-05-28	UDANG BASAH UK. SEDANG	78333.0

3.4. Proses Pengumpulan Data

Proses pengambilan data dari kedua sumber API tersebut dilakukan secara terprogram dan otomatis. Sebuah skrip dikembangkan menggunakan bahasa pemrograman *Python* dengan memanfaatkan Pustaka (*library*) *request* untuk melakukan pemanggilan (*request*) ke setiap *endpoint* API. Data yang diterima dalam format JSON kemudian diproses dan disimpan. Pendekatan otomatis ini dipilih untuk menjamin efisiensi, mengurangi potensi galat manusia (*human error*), dan memastikan data yang diperoleh adalah data yang terbaru.

3.5. Pra-pemrosesan dan Rekayasa Fitur

Tahapan ini merupakan fondasi awal sebelum perancangan model, di mana data mentah diolah menjadi dataset yang bersih, konsisten, dan kaya akan informasi. Proses ini diterapkan secara seragam untuk kedua model (XGBoost dan GRU) guna memastikan perbandingan yang adil.

1. Pembersihan dan Validasi data

Proses awal meliputi konversi tipe data, penghapusan baris dengan data kosong, dan eliminasi data yang duplikat. Dilakukan juga filtrasi untuk mempertahankan komoditas yang memiliki lebih dari 300 catatan data historis guna menjamin ukuran data yang memadai.

2. Penanganan Deret Waktu dan Interpolasi

Mengingat karakteristik data harga yang hanya tercatat pada hari kerja, kekosongan data pada akhir pekan dan hari libur diisi dengan membuat rentang tanggal harian yang kontinu. Selanjutnya, metode interpolasi berbasis waktu, yaitu *interpolate(method='time')*, diterapkan untuk mengisi nilai-nilai yang hilang tersebut, memastikan deret waktu yang lengkap dan konsisten.

3. Rekayasa Fitur (*Fitur Engineering*)

Untuk memperkaya data masukan dan meningkatkan kemampuan prediksi model, serangkaian fitur informatif direkayasa dari data harga historis dan data eksternal. Fitur-fitur ini mencakup fitur *lag* historis (harga H-1, H-7), fitur berbasis kalender (hari dalam seminggu, minggu dari tahun, bulan dari tahun), fitur statistik (*moving average* dan standar deviasi harga 7 hari terakhir), dan fitur eksternal (status hari libur nasional).

Tabel 3. 3 Potongan Dataset Harga Pangan (Setelah Rekayasa Fitur)

	date	price	commodity	holiday_name	year	month	month	dayofweek	dayofweek	is_holiday	price_ma7	price_std7	commodity id
0	2023-12-29	3000.0	BAWANG BOMBAY	No Holiday	2023	12	29	0	0	0	30000.000000	0.000000	0
1	2023-12-29	3450.0	BAWANG MERAH Impor	No Holiday	2023	12	29	0	0	0	34500.000000	0.000000	1
2	2023-12-29	3700.0	BAWANG PUTIH	No Holiday	2023	12	29	0	0	0	37000.000000	0.000000	2
3	2023-12-29	4750.0	CABERAWI Hijau	No Holiday	2023	12	29	0	0	0	47500.000000	0.000000	3
4	2023-12-29	3500.0	MIE INSTANT Indomie rasa kari ayam	No Holiday	2023	12	29	0	0	0	35000.000000	0.000000	4
20579	2023-05-28	8000.0	IKAN ASIN TERI	No Holiday	2023	05	28	2	2	0	77143.142857	1259.755589	15
20580	2023-05-28	1900.0	GULAPASIR CURA H PSM	No Holiday	2023	05	28	2	2	0	19000.000000	0.000000	16

date	price	commodity	holiday_name	year	month	month	month	dayofweek	dayofweek	is_holiday	price_ma7	price_std7	commodity id
2025-05-28	1800	GULA PASIR CURAH	No Holiday	2025	5.0000	00e-01	0.866025	0.974928	-	0	18000.000000	0.000000	43
2025-05-28	8000	DAGING Daging Sapi Tetelan	No Holiday	2025	5.0000	00e-01	0.866025	0.974928	-	0	80000.000000	0.000000	13
2025-05-28	7833	UDANG BASA H UK. SEDANG	No Holiday	2025	5.0000	00e-01	0.866025	0.974928	-	0	82380.714286	3021.247519	44

3.6. Perancangan dan Pelatihan Model

Pada tahap ini, dirancang dua model untuk prediksi, yaitu XGBoost dan GRU, dengan pendekatan pelatihan dan validasi yang disesuaikan dengan karakteristik masing-masing model.

3.6.1. Model XGBoost Optimasi dan Validasi Tiga Fase

Model pertama yang dikembangkan adalah XGBoost, sebuah algoritma *ensemble learning* yang sangat efisien. Untuk memberikan gambaran praktis mengenai cara kerja XGBoost dalam satu langkah prediksi, berikut adalah contoh perhitungan manual sederhana:

- Kondisi awal
 - Harga Aktual : Rp65.000
 - Fitur `price_lag_1`: Rp62.000
 - Fitur `rolling_mean_7`: Rp60.000
 - Learning rate (η): 0.3
- Hitung Kesalahan (Residual)

Residual = Aktual - Prediksi Awal = Rp65.000 - Rp61.000 = Rp4.000
- Latih *Tree* pertama untuk memprediksi Residual

Sebuah *tree* sederhana dibangun. Asumsikan untuk data saat ini, *tree* tersebut memberikan output prediksi residual sebesar +3.500.
- Perbarui Residual

Prediksi Baru = $Rp61.000 + (0.3 \times 3.500) = Rp61.000 + 1.050 = Rp62.050$

Setelah satu iterasi, prediksi model bergerak dari Rp61.000 menjadi Rp62.050, lebih mendekati nilai aktual. Proses ini diulang pada iterasi berikutnya untuk terus mengurangi kesalahan.

Setelah memahami mekanisme dasarnya, pelatihan model XGBoost dilakukan melalui proses tiga fase yang sistematis untuk memastikan performa maksimal:

- **Optimisasi Hiperparameter dengan Optuna**
Tahap pertama adalah pencarian otomatis hiperparameter terbaik menggunakan pustaka Optuna, yang menerapkan optimisasi Bayesian. Proses ini secara efisien menjelajahi berbagai kombinasi parameter (*learning_rate*, *max_depth*, *subsample*, dll.). Setiap kombinasi parameter dievaluasi menggunakan *TimeSeriesSplit* dengan 3 lipatan untuk mendapatkan skor RMSE yang andal. Tujuannya adalah untuk menemukan konfigurasi hiperparameter yang secara objektif menghasilkan galat prediksi terendah.
- **Validasi Performa dengan Cross-Validation**
Setelah mendapatkan set hiperparameter terbaik dari Optuna, dilakukan validasi performa yang lebih mendalam. Model dilatih dan dievaluasi menggunakan *TimeSeriesSplit* dengan 10 lipatan. Pada setiap lipatan, model dilatih dengan hiperparameter terbaik dan memanfaatkan mekanisme *early_stopping_rounds* untuk menemukan jumlah iterasi pohon (*boosting rounds*) yang optimal secara otomatis, sehingga mencegah *overfitting*. Rata-rata metrik evaluasi dari 10 lipatan ini menjadi skor performa final yang dilaporkan.
- **Pelatihan Model Final**
Tahap terakhir adalah melatih satu model final menggunakan 100% data yang tersedia dengan hiperparameter terbaik yang telah ditemukan pada optimisasi hiperparameter. Model ini kemudian disimpan dalam format *.json* untuk implementasi di sistem aplikasi.

3.6.2. Model GRU Validasi dan Pelatihan Tiga Fase

GRU dirancang untuk menangani dependensi temporal dalam data deret waktu. Untuk mengilustrasikan alur kerja GRU dalam satu iterasi, berikut adalah contoh perhitungan sederhana dengan bobot hipotetis. GRU menggunakan *hidden state* (h_{t-1}) dari langkah sebelumnya dan input saat ini (x_t) untuk menghasilkan *hidden state* baru (h_t).

a. Kondisi Awal

- Input saat ini (x_t): vektor fitur, misal [*price_lag_1*, *rolling_mean_7*] = [0.8, 0.7]
- *Hidden State* sebelumnya (h_{t-1}): [0.2]

b. Hitung *Gates*

- *Reset Gate (r)*

Reset gate menentukan seberapa banyak *hidden state* lama yang harus diabaikan.

$$r = \sigma([0.3, 0.2] \cdot [0.8, 0.7]^T + [0.2] \cdot [0.2])$$

$$r = \sigma((0.3 * 0.8 + 0.2 * 0.7) + (0.2 * 0.2))$$

$$r = \sigma((0.24 + 0.14) + 0.04) = \sigma(0.42) \approx 0.60$$

- *Update Gate (z)*

Update gate menentukan seberapa banyak informasi baru yang akan ditambahkan.

$$z = \sigma([0.2, 0.1] \cdot [0.8, 0.7]^T + [0.1] \cdot [0.2])$$

$$z = \sigma((0.2 * 0.8 + 0.1 * 0.7) + (0.1 * 0.2))$$

$$z = \sigma((0.16 + 0.07) + 0.02) = \sigma(0.25) \approx 0.56$$

c. Hitung *Candidate Hidden State (h~)*

$$h\tilde{=} \tanh([0.4, 0.3] \cdot [0.8, 0.7]^T + 0.60 * ([0.3] \cdot [0.2]))$$

$$h\tilde{=} \tanh((0.4 * 0.8 + 0.3 * 0.7) + 0.60 * (0.3 * 0.2))$$

$$h\tilde{=} \tanh((0.32 + 0.21) + 0.60 * 0.06) = \tanh(0.53 + 0.036) \\ = \tanh(0.566) \approx 0.51$$

d. Perbarui *Hidden State*

$$h = 0.56 * [0.2] + (1 - 0.56) * [0.51]$$

$$h = 0.112 + 0.44 * 0.51 = 0.112 + 0.2244 = 0.3364$$

Dengan demikian, *hidden state* model diperbarui dari [0.2] menjadi [0.336]. Nilai baru ini digunakan untuk prediksi dan diteruskan ke langkah waktu berikutnya.

Berbeda dengan XGBoost, proses untuk model GRU lebih langsung dan terdiri dari dua fase utama:

- *Validasi Performa dengan Cross-Validation.* Model GRU dengan arsitektur yang telah ditetapkan (1 lapisan GRU dengan 128 unit, *dropout rate* 0.2, dan dioptimalkan dengan Adam) dievaluasi kinerjanya

menggunakan `TimeSeriesSplit` dengan 5 lipatan. Sama seperti XGBoost, proses ini bertujuan untuk mendapatkan estimasi performa yang robust dan andal dari arsitektur yang ada. Mekanisme `EarlyStopping` juga diterapkan untuk mencegah *overfitting* selama pelatihan di setiap lipatan.

- Pelatihan Model Final. Setelah performanya tervalidasi pada Fase 1, model GRU final dilatih menggunakan 100% data yang tersedia. Model yang telah dilatih penuh ini kemudian disimpan dalam format `.h5` beserta artefak *scaler*-nya untuk digunakan pada tahap implementasi.

3.7. Evaluasi Kinerja Model

Setelah model dilatih, kinerjanya dievaluasi menggunakan metode *Time Series Cross-Validation* untuk mendapatkan estimasi performa yang andal. Metrik kuantitatif yang digunakan untuk mengukur tingkat kesalahan dan keakuratan model adalah MAE, RMSE, MAPE, dan R2. Untuk memberikan pemahaman praktis mengenai penerapan metrik-metrik tersebut, berikut disajikan contoh perhitungan manual menggunakan data hipotetis untuk komoditas "Cabai Merah Keriting".

Tabel 3. 4 Data aktual dan data prediksi Cabai Merah Keriting

Hari ke-	Harga Aktual (Y)	Harga Prediksi (F)
1	Rp65.000	Rp62.000
2	Rp68.000	Rp67.000
3	Rp64.000	Rp66.000
4	Rp70.000	Rp71.000

1) Perhitungan MAE

MAE mengukur rata-rata dari selisih absolut antara nilai aktual dan prediksi. Metrik ini menyajikan rata-rata galat dalam satuan aslinya (Rupiah).

- Menghitung galat absolut untuk setiap data

$$| 62.000 - 65.000 | = 3.000$$

$$| 67.000 - 68.000 | = 1.000$$

$$| 66.000 - 64.000 | = 2.000$$

$$| 71.000 - 70.000 | = 1.000$$

- Menjumlahkan seluruh galat absolut

$$Total\ Galat = 3.000 + 1.000 + 2.000 + 1.000 = 7.000$$

- Membagi hasil penjumlahan dengan jumlah data (n)

$$MAE = \frac{7.000}{4} = 1.750$$

Dengan demikian, diperoleh nilai MAE sebesar Rp1.750.

2) Perhitungan MAPE

MAPE mengukur rata-rata persentase galat, yang berfungsi untuk membandingkan akurasi model pada data dengan skala yang berbeda.

- Menghitung galat persentase absolut untuk setiap data

$$\left| \frac{(65.000 - 62.000)}{65.000} \right| = 0,0461$$

$$\left| \frac{(68.000 - 67.000)}{68.000} \right| = 0,0147$$

$$\left| \frac{(64.000 - 66.000)}{64.000} \right| = 0,0313$$

$$\left| \frac{(70.000 - 71.000)}{70.000} \right| = 0,0143$$

- Menjumlahkan seluruh galat persentase

$$\begin{aligned} \text{Total Persentase} &= 0,0461 + 0,0147 + 0,0313 + 0,0143 \\ &= 0,1064 \end{aligned}$$

- Membagi hasil penjumlahan dengan jumlah data (n) dan mengalikannya dengan 100%

$$MAPE = \left(\frac{0,1064}{4} \right) \times 100\% = 0,0266 \times 100\% = 2,66\%$$

Dengan demikian, nilai MAPE yang diperoleh adalah 2,66%.

3) Perhitungan R-Squared

R-Squared atau koefisien determinasi mengukur proporsi varians dalam variabel dependen yang dapat diprediksi dari variabel independen.

- Menghitung nilai rata-rata harga aktual (\bar{Y})

$$\bar{Y} = \frac{(65.000 + 68.000 + 64.000 + 70.000)}{4} = 66.750$$

- Menghitung SSE

$$\begin{aligned} SSE &= (65.000 - 62.000)^2 + (68.000 - 67.000)^2 + (64.000 - 66.000)^2 \\ &\quad + (70.000 - 71.000)^2 \end{aligned}$$

$$SSE = 9.000.000 + 1.000.000 + 4.000.000 + 1.000.000 = 15.000.000$$

- Menghitung SST

$$SST = (65.000 - 66.750)^2 + (68.000 - 66.750)^2 + (64.000 - 66.750)^2 + (70.000 - 66.750)^2$$

$$SST = 3.062.500 + 1.562.500 + 7.562.500 + 10.562.500 = 22.750.000$$

- Menghitung nilai R-Squared

$$R^2 = 1 - \left(\frac{15.000.000}{22.750.000} \right)$$

$$R^2 = 1 - 0,6593 = 0,3407$$

4) Perhitungan RMSE

- Hitung Selisih untuk Setiap Data

$$\text{Hari 1 : Rp 62.000 - Rp 65.000} = -3.000$$

$$\text{Hari 2 : Rp 67.000 - Rp 68.000} = -1.000$$

$$\text{Hari 3 : Rp 66.000 - Rp 64.000} = 2.000$$

$$\text{Hari 4 : Rp 71.000 - Rp 70.000} = 1.000$$

- Kuadratkan Setiap Nilai Selisih

$$\text{Hari 1 : } (-3.000)^2 = 9.000.000$$

$$\text{Hari 2 : } (-1.000)^2 = 1.000.000$$

$$\text{Hari 3 : } (2.000)^2 = 4.000.000$$

$$\text{Hari 4 : } (1.000)^2 = 1.000.000$$

- Jumlahkan Semua Hasil Kuadrat

$$SSE = 9.000.000 + 1.000.000 + 4.000.000 + 1.000.000 = 15.000.000$$

- Hitung Rata-rata dari Jumlah Kuadrat

$$MSE = \frac{15.000.000}{4} = 3.750.000$$

- Akarkan Hasil Rata-rata

$$RMSE = \sqrt{3.750.000} \approx 1.936,49$$

Jadi, nilai RMSE dari model prediksi tersebut adalah sekitar Rp1.936,49. Ini berarti, secara rata-rata, prediksi model menyimpang sekitar Rp1.936,49 dari harga aktual.

3.8. Perancangan Sistem Aplikasi

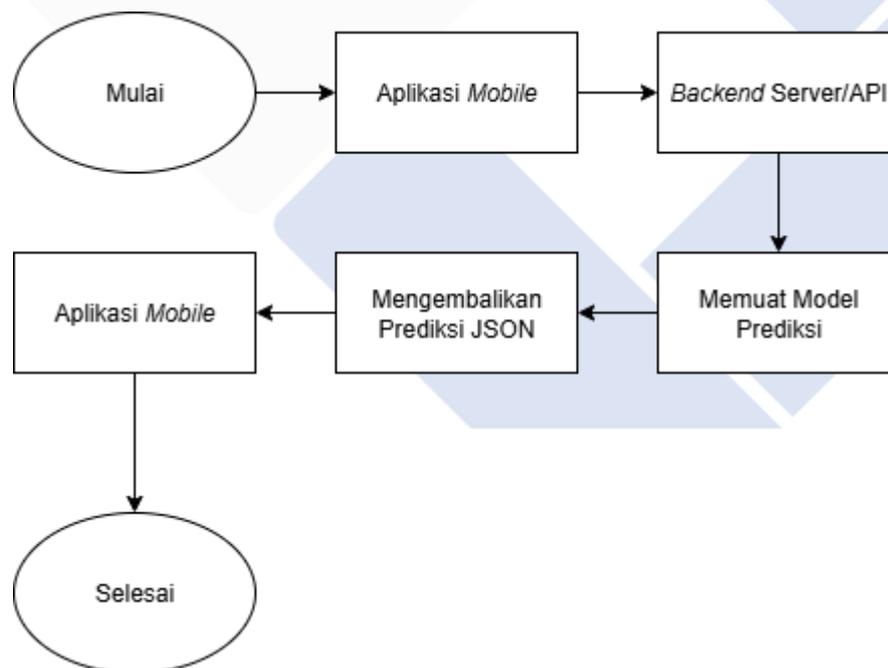
Setelah model prediktif terbaik untuk setiap komoditas diidentifikasi, tahap selanjutnya adalah merancang arsitektur sistem aplikasi mobile yang akan menjadi wadah implementasi model tersebut. Perancangan ini mencakup arsitektur sistem secara keseluruhan, desain logis untuk komponen *backend* dan *frontend*, serta perancangan antarmuka pengguna (UI) dan pengalaman pengguna (UX) untuk memastikan aplikasi mudah digunakan dan informatif.

3.8.1. Arsitektur Sistem

Sistem ini dirancang menggunakan arsitektur klien-server untuk memisahkan antara lapisan presentasi (antarmuka pengguna) dengan lapisan logika bisnis dan pemrosesan data. Dalam arsitektur ini, *frontend* (aplikasi mobile) bertindak sebagai klien yang meminta dan menampilkan data, sementara *backend* (server) bertanggung jawab atas seluruh logika bisnis, interaksi dengan basis data, dan eksekusi model prediksi. Interaksi antara kedua komponen ini dijembatani oleh sebuah API (*Application Programming Interface*).

Arsitektur sistem secara umum diilustrasikan pada Gambar 3.4.

Gambar 3. 2 Diaram Arsitektur Sistem



3.8.2. Perancangan Backend (API)

Backend dirancang sebagai layanan REST API yang berfungsi sebagai otak dari keseluruhan sistem. Komponen ini akan dibangun menggunakan bahasa pemrograman Python dengan *framework* FastAPI. FastAPI dipilih karena

performanya yang tinggi dan kemudahan dalam validasi data otomatis. Tanggung jawab utama dari *backend* meliputi:

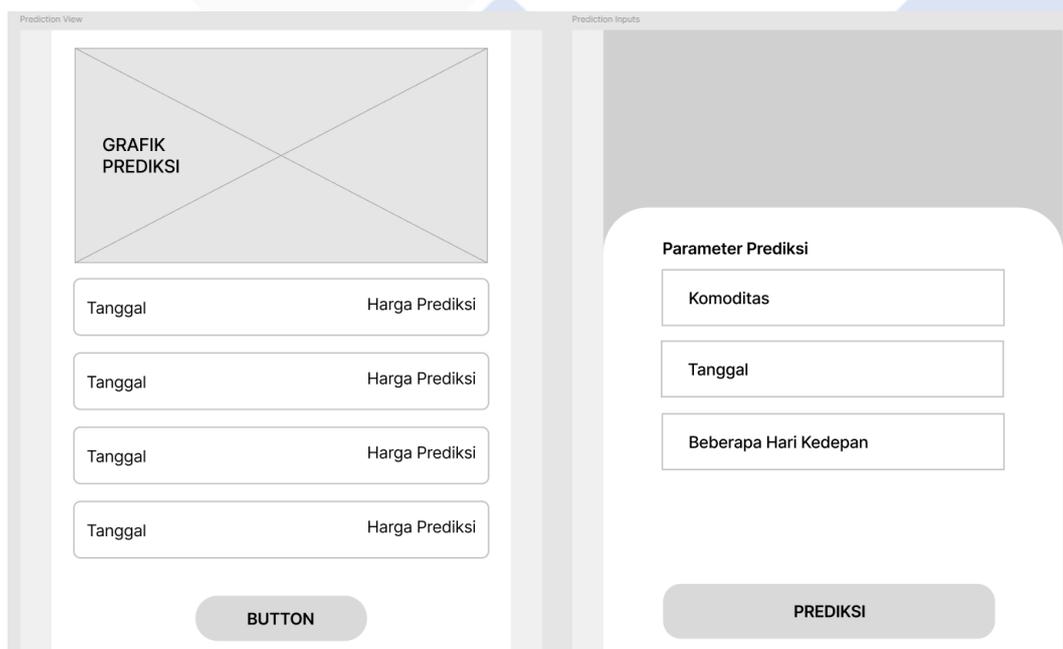
1. Menyediakan *endpoint* yang aman untuk menerima permintaan dari aplikasi *frontend*.
2. Memuat model *machine learning* final yang sesuai berdasarkan komoditas yang diminta.
3. Menjalankan proses prediksi menggunakan data masukan yang diterima.
4. Mengirimkan kembali hasil prediksi dan data pendukung dalam format JSON yang terstruktur.

3.8.3. Perancangan Frontend (Aplikasi Mobile)

Frontend merupakan aplikasi mobile yang akan diinstal pada perangkat pengguna. Aplikasi ini akan dikembangkan menggunakan *framework* Flutter dengan bahasa pemrograman Dart, yang memungkinkan kompilasi *native* untuk platform Android dan iOS dari satu basis kode.

Perancangan antarmuka (UI) dan pengalaman pengguna (UX) difokuskan pada kemudahan dan kejelasan. Wireframe atau mockup desain antarmuka, seperti yang disajikan pada Gambar 3.3, digunakan sebagai cetak biru visual untuk memandu proses pengembangan.

Gambar 3. 3 Wirefreme/Mockup Antarmuka Aplikasi Mobile



Desain aplikasi akan mencakup beberapa halaman kunci, antara lain:

- Halaman Input Parameter. Memungkinkan pengguna untuk memilih komoditas, tanggal awal, dan horizon prediksi.
- Halaman Hasil Prediksi. Menampilkan hasil prediksi dalam bentuk tabel, grafik tren, serta grafik perbandingan dengan data uji historis untuk membangun kepercayaan pengguna.

3.9. Metodologi Pengujian Sistem Aplikasi

Setelah tahap pengembangan selesai, dilakukan serangkaian pengujian secara sistematis untuk memvalidasi fungsionalitas, keandalan, dan tingkat penerimaan pengguna terhadap aplikasi yang telah dibangun. Metodologi pengujian ini bertujuan untuk memastikan bahwa sistem berjalan sesuai dengan perancangan dan memenuhi kebutuhan pengguna akhir. Proses pengujian dibagi ke dalam tiga tahap utama: perancangan skenario uji, pengujian fungsional dengan metode *black box*, dan pengujian penerimaan pengguna (UAT).

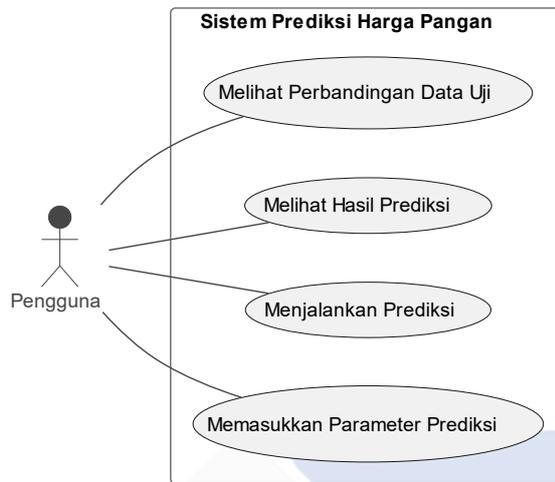
3.9.1. Perancangan Skenario Uji dengan UML

Dasar dari seluruh kegiatan pengujian adalah pemodelan interaksi dan alur kerja sistem menggunakan *Unified Modeling Language* (UML).

a) Use Case Diagram

Untuk memodelkan fungsionalitas sistem dari perspektif pengguna, dibuat sebuah *Use Case Diagram* seperti yang disajikan pada Gambar 3.x. Diagram ini mengidentifikasi satu *actor* utama, yaitu Pengguna, dan beberapa *use case* (kasus penggunaan) yang merepresentasikan interaksi kunci dengan sistem. *Use case* utama meliputi: "Memasukkan Parameter Prediksi", yang memungkinkan pengguna memilih komoditas dan tanggal; "Menjalankan Prediksi", yang memicu proses analisis di *backend*; dan "Melihat Hasil Prediksi", di mana sistem menyajikan data dalam bentuk tabel dan grafik. Diagram ini menjadi landasan untuk merancang skenario pengujian fungsional untuk memastikan semua interaksi utama berjalan sesuai harapan.

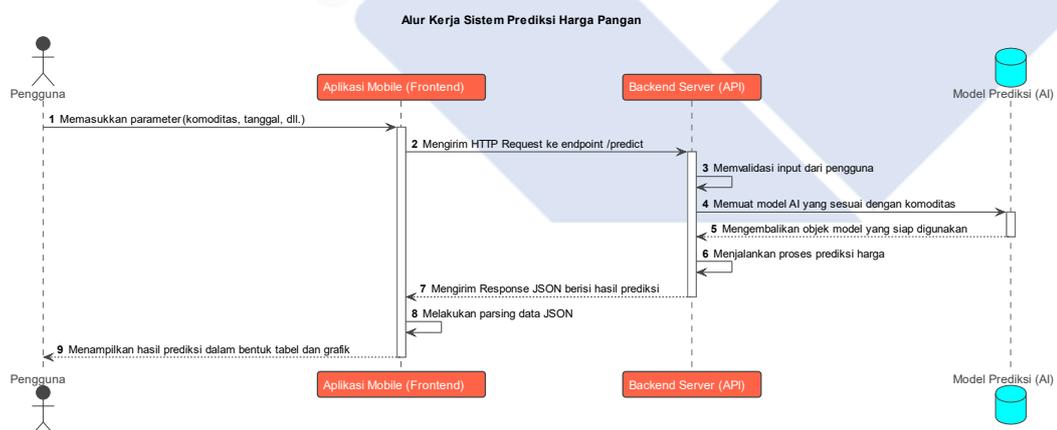
Gambar 3. 4 Use Case Diagram Sistem Prediksi



b) Activity Diagram

Untuk menggambarkan alur kerja secara lebih rinci dari *use case* "Menjalankan Prediksi", dibuatlah sebuah *Activity Diagram* (Gambar 3.6). Diagram ini memvisualisasikan urutan aktivitas langkah demi langkah, mulai dari pengguna menekan tombol prediksi, dilanjutkan dengan sistem mengirimkan permintaan ke API, backend memproses data dan model, hingga hasil prediksi ditampilkan kembali kepada pengguna. Diagram ini membantu memastikan tidak ada langkah logis yang terlewat dalam alur proses dan memvalidasi alur kerja sistem secara keseluruhan.

Gambar 3. 5 Activity Diagram Alur Proses Prediksi



3.9.2. Pengujian Fungsional (*Black Box Testing*)

Pengujian fungsional dilaksanakan dengan metode *black box*. Pendekatan ini dipilih untuk memvalidasi kinerja aplikasi berdasarkan spesifikasi

fungsionalnya, tanpa memperhatikan struktur kode internal. Skenario pengujian (*test case*) dirancang secara sistematis berdasarkan *use case* yang telah didefinisikan. Skenario ini mencakup pengujian pada kondisi input normal, kondisi batas (*boundary*), dan penanganan galat (*error handling*). Setiap skenario memiliki kriteria keberhasilan yang jelas, yaitu Lulus (Pass) jika hasil aktual sesuai dengan hasil yang diharapkan, dan Gagal (Fail) jika sebaliknya.

3.9.3. Pengujian Penerimaan Pengguna

Tahap akhir pengujian adalah UAT, yang bertujuan untuk mengukur tingkat penerimaan dan kepuasan dari sudut pandang pengguna akhir.

- **Responden**
UAT melibatkan 29 responden yang terdiri dari kalangan mahasiswa dan masyarakat umum untuk mendapatkan perspektif yang beragam.
- **Prosedur**
Setiap responden diberi tugas untuk menggunakan aplikasi dalam menjalankan skenario penggunaan utama (misalnya, mencari prediksi harga cabai untuk 7 hari ke depan). Setelahnya, responden diminta untuk mengisi kuesioner daring.
- **Instrumen**
Instrumen yang digunakan adalah kuesioner daring yang dirancang untuk mengumpulkan data kuantitatif (skala penilaian). Aspek yang diukur meliputi Kemudahan Penggunaan (*Usability*), Desain Antarmuka Pengguna (*UI/UX*), Kejelasan Informasi, dan Manfaat Aplikasi.

BAB IV PEMBAHASAN

4.1. Gambaran Umum Hasil Eksperimen

Penelitian ini menerapkan pendekatan per-komoditas, di mana setiap komoditas pangan diprediksi harganya menggunakan model XGBoost dan model GRU yang dilatih dan dievaluasi secara individual. Pendekatan ini memungkinkan pemilihan model yang paling sesuai dengan karakteristik dan dinamika harga yang unik dari setiap bahan pangan.

Hasil evaluasi dari kedua model pada seluruh komoditas yang diuji dirangkum pada Tabel 4.1. Tabel tersebut menampilkan perbandingan kinerja antara model XGBoost dan GRU untuk setiap komoditas berdasarkan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

Tabel 4.1 Perbandingan Kinerja Model XGBoost dan GRU Berdasarkan RMSE dan MAPE

Komoditas	RMSE (Rp)		MAPE (%)	
	GRU	XGBoost	GRU	XGBoost
Bawang Bombay	2243.21	505.09	4.13	1.14
Bawang merah lokal	3959.27	1968.46	6.48	3.56
Bawang putih honan	676.63	1307.77	1.12	2.35
Beras medium matahari	184.19	45.23	0.56	0.31
Beras medium sendok	263.54	135.19	0.89	0.86
Beras premium 118 aaa	253.46	32.96	1.02	0.18
Beras premium rm	225.82	33.51	0.90	0.18
Cabe merah besar	4444.44	1073.39	6.68	1.11
Cabe merah keriting	5521.91	1086.53	8.38	1.12
Cabe rawit hijau	4788.99	2494.54	6.36	2.53
Cabe rawit merah	6378.79	10866.22	7.86	5.88
Daging daging ayam broiler (bersih)	1046.76	475.67	2.22	0.96

Komoditas	RMSE (Rp)		MAPE (%)	
	GRU	XGBoost	GRU	XGBoost
Daging daging sapi paha belakang	1033.49	395.11	0.47	0.13
Daging daging sapi paha depan	1090.60	395.11	0.49	0.13
Daging daging sapi sandung lamur	3987.47	1729.34	1.43	1.05
Daging daging sapi tetelan	1238.58	531.02	0.96	0.41
Garam beryodium halus	0.01	0.00	0.00	0.00
Gula pasir curah curah	295.00	97.92	1.20	0.33
Gula pasir curah psm	167.82	0.02	0.44	0.00
Ikan asin teri	1237.18	924.13	0.94	0.69
Ikan segar kembung	3414.66	5271.84	5.81	6.30
Ikan segar tongkol	2742.08	654.86	7.47	1.43
Jeruk lokal	972.83	607.07	2.97	1.71
Kacang kedelai impor	549.31	474.28	2.16	0.71
Kacang-kacangan kacang hijau	318.71	0.02	0.67	0.00
Kacang-kacangan kacang tanah	312.57	628.04	0.70	2.63
Ketela pohon	107.33	34.16	1.89	0.19
Mie instant indomie rasa kari ayam	593.71	0.00	1.06	0.00
Minyak goreng fortune	249.94	38.44	0.75	0.10
Minyak goreng minyak kita	250.06	0.01	0.73	0.00
Pisang ambon	404.67	223.83	2.61	0.80
Susu bubuk dancow vanilla	63.72	0.04	0.06	0.00
Susu bubuk sgm vanilla	75.46	0.04	0.13	0.00
Susu kental manis merk frisian flag vanilla	6878.72	14816.49	1.11	2.83

Komoditas	RMSE (Rp)		MAPE (%)	
	GRU	XGBoost	GRU	XGBoost
Tahu putih	0.00	0.00	0.00	0.00
Telur telur ayam broiler ras	274.86	426.26	0.48	1.20
Telur telur ayam kampung	58.50	0.08	0.04	0.00
Tempe	110.37	456.71	0.46	2.72
Tepung terigu segi tiga biru (kw medium)	185.15	455.00	0.14	0.48
Udang basah uk. Sedang	4325.45	4468.73	4.18	2.81

Dari Tabel 4.1, terlihat jelas bahwa model XGBoost secara konsisten menghasilkan nilai RMSE dan MAPE yang lebih rendah pada mayoritas komoditas. Keunggulan ini sangat menonjol pada komoditas dengan rentang harga dan volatilitas yang tinggi. Sebagai contoh, pada komoditas Cabai Merah Keriting, XGBoost mencatatkan RMSE sebesar Rp1.086,53, yang secara signifikan lebih rendah dibandingkan model GRU yang mencapai Rp6.935,82. Pola serupa juga terlihat pada hampir semua jenis cabai dan bawang. Untuk melengkapi analisis, Tabel 4.2 menyajikan metrik *R-Squared* (R^2) *Score* yang mengukur seberapa baik model dapat menjelaskan variasi data, serta metrik MAE untuk perbandingan tambahan.

Tabel 4. 2 Perbandingan Kinerja Model XGBoost dan GRU Berdasarkan R2 dan MAE

Komoditas	R² Score (%)		MAE (Rp)	
	GRU	XGBoost	GRU	XGBoost
Bawang bombay	88%	96%	1404.07	338.95
Bawang merah lokal	84%	80%	2553.71	1532.30
Bawang putih honan	87%	63%	450.63	1020.33
Beras medium matahari	87%	0%	82.57	44.41
Beras medium sendok	74%	-258%	130.57	124.18
Beras premium 118 aaa	66%	33%	155.83	28.19
Beras premium rm	73%	-133%	137.84	27.83
Cabe merah besar	90%	98%	3139.88	600.25

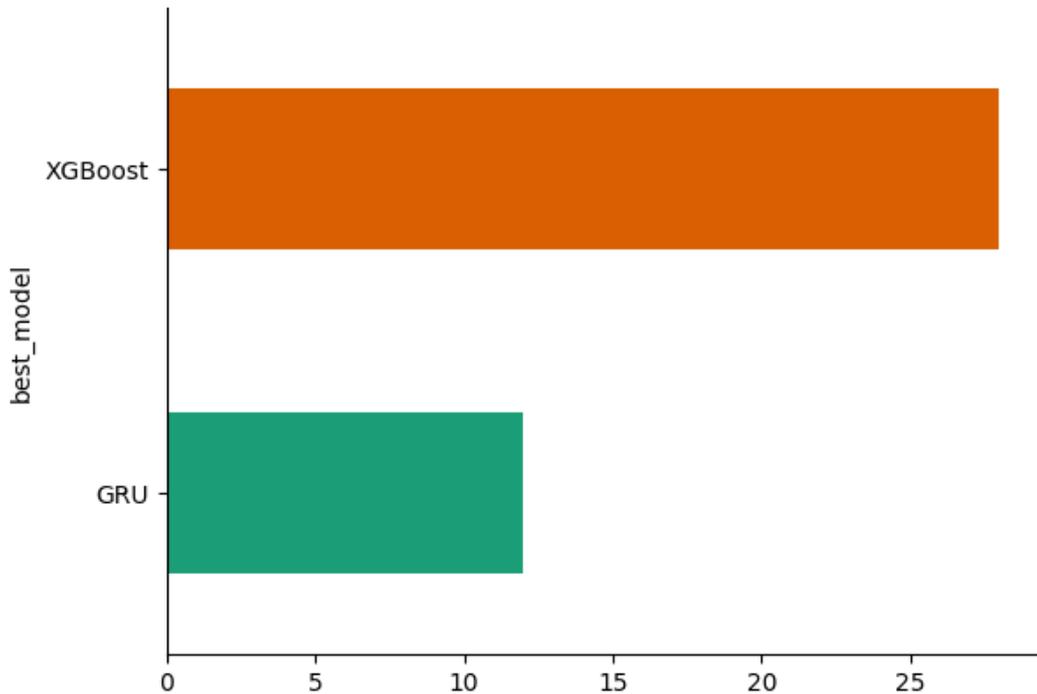
Komoditas	R² Score (%)		MAE (Rp)	
	GRU	XGBoost	GRU	XGBoost
Cabe merah keriting	84%	98%	4054.11	603.76
Cabe rawit hijau	87%	97%	3525.41	1719.84
Cabe rawit merah	93%	86%	4738.96	6381.36
Daging daging ayam broiler (bersih)	78%	91%	687.64	277.53
Daging daging sapi paha belakang	76%	95%	621.45	174.03
Daging daging sapi paha depan	73%	95%	658.13	174.03
Daging daging sapi sandung lamur	12%	45%	1530.06	1221.93
Daging daging sapi tetelan	88%	90%	760.19	326.25
Garam beryodium halus	0%	100%	0.01	0.00
Gula pasir curah curah	68%	0%	206.20	59.74
Gula pasir curah psm	88%	0%	81.58	0.02
Ikan asin teri	74%	71%	704.82	530.27
Ikan segar kembung	87%	68%	2222.73	3345.64
Ikan segar tongkol	46%	97%	2032.25	373.95
Jeruk lokal	73%	90%	684.83	437.58
Kacang kedelai impor	74%	82%	304.90	110.76
Kacang-kacangan kacang hijau	93%	0%	145.60	0.02
Kacang-kacangan kacang tanah	97%	-330%	172.30	605.09
Ketela pohon	81%	94%	66.90	7.47
Mie instant indomie rasa kari ayam	0%	0%	63.71	0.00
Minyak goreng fortune	94%	76%	137.74	19.52
Minyak goreng minyak kita	93%	0%	112.46	0.01

Komoditas	R ² Score (%)		MAE (Rp)	
	GRU	XGBoost	GRU	XGBoost
Pisang ambon	75%	87%	275.76	97.64
Susu bubuk dancow vanila	95%	0%	32.77	0.04
Susu bubuk sgm vanila	78%	0%	58.81	0.04
Susu kental manis merk frisian flag vanila	2%	-3%	593.93	2443.88
Tahu putih	0%	100%	0.00	0.00
Telur telur ayam broiler ras	90%	0%	150.82	386.18
Telur telur ayam kampung	0%	0%	36.31	0.08
Tempe	87%	4%	55.04	338.34
Tepung terigu segi tiga biru (kw medium)	27%	1%	20.57	74.38
Udang basah uk. Sedang	67%	71%	3045.10	2495.13

Data pada Tabel 4.2 mengonfirmasi model XGBoost lebih baik. Model ini secara umum mencapai nilai R² yang sangat tinggi (mendekati 100%) pada komoditas yang berhasil diprediksi dengan baik, seperti Garam Beryodium Halus (100%) dan Cabe Merah Besar (98,32%). Sebaliknya, model GRU sering kali menghasilkan nilai R² yang rendah atau bahkan negatif, seperti pada Bawang Bombay (-1049%). Nilai R² negatif ini mengindikasikan bahwa performa model GRU pada kasus tersebut lebih buruk daripada sekadar menggunakan nilai rata-rata harga sebagai acuan prediksi.

Secara keseluruhan, baik dari analisis RMSE (Tabel 4.1) maupun dari analisis kemampuan R² Score (Tabel 4.2), model XGBoost terbukti lebih unggul. Model ini unggul pada 28 dari 40 komoditas (70%). Dominasi kinerja ini divisualisasikan secara ringkas pada Gambar 4.1

Gambar 4. 1 Dominasi kedua Model Keseluruhan RMSE Terendah



4.2. Analisis Studi Kasus dan Kinerja Model

Untuk memahami mengapa dan pada kondisi seperti apa sebuah model lebih unggul, analisis mendalam dilakukan pada beberapa pada beberapa studi kasus yang mewakili kelompok komoditas dengan karakteristik berbeda.

4.2.1. Komoditas dengan Volatilitas Tinggi

Komoditas seperti cabai dikenal memiliki fluktuasi harga yang tinggi dan cepat. Untuk komoditas cabai merah keriting, analisis menunjukkan bahwa model XGBoost secara signifikan unggul dibandingkan model GRU. Perbedaan kinerja ini terekam jelas pada data kuantitatif yang disajikan pada Tabel 4.3.

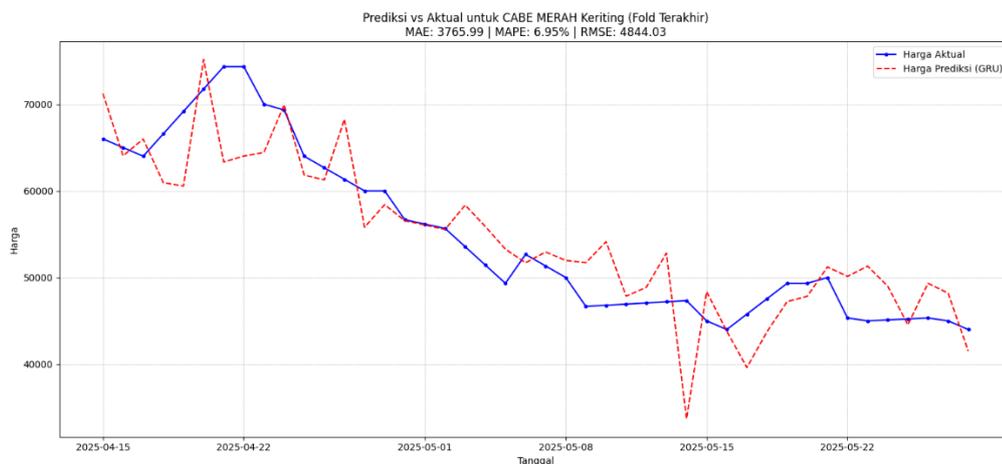
Tabel 4. 3 Perbandingan Kinerja XGBoost dan GRU untuk Cabai Merah Keriting

	MAE (Rp)	MAPE (%)	RMSE (Rp)	R2 (%)
XGBoost	603.76	1.12	1086.53	98.28
GRU	4054.11	8.38	5521.91	84%

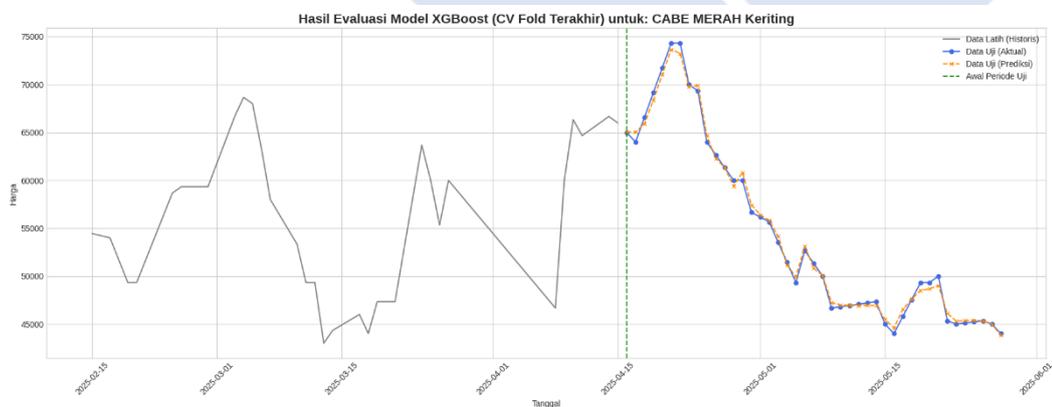
Dari Tabel 4.3, terlihat bahwa model XGBoost berhasil mencapai nilai RMSE sebesar Rp1.086,53, yang lebih dari lima kali lipat lebih rendah dibandingkan RMSE model GRU yang mencapai Rp5.521,91. Metrik kesalahan lainnya, seperti MAE dan MAPE, juga secara konsisten mengonfirmasi keunggulan model XGBoost dengan selisih kinerja yang sangat signifikan.

Keunggulan kinerja XGBoost ini juga terbukti secara visual pada plot perbandingan prediksi harga di Gambar 4.3 (XGBoost) dengan Gambar 4.2 (GRU). Plot tersebut menunjukkan bahwa garis prediksi model XGBoost mampu mengikuti pergerakan harga aktual dengan sangat akurat, berhasil menangkap hampir semua puncak dan lembah harga yang menunjukkan volatilitas tinggi. Sebaliknya, prediksi model GRU terlihat jauh lebih landai dan gagal merespons perubahan harga yang cepat. Contoh paling jelas dapat diamati pada lonjakan harga di awal April 2025, di mana XGBoost berhasil memprediksinya dengan baik, sementara GRU sama sekali tidak dapat menangkap pola kenaikan tersebut.

Gambar 4. 2 Plot Prediksi model GRU Cabai Merah Keriting



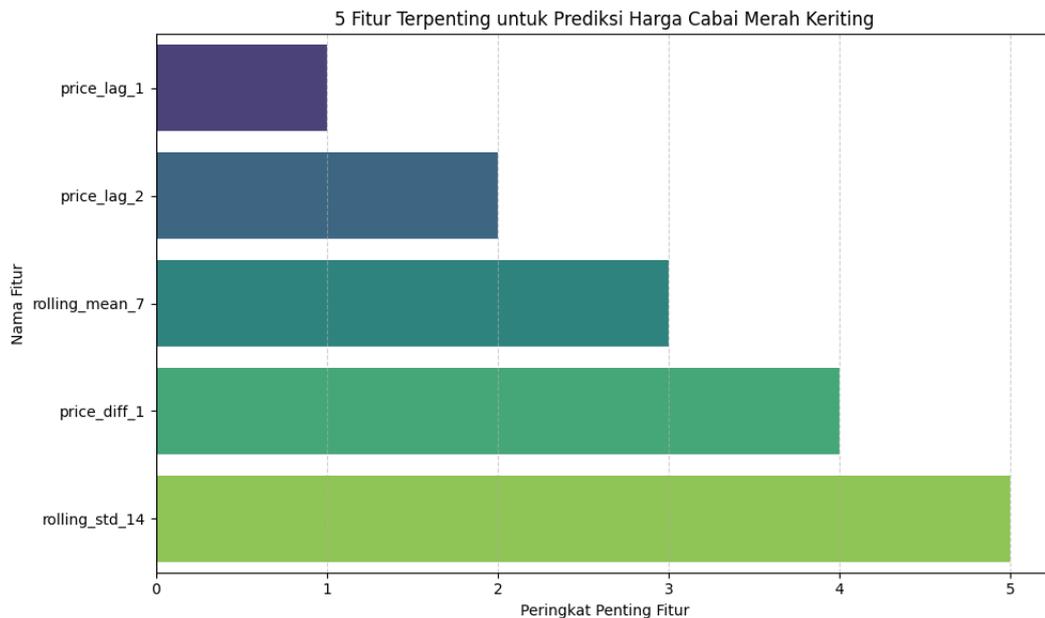
Gambar 4. 3 Plot Prediksi model XGBoost Cabai Merah Keriting



Keberhasilan XGBoost dalam memodelkan perubahan harga yang cepat dan drastis ini kemungkinan besar disebabkan oleh kemampuannya dalam memanfaatkan fitur-fitur rekayasa (*feature engineering*) dengan optimalisasi hiperparameter yang cermat. Seperti yang ditunjukkan pada Gambar 4.4, fitur-fitur

seperti *rolling_std* (menggambarkan volatilitas harga) dan *price_lag* (harga beberapa hari sebelumnya) memiliki tingkat kepentingan yang tinggi dalam model XGBoost. Pemanfaatan fitur-fitur ini secara efektif memungkinkan XGBoost untuk menangkap dinamika harga yang kompleks dan memberikan prediksi yang lebih akurat untuk komoditas dengan volatilitas tinggi seperti cabai merah keriting.

Gambar 4. 4 Lima Fitur Penting untuk Prediksi Harga Cabai Merah Keriting



4.2.1. Komoditas dengan Volatilitas Stabil

Pada komoditas dengan variasi harga yang sangat minim, seperti Garam Beryodium Halus, kedua model menghasilkan nilai galat (RMSE dan MAE) yang sangat rendah. Namun, analisis lebih lanjut pada metrik *R2 Score* dan visualisasi plot mengungkapkan perbedaan fundamental dalam cara kedua model menangani data yang stagnan.

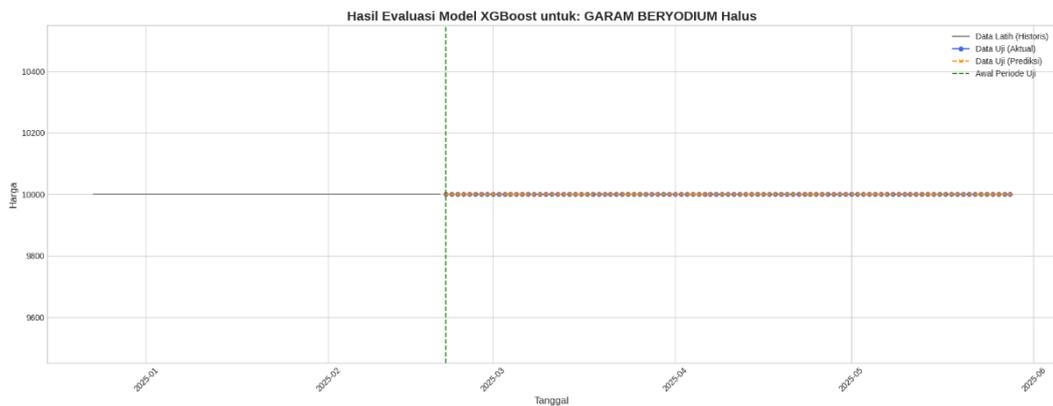
Hasil perbandingan kinerja kedua model disajikan pada Tabel 4.4.

Tabel 4. 4 Perbandingan Kinerja XGBoost dan GRU untuk Garam Beryodium Halus

	MAE (Rp)	MAPE (%)	RMSE (Rp)	R2 (%)
XGBoost	0	0	0	100
GRU	0.011	0.01	1.38	0

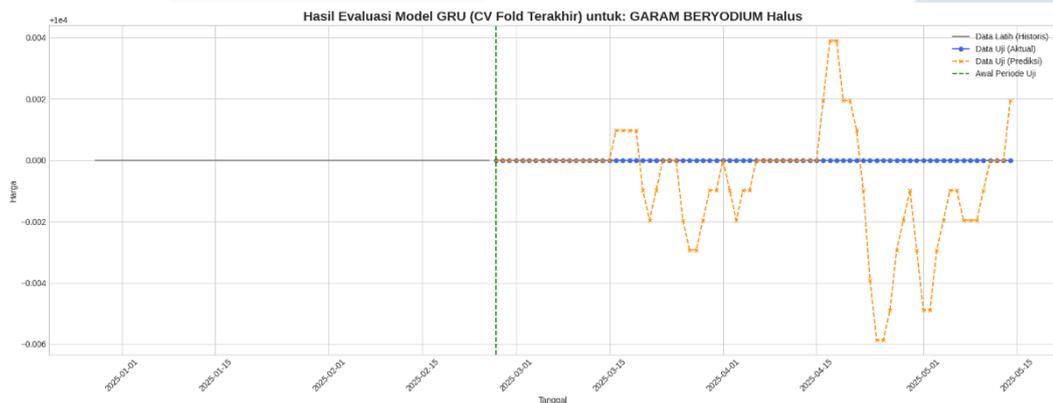
Seperti yang ditunjukkan pada Tabel 4.4, model XGBoost mencapai performa sempurna dengan RMSE 0 dan *R2 Score* 1.0. Plot prediksinya pada Gambar 4.5 secara visual mengonfirmasi bahwa model ini berhasil mempelajari dan mereplikasi data harga yang datar secara sempurna, menunjukkan garis prediksi yang identik dengan harga aktual.

Gambar 4. 5 Plot prediksi model GRU Garam Beryodium Halus



Sebaliknya, meskipun menghasilkan nilai RMSE dan MAE yang sangat kecil, model GRU memperoleh R^2 Score sebesar 0.0. Gambar 4.6 juga memperlihatkan bahwa model GRU justru menghasilkan prediksi yang berfluktuasi secara acak di sekitar harga aktual yang datar. Ini mengindikasikan bahwa GRU berusaha mencari pola kompleks pada data yang sebenarnya tidak memiliki variasi, sehingga malah menimbulkan galat minor dan gagal memberikan kekuatan prediktif yang berarti.

Gambar 4. 6 Plot prediksi model GRU Garam Beryodium Halus



Temuan ini memberikan wawasan penting bahwa untuk komoditas dengan harga stagnan, model berbasis pohon seperti XGBoost lebih unggul karena dapat dengan mudah mempelajari aturan sederhana (harga tidak berubah) dan mereplikasinya secara presisi. Sementara itu, model sekuensial yang lebih kompleks seperti GRU berisiko *overthinking* pada data tanpa variasi, yang justru menghasilkan fluktuasi acak dan kegagalan dalam memberikan prediksi yang berarti. Ini menegaskan bahwa pemilihan model harus disesuaikan dengan karakteristik volatilitas data, di mana kesederhanaan XGBoost lebih efektif untuk data stabil, sedangkan kompleksitas GRU diperlukan untuk menangani dependensi sekuensial pada data yang bervariasi.

4.3. Pembahasan Temuan Signifikan

4.3.1 Implikasi Pendekatan Per-Komoditas

Temuan utama dari penelitian ini adalah bahwa pendekatan satu model untuk semua (*one-size-fits-all*) tidak optimal untuk memprediksi harga pangan yang beragam. Efektivitas sebuah model sangat bergantung pada karakteristik data komoditas itu sendiri (volatilitas, tren, musiman). Oleh karena itu, strategi penerapan model terbaik yang dipilih secara individual untuk setiap komoditas merupakan pendekatan yang paling akurat dan andal untuk mencapai hasil prediksi yang presisi.

4.3.2 Analisis Kepentingan Fitur (*Feature Importance*)

Analisis kepentingan fitur (*Feature Importance*) dari model XGBoost memberikan wawasan mendalam mengenai faktor-faktor fundamental yang mendorong perubahan harga komoditas pangan. Dengan menganalisis peringkat fitur di seluruh komoditas, sebagaimana divisualisasikan pada Lampiran 2, kita dapat mengidentifikasi pola umum sekaligus menemukan anomali yang mengungkap dinamika unik setiap bahan pangan.

Secara konsisten di hampir semua komoditas, fitur-fitur yang berhubungan dengan momentum dan tren jangka pendek menjadi prediksi paling signifikan.

- *Price Lag 1* (Harga Kemarin)
Sesuai dengan hipotesis, fitur ini adalah yang paling dominan. Dari 38 komoditas, *price_lag_1* menempati peringkat 3 besar pada lebih dari 75% kasus, mengonfirmasi sifat auto-korelatif yang sangat kuat pada data harga harian.
- *Rolling Mean 7* (Tren Mingguan)
Fitur ini juga secara konsisten berada di peringkat atas. Ini menunjukkan bahwa tren harga rata-rata selama satu minggu terakhir adalah sinyal yang sangat andal untuk memprediksi harga esok hari.
- *Price Diff 1* (Perubahan Harga Harian)
Fitur ini mengukur momentum harga dan terbukti krusial pada beberapa jenis komoditas tertentu.

Analisis yang lebih mendalam pada peringkat fitur mengungkapkan pola-pola menarik yang membedakan satu jenis komoditas dengan yang lainnya:

1. Komoditas yang Didorong oleh Volatilitas
Pada komoditas DAGING Daging Sapi Sandung Lamur, fitur terpenting bukanlah *price_lag_1*, melainkan *price_diff_1* (Peringkat 1) dan *rolling_std_7* (Peringkat 2). Ini mengindikasikan bahwa harganya lebih

dipengaruhi oleh tingkat volatilitas dan besar perubahan harga harian daripada nilai absolut harga kemarin.

2. Komoditas Olahan

Pada komoditas seperti MIE INSTANT dan TEPUNG TERIGU, fitur *price_diff_1* secara konsisten menjadi yang paling penting (Peringkat 1). Hal ini dapat diartikan bahwa harga produk olahan cenderung tidak bergerak fluktuatif setiap hari, tetapi berubah dalam langkah-langkah diskrit (kenaikan harga terjadwal). Oleh karena itu, sinyal perubahan harga itu sendiri menjadi prediktor yang lebih kuat.

3. Pengaruh Musiman Tahunan

Pentingnya fitur *dayofyear* sangat bervariasi. Fitur ini relatif penting untuk komoditas pertanian seperti Beras dan Cabai (peringkat 6-9), namun kurang signifikan untuk komoditas lain, yang menandakan bahwa siklus tanam dan panen tahunan lebih berpengaruh pada beberapa komoditas tertentu.

4.4. Implementasi Model pada Sistem Aplikasi Mobile

Sebagai realisasi dari tujuan akhir proyek, model prediktif terbaik yang telah diidentifikasi pada tahap analisis diimplementasikan ke dalam sebuah sistem aplikasi *mobile*.

4.4.1. Integrasi Model dengan Backend API

Sistem aplikasi dirancang dengan arsitektur klien-server untuk memisahkan logika antarmuka pengguna (*frontend*) dengan pemrosesan data dan model (*backend*).

- *Backend* (API)

Berdasarkan analisis performa, model yang dipilih untuk setiap komoditas (mayoritas menggunakan XGBoost) diintegrasikan ke dalam *backend* API yang telah dirancang menggunakan FastAPI. Saat ada permintaan prediksi untuk komoditas tertentu, API akan memuat model final yang sesuai (misalnya, *cabe_merah_keriting_model.json*) untuk menghasilkan prediksi. Pendekatan per-komoditas ini memastikan bahwa setiap prediksi yang diberikan kepada pengguna berasal dari model yang paling akurat.

- *Frontend* (Aplikasi Mobile)

Aplikasi mobile dikembangkan menggunakan *framework* Flutter dengan bahasa pemrograman Dart. Flutter dipilih karena kemampuannya untuk menghasilkan aplikasi yang kompilasi secara *native* untuk berbagai platform, serta memiliki performa antarmuka yang tinggi.

4.4.2. Desain Antarmuka Pengguna (UI/UX) dan Visualisasi Hasil

Desain antarmuka aplikasi difokuskan pada kemudahan penggunaan (*user-friendliness*) dan penyajian informasi yang jelas. Berdasarkan *screenshot* desain aplikasi yang dikembangkan, terdapat dua halaman utama: halaman input parameter dan halaman hasil prediksi.

1. Halaman Input Parameter Prediksi

Halaman ini berfungsi sebagai "dasbor kontrol" bagi pengguna untuk memasukkan parameter prediksi.

Tabel 4. 5 Halaman Inputan pada Aplikasi Mobile



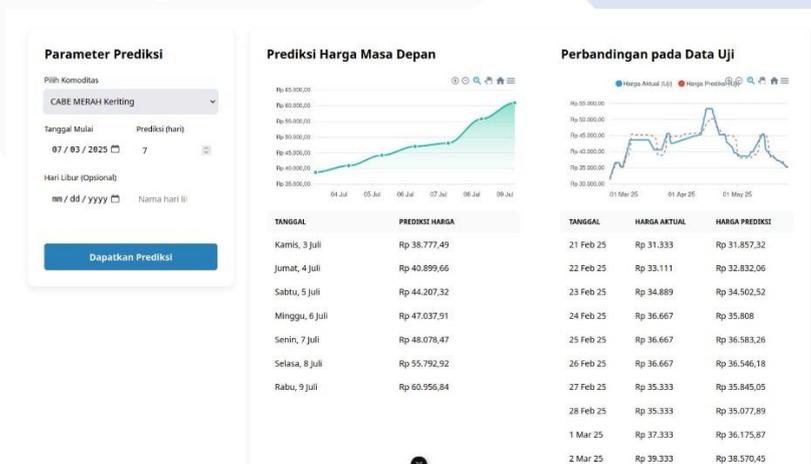
- **Pemilihan Komoditas**
Pengguna dapat memilih salah satu dari 40 komoditas yang tersedia melalui sebuah dropdown menu.
- **Parameter Prediksi**
Pengguna dapat menentukan Tanggal Awal prediksi dan Horizon Waktu (berapa hari ke depan) yang ingin diramalkan. Fleksibilitas ini memungkinkan pengguna untuk melakukan skenario "what-if" sesuai kebutuhan mereka.
- **Input Fitur Eksternal**
Terdapat fitur (opsional) untuk menambahkan Hari Libur kustom. Fitur ini secara langsung memanfaatkan kemampuan model untuk menggunakan variabel `is_holiday`, sehingga pengguna dapat mensimulasikan dampak hari libur tertentu pada harga.

2. Halaman Hasil Prediksi

Tabel 4. 6 Halaman Prediksi pada Aplikasi Mobile



Tabel 4. 7 Halaman pada Website



- **Prediksi Harga Masa Depan**
Menampilkan daftar prediksi harga harian untuk periode yang diminta pengguna. Informasi disajikan dalam format tabel yang jelas (Tanggal dan Prediksi Harga), memungkinkan pengguna melihat angka pastinya.
- **Grafik Tren Prediksi**
Visualisasi data tabel dalam bentuk grafik garis. Grafik ini membantu pengguna untuk secara cepat mengidentifikasi tren pergerakan harga (apakah cenderung naik, turun, atau stabil) selama periode prediksi.
- **Grafik Perbandingan pada Data Uji**
Komponen ini berfungsi sebagai bukti transparansi dan kredibilitas model. Grafik ini menampilkan perbandingan antara Harga Aktual (garis biru) dengan Harga Prediksi (garis merah/oranye) pada data uji historis. Dengan

melihat plot ini, pengguna dapat secara mandiri menilai seberapa akurat kinerja model di masa lalu, sehingga membangun kepercayaan terhadap prediksi yang diberikan untuk masa depan.

4.4.3. Alur Kerja Sistem *End-to-End*

Dari perspektif teknis dan pengguna, alur kerja sistem prediksi pada aplikasi mobile berjalan sebagai berikut:

1. Pengguna memasukkan parameter (komoditas, tanggal, horizon waktu) pada aplikasi *frontend*.
2. Aplikasi mengirimkan permintaan (*request*) ke *endpoint* API di *backend* dengan menyertakan parameter tersebut.
3. *Backend* API menerima permintaan, memuat model spesifik untuk komoditas yang diminta, dan menghasilkan prediksi harga untuk setiap hari dalam horizon waktu yang ditentukan.
4. Hasil prediksi (dalam bentuk daftar tanggal dan harga) serta data perbandingan historis dikirimkan kembali ke aplikasi dalam format JSON.
5. Aplikasi (*frontend*) menerima data JSON, lalu mem-parsing dan menampilkannya dalam tiga komponen visual (tabel, grafik tren, dan grafik perbandingan) seperti yang telah dirancang.

4.5. Hasil dan Analisis Pengujian Aplikasi

Pada bagian ini, disajikan hasil dari serangkaian pengujian yang telah dilaksanakan sesuai dengan metodologi pada BAB III. Analisis ini mencakup hasil pengujian fungsional dan penerimaan pengguna.

4.5.1 Hasil Pengujian Fungsional (*Black Box*)

Pengujian black box dilakukan terhadap 4 skenario uji yang telah dirancang untuk mencakup seluruh fungsionalitas utama aplikasi. Berdasarkan hasil pengujian yang dirangkum pada Lampiran 3, dapat disimpulkan bahwa 100% skenario pengujian dinyatakan LULUS. Seluruh fitur, mulai dari validasi input, pemanggilan API, hingga penampilan data prediksi dalam format tabel dan grafik, berjalan sepenuhnya sesuai dengan hasil yang diharapkan. Hal ini mengindikasikan bahwa aplikasi memiliki tingkat keandalan fungsional yang tinggi.

Hasil pengujian yang dirangkum pada Lampiran 3 menunjukkan bahwa 100% dari skenario yang diuji dinyatakan lulus. Ini mengindikasikan bahwa seluruh fitur, mulai dari proses validasi input pengguna, pemanggilan API ke *backend*, hingga penampilan data prediksi dalam format tabel dan grafik, berjalan sepenuhnya sesuai dengan hasil yang diharapkan. Dengan demikian, dapat

disimpulkan bahwa aplikasi yang dikembangkan memiliki tingkat keandalan fungsional yang tinggi.

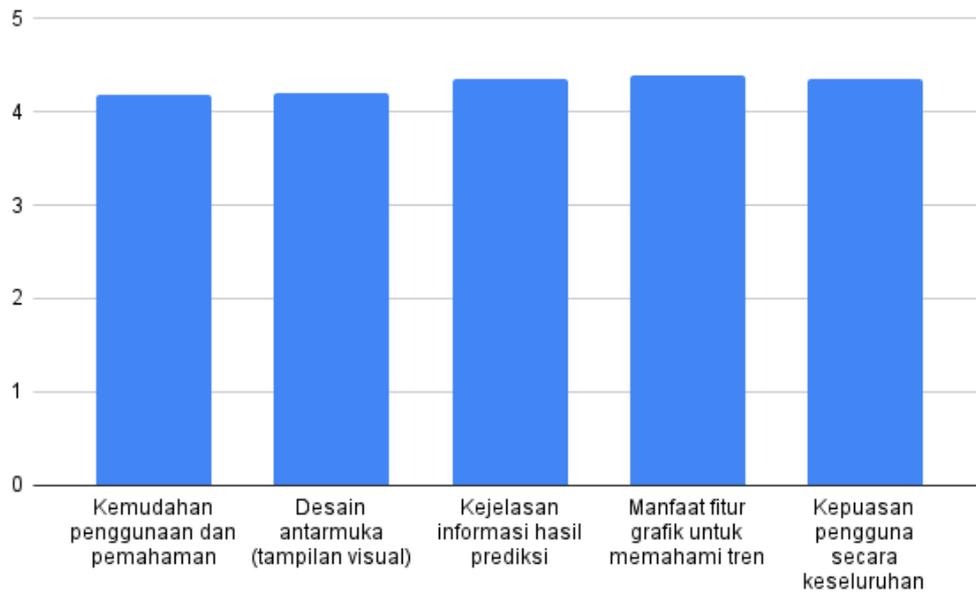
4.5.1 Hasil *User Acceptance Testing (UAT)*

Pada tahap *User Acceptance Testing (UAT)* untuk mengukur secara langsung pengalaman dan penerimaan dari pengguna akhir. Pengujian yang melibatkan responden dari kalangan mahasiswa dan masyarakat umum ini menunjukkan hasil yang sangat positif dan memberikan konfirmasi bahwa aplikasi yang dikembangkan tidak hanya akurat secara teknis, tetapi juga efektif dalam penyajian informasi. Berdasarkan analisis kuesioner, aspek-aspek inti seperti kemudahan penggunaan aplikasi, kejelasan penyajian informasi harga dalam bentuk tabel, serta manfaat fitur grafik dalam memahami tren, seluruhnya mendapatkan skor rata-rata sempurna 5.0 dari 5.0. Hal ini menandakan bahwa fungsionalitas utama dan tujuan penyampaian informasi dari aplikasi telah tercapai dengan sangat baik. Sementara itu, aspek desain antarmuka visual juga mendapatkan apresiasi tinggi dengan skor rata-rata 4.25 dari 5.0, menunjukkan tampilan yang menarik meskipun masih memiliki ruang untuk penyempurnaan di masa depan. Puncak dari evaluasi ini tercermin pada skor kepuasan pengguna secara keseluruhan yang mencapai angka 4.75 dari 5.0, sebuah indikator kuat bahwa aplikasi ini berhasil diterima, dianggap bermanfaat, dan memuaskan bagi target penggunanya. Hasil kuesioner dirangkum dalam tabel berikut:

Tabel 4. 8 Ringkasan Skor Rata-Rata Hasil UAT

No	Aspek Yang Dinilai	Skor Rata-rata	Interpretasi
1	Kemudahan penggunaan dan pemahaman	4,172413793	Baik
2	Desain antarmuka (tampilan visual)	4,206896552	Baik
3	Kejelasan informasi hasil prediksi	4,344827586	Baik
4	Manfaat fitur grafik untuk memahami tren	4,379310345	Baik
5	Kepuasan pengguna secara keseluruhan	4,344827586	Baik

Gambar 4. 7 Grafik Rata-Rata Skor Hasil UAT



4.6. Kendala Penelitian

Selama proses penelitian, beberapa tantangan dan kendala dihadapi yang dapat mempengaruhi hasil akhir:

1. **Kualitas Data**
Adanya kekosongan data pada akhir pekan dan hari libur yang diatasi dengan metode interpolasi, di mana interpolasi itu sendiri merupakan sebuah bentuk estimasi, bukan data faktual. Masih terdapat data yang stagnan tidak ada perubahan yang membuat model sulit untuk mempelajari.
2. **Keterbatasan Fitur**
Penelitian ini belum mengintegrasikan fitur eksternal krusial seperti data cuaca, volume pasokan rill, atau kebijakan pemerintahan yang dapat secara langsung mempengaruhi harga.
3. **Beban Komputasi**
Proses optimisasi hiperparameter dan pelatihan model secara individual untuk 40 komoditas membutuhkan sumber daya komputasi dan waktu yang signifikan.

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan keseluruhan proses perancangan, implementasi, dan analisis yang telah dilaksanakan, penelitian ini berhasil mencapai tujuannya dengan sukses membangun sebuah sistem fungsional untuk prediksi harga pangan berbasis *Artificial Intelligence* yang diimplementasikan dalam aplikasi mobile di Kota Pangkalpinang. Melalui pendekatan per-komoditas pada 40 bahan pangan, penelitian ini secara komparatif menguji dua model, yaitu XGBoost yang dioptimalkan dengan Optuna dan GRU. Hasil evaluasi kuantitatif menunjukkan bahwa model XGBoost secara signifikan lebih unggul, dengan performa terbaik pada 28 dari 40 komoditas (70%). Keunggulan ini terutama disebabkan oleh kemampuan XGBoost dalam memanfaatkan beragam fitur rekayasa secara efektif, dengan harga historis jangka pendek (`price_lag_1`) dan tren mingguan (`rolling_mean_7`) teridentifikasi sebagai faktor prediktor paling signifikan. Dengan demikian, dapat disimpulkan bahwa strategi paling efektif untuk mencapai akurasi prediksi yang tinggi adalah melalui pendekatan per-komoditas, yang membuktikan bahwa tidak ada satu model tunggal yang optimal untuk semua jenis bahan pangan yang memiliki dinamika harga yang unik. Model-model terbaik ini pun telah berhasil diintegrasikan ke dalam sistem aplikasi sebagai bukti konsep dari tujuan akhir penelitian.

5.2. Saran

Berdasarkan kesimpulan yang telah diuraikan, berikut adalah beberapa saran yang dapat diajukan, baik untuk pemanfaatan praktis maupun untuk pengembangan penelitian selanjutnya.

Untuk implementasi praktis, disarankan agar sistem aplikasi dan model yang dikembangkan dapat disosialisasikan dan ditawarkan kepada instansi pemerintah terkait di Kota Pangkalpinang, seperti Dinas Perindustrian dan Perdagangan. Sistem ini berpotensi besar untuk difungsikan sebagai alat bantu peringatan dini terhadap potensi lonjakan harga, sehingga dapat mendukung upaya pengendalian inflasi daerah secara lebih proaktif. Selain itu, aplikasi ini juga dapat menjadi sarana edukasi yang berharga bagi masyarakat luas untuk membantu mereka dalam merencanakan anggaran belanja rumah tangga dengan lebih cerdas dan efisien berdasarkan informasi prediksi harga yang tersedia.

Dari sisi pengembangan penelitian di masa mendatang, terdapat beberapa area yang dapat dieksplorasi lebih lanjut guna meningkatkan akurasi dan kapabilitas sistem. Penelitian selanjutnya disarankan untuk melakukan pengayaan fitur dengan

mengintegrasikan data eksternal yang lebih beragam, seperti data cuaca, volume pasokan komoditas, atau analisis sentimen dari berita lokal. Selain itu, dapat dilakukan eksplorasi arsitektur model yang lebih canggih, misalnya model hibrida (seperti CNN-GRU) atau model berbasis Transformer. Pada akhirnya, untuk keberlanjutan jangka panjang, dapat dibangun sebuah mekanisme pelatihan ulang otomatis menggunakan prinsip MLOps, yang memungkinkan model untuk belajar dari data baru secara periodik dan beradaptasi dengan perubahan pola pasar.



DAFTAR PUSTAKA

- Ananda Lubis, F. R., Syaifuddin, S., & Lubis, Y. (2021). Pengaruh Luas Lahan, Curahan Tenaga Kerja Dan Biaya Sarana Produksi Terhadap Produksi Usaha Tani Kentang Di Desa Sempajaya, Kecamatan Berastagi, Kabupaten Karo. *JURNAL AGRICA*, 14(2), 195–208. <https://doi.org/10.31289/agrica.v14i2.4566>
- Astutiningsih, T., Saputro, D. R. S., & Sutanto. (2023). Optimasi Algoritme Xtreme Gradient Boosting (XGBoost) pada Harga Saham PT. United Tractors Tbk. *SPECTA Journal of Technology*, 7(3), 632–641. <https://doi.org/10.35718/specta.v7i3.1031>
- Bagnall, A., Lines, J., Bostrom, A., Large, J., & Keogh, E. (2017). The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*, 31(3), 606–660. <https://doi.org/10.1007/s10618-016-0483-9>
- Bahtiar, R., & Raswatie, F. D. (2023). Analisis Fluktuasi Harga Pangan di Kota Bogor. *Indonesian Journal of Agriculture Resource and Environmental Economics*, 1(2), 70–81. <https://doi.org/10.29244/ijaree.v1i2.42020>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*. <http://arxiv.org/abs/1412.3555>
- Digno, C., Jauhar, M. I., & Syaifullah, M. N. (2023). Pendekatan Deep Learning dan Gradient Boosting dalam Prediksi Harga Properti Airbnb dengan Analisi Sentimen. *Jurnal Elektronik Ilmu Komputer Udayana*, 12(1), 191. <https://doi.org/https://doi.org/10.24843/JLK.2023.v12.i01.p22>
- Ericko, T., Dolok Lauro, M., & Handhayani, T. (2023). *PREDIKSI HARGA PANGAN DI PASAR TRADISIONAL KOTA SURABAYA DENGAN METODE LSTM*. <https://doi.org/https://doi.org/10.24912/jiksi.v11i2.26012>
- Falah, R. F., Komarudin, M., & Pratama, M. (2023). PERANCANGAN MICROSERVICE BERBASIS REST API PADA GOOGLE CLOUD PLATFORM MENGGUNAKAN NODEJS DAN PYTHON. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11. <https://doi.org/https://doi.org/10.23960/jitet.v11i3s1.3506>
- Falatehan, S. F., & Pariyasi, P. (2021). MOTIF DALAM PERILAKU MEMILIH PANGAN DAN HUBUNGANNYA DENGAN KETAHANAN PANGAN DI KOMUNITAS NELAYAN. *Jurnal Sosial Ekonomi Kelautan Dan Perikanan*, 16(1), 103. <https://doi.org/10.15578/jsekp.v16i1.8216>

- Fauzin, F. (2021). Pengaturan Impor Pangan Negara Indonesia Yang Berbasis Pada Kedaulatan Pangan. *Pamator Journal*, 14(1), 1–9.
<https://doi.org/10.21107/pamator.v14i1.10497>
- Fitriastuti, F., Eka Putri, A., Kautsar Sunardi, A., & Apriliya Hidayat, R. (2024). Analisis Website SIAKAD Universitas Janabadra Menggunakan Metode UAT. In *JTSI* (Vol. 5, Issue 1).
- Hair, J. F., Tomas, G., Hult, M., Ringle, C. M., & Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*.
<https://www.researchgate.net/publication/354331182>
- Huda, N., Wati, H. D., & Hamzah, A. (2023). FAKTOR-FAKTOR YANG MEMPENGARUHI PENDAPATAN PETANI PADI DI DESA MANDALA KECAMATAN RUBARU KABUPATEN SUMENEP. *Seminar Nasional Hilirisasi Produk Pertanian Dalam Mendorong Pertumbuhan Sektor Ekonomi Pertanian Dan Penguatan Ketahanan Pangan*.
<https://doi.org/https://doi.org/10.24929/prosd.v0i0.2384>
- Inflasi Tahun Kalender (y-to-d) Provinsi Kepulauan Bangka Belitung Menurut Kelompok Pengeluaran (2022=100) - Tabel Statistik - Badan Pusat Statistik Provinsi Kep. Bangka Belitung*. (n.d.). Retrieved April 13, 2025, from <https://babel.bps.go.id/id/statistics-table/2/MTE5MiMy/inflasi-tahun-kalender--y-to-d--provinsi-kepulauan-bangka-belitung-menurut-kelompok-pengeluaran--2022-100---persen-.html>
- Jange, B. (2022). Prediksi Harga Saham Bank BCA Menggunakan XGBoost. *ARBITRASE: Journal of Economics and Accounting*, 3(2), 231–237.
<https://doi.org/10.47065/arbitrase.v3i2.495>
- Kusumawardani, Q. D. (2019). PROSPEK KECERDASAN BUATAN SEBAGAI SUBJEK HUKUM PERDATA DI INDONESIA. *Veritas et Justitia*, 5(1), 166–190. <https://doi.org/10.25123/vej.3270>
- Lubis, A. H., & Pulungan, M. R. (2024). Prediksi Harga Pangan di Tengah Isu Ketidakpastian Global Menggunakan Metode Regresi Linear dan Regresi Polinomial. *JURNAL FASILKOM*, XIV(2), 404–409.
<https://doi.org/https://doi.org/10.37859/jf.v14i2.6996>
- Lubis, A. H., Pulungan, R., & Pulungan, M. R. (2024). Prediksi Harga Pangan di Tengah Isu Ketidakpastian Global Menggunakan Metode Regresi Linear dan Regresi Polinomial. *Jurnal FASILKOM*, 14(2), 404–409.
<https://doi.org/https://doi.org/10.37859/jf.v14i2.6996>
- Meriani, A. P., & Rahmatulloh, A. (2024). PERBANDINGAN GATED RECURRENT UNIT (GRU) DAN ALGORITMA LONG SHORT TERM MEMORY (LSTM) LINEAR REFRESSION DALAM PREDIKSI HARGA

- EMAS MENGGUNAKAN MODEL TIME SERIES. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(1). <https://doi.org/10.23960/jitet.v12i1.3808>
- Mienye, I. D., & Sun, Y. (2022). A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects. In *IEEE Access* (Vol. 10, pp. 99129–99149). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2022.3207287>
- Nilsen, A. (2022). Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45. *Jurnal Statistika Dan Aplikasinya*, 6(1), 137–147. <https://doi.org/https://doi.org/10.21009/JSA.06113>
- Prayogi, K., Gata, W., & Kussanti, D. P. (2024). Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU. *Jutisi : Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13(1), 647–658. <https://doi.org/http://dx.doi.org/10.35889/jutisi.v13i1.1910>
- Purwaningtyas, E., & Jatmiko, A. R. (2024). PENGUJIAN BLACK BOX WEBSITE PERPUSTAKAAN UNIVERSITAS MERDEKA MALANG BERBASIS GRAPH BASED TESTING. In *Jurnal Ilmiah Computing Insight* (Vol. 6, Issue 1). www.library.unmer.ac.id
- Samsudin, Muliani Harahap, A., & Fitrie, S. (2021). IMPLEMENTASI GATED RECURRENT UNIT (GRU) UNTUK PREDIKSI HARGA SAHAM BANK KONVENSIIONAL DI INDONESIA. *JISTech (Journal of Islamic Science and Technology) JISTech*, 6(2), 42–49. <http://jurnal.uinsu.ac.id/index.php/jistech>
- Tashildar, A., Shah, N., Gala, R., Giri, T., & Chavhan, P. (2020). APPLICATION DEVELOPMENT USING FLUTTER. In *International Research Journal of Modernization in Engineering Technology and Science @International Research Journal of Modernization in Engineering*. www.irjmets.com
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3). <https://doi.org/10.23960/jitet.v11i3.3250>
- Virginia, V. R., Herman Nayoan, & Neni Kumayas. (2021). Peran Pemerintah Dalam Mewujudkan Ketahanan Pangan di Minahasa Selatan (Studi Dinas Ketahanan Pangan Minahasa Selatan). *Journal Governance*, 1(1).
- Yusapra Salim, A., Yuliani, M., Andayani Komara, M., Sri Wahyuni, R., Kartamulia, U., Kepribadian, P., & Tinggi Teknologi Wastukencana, S. (2024). Analisis Deret Waktu Data Perencanaan Tenaga Kerja pada Perusahaan Manufaktur Menggunakan Model ARIMA Time Series Analysis

of Man Power Planning Data at Manufacturing Company Using ARIMA Model. 14(2), 481–492. <https://doi.org/10.51132/teknologika.v14/2>



LAMPIRAN



Lampiran 1 Daftar Riwayat Hidup

1. Daftar Pribadi

Nama Lengkap : Khemal Fasyah Ishaq
Tempat, Tanggal Lahir : Sungailiat, 10 Desember 2003
Alamat : Jl. Hos Cokroaminoto, Gg. Camar,
Sungailiat, Bangka, Kepl. Bangka
Belitung
Telp : -
Hp : 087848441707
Email : dev.fasyah@gmail.com
Jenis Kelamin : Laki-laki
Agama : Islam



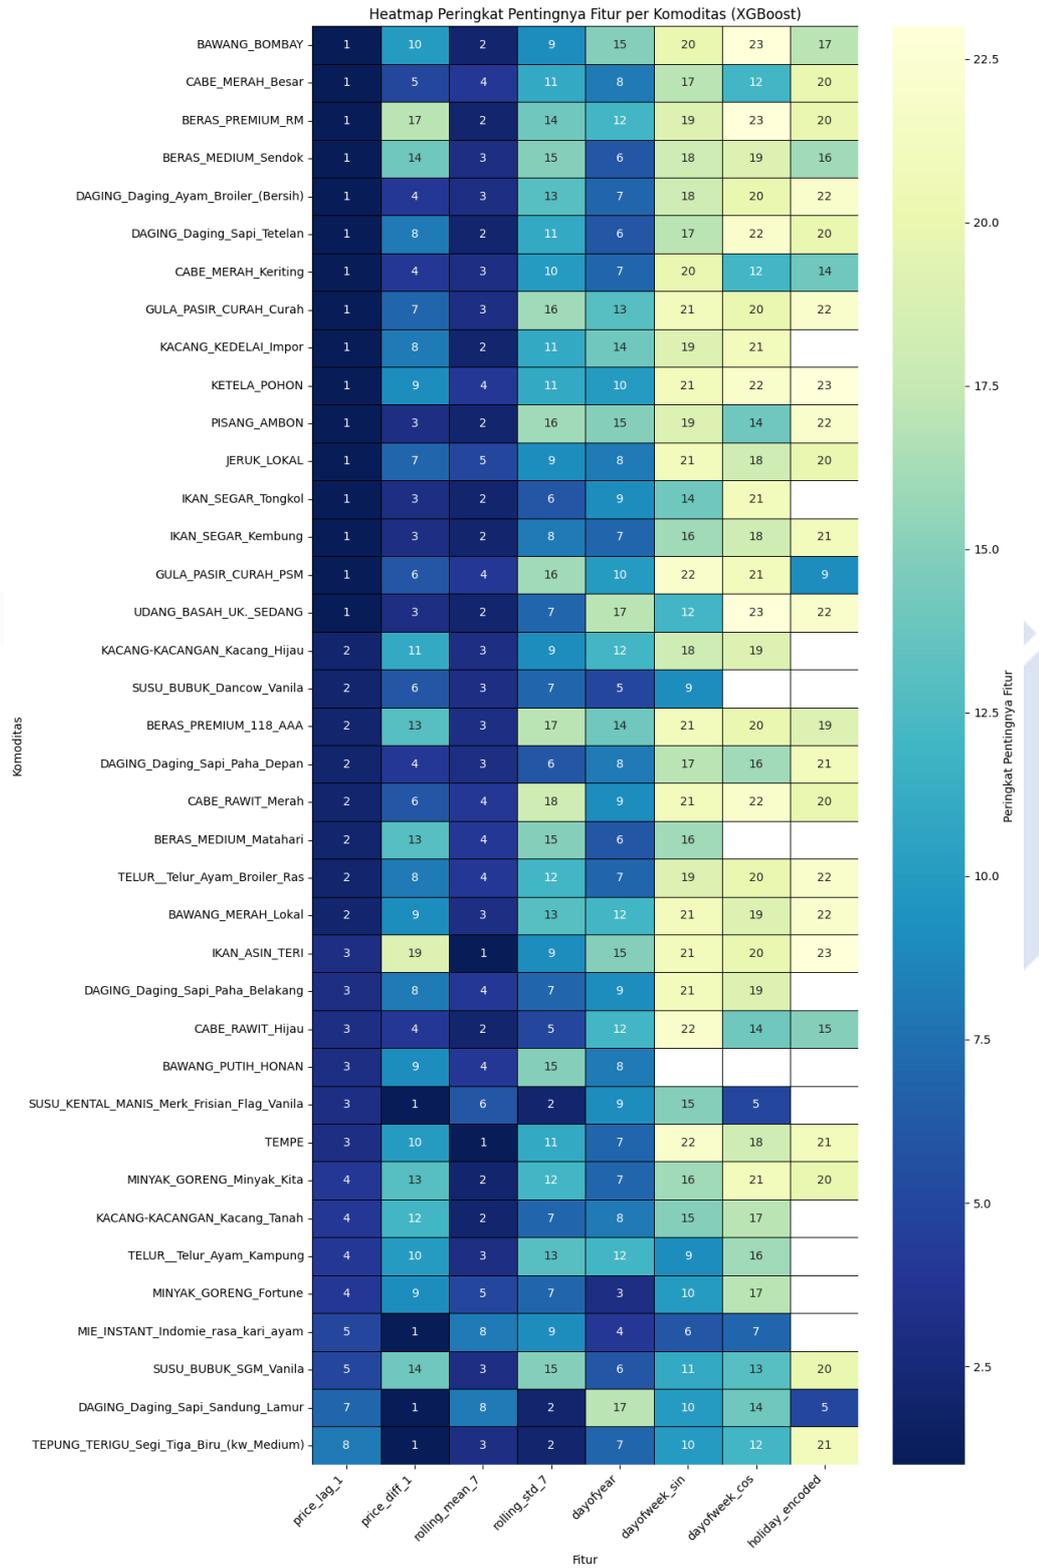
2. Riwayat Pendidikan

SD Negeri 1 Sungailiat	2010-2016
SMP Negeri 1 Sungailiat	2016-2019
SMA Negeri 1 Sungailiat	2019-2022

Sungailiat, 15 September 2025

Khemal Fasyah Ishaq

Lampiran 1 Heatmap Fitur Penting per Komoditas model XGBoost



Lampiran 2 Pengujian Fungsional Black Box

No	Skenario Pengujian	Langkah-langkah Pengujian	Hasil Yang Diharapkan	Hasil Aktual	Status
1	Menjalankan prediksi dengan input yang valid (kondisi normal).	<ol style="list-style-type: none"> 1. Buka aplikasi. Pilih Komoditas: "Cabai Merah Keriting". 2. Pilih Tanggal Awal. 3. Masukkan Horizon Waktu: "7" hari. 4. Tekan tombol "Dapatkan Prediksi". 	Aplikasi menampilkan halaman hasil dengan daftar harga dan grafik prediksi untuk 7 hari ke depan.	Prediksi berhasil ditampilkan lengkap dengan grafik dan daftar harga untuk 7 hari ke depan.	Lulus
2	Menjalankan prediksi dengan input tidak lengkap (kondisi galat).	<ol style="list-style-type: none"> 1. Buka aplikasi. 2. Biarkan kolom Komoditas kosong. 3. Tekan tombol "Dapatkan Prediksi". 	Aplikasi menampilkan pesan peringatan/galat yang meminta pengguna untuk melengkapi input.	Sistem berhasil menampilkan notifikasi galat yang sesuai, meminta pengguna untuk melengkapi input komoditas sebelum melanjutkan.	Lulus
3	Verifikasi kesesuaian data pada tabel dan grafik.	<ol style="list-style-type: none"> 1. Lakukan skenario 1. 2. Amati data pada tabel. 3. Bandingkan dengan titik data pada grafik yang ditampilkan. 	Titik data pada grafik secara visual merepresentasikan nilai harga yang tertera pada tabel.	Visualisasi grafik berhasil merepresentasikan data harga dari tabel dengan konsisten dan akurat.	Lulus

Lampiran Nomor : 30/PL28/KM/PA/2025

SURAT PERNYATAAN

Saya/Kami yang bertandatangan dibawah ini telah menyelesaikan Proyek Akhir yang berjudul:

IMPLEMETASI *ARTIFICIAL INTELLIGENCE* UNTUK PREDIKSI HARGA PANGAN PADA APLIKASI *MOBILE* DI KOTA PANGKALPINANG

Oleh :

1. Khemal Fasyah Ishaq /1062215

Dengan ini menyatakan bahwa isi laporan akhir proyek akhir sama dengan *hardcopy*.
Demikian surat pernyataan ini dibuat dengan sebenar-benarnya.

Sungailiat, 15 September 2025



Khemal Fasyah Ishaq

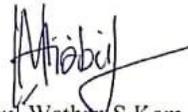
Mengetahui,

Pembimbing 1

Pembimbing 2



Riki Anjansyah M.T
NIP. 199004042019031013



M. Hizbul Wathan S.Kom., M.Kom.
NIP. 198904182024061001

18% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- ▶ Bibliography
- ▶ Quoted Text
- ▶ Cited Text
- ▶ Small Matches (less than 8 words)

Top Sources

- 18%  Internet sources
- 7%  Publications
- 8%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

No suspicious text manipulations found.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.