

Pengembangan Model Prediksi Harga Beras Nasional Berbasis *Multivariate* Menggunakan *Temporal Fusion Transformer* (TFT)

1st Maulaya Radhibilla
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

radhibilla@student.telkomuniversity.ac.id

2nd Suryo Adhi Wibowo
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

suryoadhiwibowo@telkomuniversity.ac.id

3rd Koredianto Usman
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

korediantousman@telkomuniversity.ac.id

Abstrak — Dalam konteks ekonomi, sosial, dan politik, harga komoditas pangan memiliki peran penting yang signifikan dalam menentukan stabilitas ekonomi dan kesejahteraan masyarakat. Namun, terdapat tantangan dalam pengelolaan harga pangan, seperti mengidentifikasi periode-periode tertentu di mana harga pangan mengalami kenaikan signifikan dan memperkirakan tren harga pangan di masa depan. Berdasarkan latar belakang tersebut, dirancanglah model prediksi dengan pendekatan *multivariate*, menggunakan arsitektur *Temporal Fusion Transformer* (TFT). TFT adalah model *Transformer* yang dirancang untuk peramalan *time series multi-horizon* dan meraih performa *state-of-the-art*. Pada perancangan ini, terdapat enam jenis data, baik data kontinu maupun kategorial, yang digunakan dengan target prediksi harga harian Beras Premium dan Beras Medium hingga 30 hari ke depan berdasarkan pola temporal 90 hari sebelumnya. Berdasarkan pengujian yang dilakukan dengan 30 baris terakhir data, didapatkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,23% untuk Beras Premium dan 0,3% untuk Beras Medium. Pengujian ini menunjukkan bahwa performa TFT sangat baik dalam implementasi *time series multivariate forecasting*.

Kata kunci— Harga, Beras, Time Series, TFT, *Multivariate*, MAPE

I. PENDAHULUAN

Dalam konteks ekonomi, sosial, dan politik, harga komoditas pangan memiliki peran penting yang signifikan dalam menentukan stabilitas ekonomi dan kesejahteraan masyarakat. Hal ini dibuktikan oleh riset yang dilakukan Badan Pusat Statistik (BPS), yaitu kontribusi Garis Kemiskinan Makanan (GKM) terhadap garis kemiskinan pada Maret 2023 sebesar 74,2%, sisanya disumbang oleh komoditas nonpangan (perumahan, sandang, pendidikan, dan kesehatan). Pada riset lainnya, BPS juga menyatakan bahwa harga beras merupakan kontributor utama dalam inflasi *year-on-year* tahun 2023. Hal ini menunjukkan bahwa apabila terjadi kenaikan tingkat harga atau inflasi suatu komoditas pangan maka akan menaikkan garis kemiskinan dan meningkatkan angka kemiskinan, dengan syarat pendapatan masyarakat tetap [1].

Tantangan utama dalam pengelolaan harga pangan adalah mengidentifikasi periode-periode tertentu di mana

harga pangan mengalami kenaikan signifikan dan memperkirakan tren harga pangan di masa depan. Untuk mengatasi masalah ini, Badan Pangan Nasional (BAPANAS) bersama Telkom University dan Badan Riset Inovasi Nasional (BRIN) bekerja sama dalam pengembangan program prediksi harga pangan di Indonesia. Program ini akan mengintegrasikan data-data yang dimiliki oleh BAPANAS seperti data harga pangan dan data stok pangan. Berdasarkan latar belakang tersebut, maka model prediksi akan dikembangkan dengan pendekatan *multivariate*, dengan menggunakan arsitektur *Temporal Fusion Transformer* (TFT). Arsitektur TFT dipilih dikarenakan kemampuannya untuk mempelajari pola temporal dari data yang bersifat heterogen.

II. KAJIAN TEORI

A. Time Series Forecasting


Time series adalah urutan data yang dikumpulkan pada interval waktu yang berurutan dan biasanya sama jaraknya. Deret ini merupakan kumpulan pengukuran di mana setiap titik data terkait dengan waktu tertentu. Data ini dianggap sebagai variabel acak dan disusun dalam urutan kronologis yang teratur [2]. Variabel dapat diartikan sebagai entitas yang mewakili kelompok dari informasi bersifat temporal, seperti pengukuran temperatur ruangan dari waktu ke waktu..

Time series forecasting ialah metode dalam memprediksi nilai-nilai masa depan dari data *time series*. Terdapat dua kategori dalam *time series forecasting*, yaitu *univariate* dan *multivariate*. *Time series forecasting univariate* adalah proses memprediksi nilai-nilai masa depan dari satu variabel. Sementara itu *Time series forecasting multivariate* adalah proses memprediksi nilai-nilai masa depan dari beberapa variabel [3].

B. Temporal Fusion Transformer (TFT)

Temporal Fusion Transformer (TFT) adalah model berbasis *transformer* yang dirancang untuk *interpretable*, *multi-horizon* pada *time series forecasting* [4]. TFT berhasil meraih performa *state-of-the-art* pada berbagai jenis datasets yang digunakan sebagai *baseline* performa pada *time series forecasting* [4]. Komponen utama dari TFT ialah:

1. *Gating mechanisms*: Dikenal sebagai *Gated Residual Networks* (GRN). Mekanisme ini secara selektif menyaring elemen-elemen arsitektur untuk menghindari pemrosesan non-linear yang tidak diperlukan.
2. Jaringan seleksi variabel: Jaringan ini memilih fitur input yang dianggap penting pada setiap interval waktu.
3. *Static covariate encoders*: Berfungsi untuk mengintegrasikan variabel-variabel statis ke dalam *model network* untuk mempelajari pola temporal.
4. Pemrosesan Temporal: Berfungsi untuk mempelajari pola-pola jangka panjang dan jangka pendek dari input yang diketahui dan yang diamati yang bervariasi dengan waktu.



GAMBAR 1
Multi Step Forecast TFT

TFT melakukan bersifat *multi step forecast*, seperti yang terlihat pada Gambar 1. *Multi step forecast* yaitu melakukan prediksi hingga “Y” langkah waktu ke depan, berdasarkan pola temporal dari rentang periode *lookback* sejauh “X”. Periode *lookback* yaitu rentang prediksi sebelum waktu prediksi dilakukan [4]. Arsitektur ini juga meningkatkan interpretabilitas dari *time series forecasting*. TFT dapat memvisualisasikan bagaimana dan mengapa hasil prediksi yang diberikan oleh model. Hal ini menjadikan keluaran model lebih dapat dipercaya dan lebih mudah digunakan, sesuai dengan objektif dari *Explainable AI* (XAI) [5].

III. METODE

A. Dataset

Dataset pada perancangan ini terdiri enam data berbeda. Data-data tersebut antara lain:

1. Pergerakan harga harian dari Beras Premium.
2. Pergerakan harga harian dari Beras Medium.
3. Data harian stok awal beras di Pasar Induk Beras Cipinang.
4. Data harian nilai tukar Dolar terhadap Rupiah.
5. Data produksi beras bulanan dalam ton.
6. Data hari penting di Indonesia (Hari Raya Idul Fitri, Hari Raya Idul Adha, Hari Natal, bulan Ramadan, dan Tahun Baru).

Rentang data-data diatas ialah dimulai dari Januari 2021 hingga Januari 2024. Dari data yang telah dikumpulkan, terdapat dua jenis variasi data: data dengan nilai kontinu dan data dengan nilai kategorikal. Data dengan nilai kontinu mencakup harga pangan harian untuk Beras Premium, Beras Medium, stok awal beras di Pasar

Induk Beras Cipinang, nilai tukar Dolar terhadap Rupiah, dan produksi beras bulanan dalam ton. Sedangkan untuk data kategorikal, terdiri dari informasi tentang hari-hari penting

B. Pre-Processing Dataset

Dari data yang telah dikumpulkan, terdapat dua jenis variasi data: data dengan nilai kontinu dan data dengan nilai kategorikal. Data dengan nilai kontinu mencakup harga pangan harian untuk Beras Premium dan Beras Medium, stok awal beras di Pasar Induk Beras Cipinang, nilai tukar Dolar terhadap Rupiah, dan produksi beras bulanan dalam ton. Sedangkan untuk data kategorikal, terdiri dari informasi tentang hari-hari penting.

Nilai yang akan diprediksi adalah harga Beras Premium dan Beras Medium dengan interval harian. Oleh karena itu, beberapa tahap pemrosesan data diperlukan. Pertama, setiap data akan diatur menggunakan format tanggal sebagai indeks, sehingga data memiliki acuan yang sama saat digabungkan. Tahap pemrosesan selanjutnya adalah mengubah data dengan interval bulanan menjadi harian melalui proses yang disebut *upsampling*. Dengan demikian, data yang diolah akan seragam dalam interval harian dan siap digunakan dalam pembangunan model prediksi harga Beras Premium dan Beras Medium.

Selain menggunakan data harga harian dan data pendukung lainnya untuk melatih model, dilakukan juga proses *feature engineering* untuk menambahkan kolom-kolom baru yang merepresentasikan informasi waktu. Kolom-kolom tersebut mencakup nilai yang menggambarkan urutan hari dalam setahun dan urutan hari sejak baris data pertama hingga baris data terakhir. Pembuatan kolom-kolom baru ini dapat membantu model untuk menangkap pola pola waktu yang mungkin ada dalam data, serta memberikan informasi tambahan tentang periode waktu relatif terhadap titik awal pengamatan. Penambahan kolom ini mengacu pada kolom tanggal yang sudah tersedia dalam dataset. Lima baris sampel dataset dapat dilihat pada Gambar 2.

	Tanggal	Kurs	StokCipinang	ProduksiBeras	occasion	jenis	harga	day_of_year	days_count
0	2021-01-04	13833.490000	36946.0	1.141734e+06	-	BerasMedium	10875.048110	4	1
1	2021-01-05	13875.280000	37903.0	1.130247e+06	-	BerasMedium	10861.400631	5	2
2	2021-01-06	13856.370000	37017.0	1.122773e+06	-	BerasMedium	10888.463259	6	3
3	2021-01-07	13868.310000	37096.0	1.119310e+06	-	BerasMedium	10931.209265	7	4
4	2021-01-08	13987.710000	36999.0	1.119859e+06	-	BerasMedium	10942.506431	8	5
5	2021-01-09	14047.166923	37623.0	1.124420e+06	-	BerasMedium	10895.076923	9	6
6	2021-01-10	14037.216880	35688.0	1.132993e+06	-	BerasMedium	10882.310105	10	7
7	2021-01-11	14084.230000	35548.0	1.145578e+06	-	BerasMedium	10890.322957	11	8
8	2021-01-12	14159.850000	37165.0	1.162175e+06	-	BerasMedium	10884.393072	12	9
9	2021-01-13	14038.460000	35146.0	1.182783e+06	-	BerasMedium	10883.318318	13	10

GAMBAR 2
Sampel dari Dataset Hasil Pre-Process

C. Pembuatan Dataloader

Pembuatan *dataloaders* bertujuan untuk memudahkan integrasi *dataset* yang telah di proses, serta memberitahukan model bagaimana *dataset* akan diproses. Beberapa konfigurasi dalam pembuatan *dataloader* antara lain:

1. Jarak periode *lookback* dalam menentukan prediksi, diatur menjadi 90 hari.
2. Rentang prediksi yang diberikan oleh model, diatur menjadi 30 hari.
3. Variabel kategorikal, terdiri dari kolom *occasion*.

4. Variabel kontinyu, terdiri dari kolom kurs, stok Cipinang, produksi beras, dan harga komoditas.

Konfigurasi diatas akan menjadi aturan pembuatan *training dataset* dan *validation dataset*. *Validation dataset* terdiri dari 30 hari terakhir masing-masing komoditas yang tidak digunakan dalam proses *training*.

D. Model Training

Dalam proses *training* menggunakan TFT, terdapat beberapa *hyperparameters* yang perlu diperhatikan. Penentuan *hyperparameter* ini menentukan jumlah parameter yang akan dipelajari oleh model. Detail dari masing-masing *hyperparameter* yang digunakan dalam proses perancangan dapat dilihat pada Tabel 1.

TABEL 1
Pemilihan *Hyperparameter*

<i>Hyperparameter</i>	Nilai
<i>Learning Rate</i>	0.0125
<i>Hidden Size</i>	80
<i>Attention Head Size</i>	3
<i>Hidden Continuous Size</i>	67
<i>Dropout</i>	0.3

E. Testing Metric

Proses *testing* dilakukan dengan menggunakan data validasi, yaitu 30 hari data terakhir yang tidak digunakan dalam proses *training* dari masing-masing jenis beras. Metriks yang digunakan yaitu Mean Absolute Percentage Error (MAPE). MAPE adalah ukuran akurasi prediksi yang mewakili rata-rata dari kesalahan persentase absolut dari setiap entri dalam sebuah data. Persamaan MAPE dapat dilihat pada persamaan (1).

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

Nilai A_t adalah *actual* atau nilai sebenarnya. F_t adalah nilai prediksi. Nilai n ada, pada pengujian nilai n ialah jumlah data validasi yaitu 30.

IV. HASIL DAN PEMBAHASAN

TABEL 2
Hasil Pengujian

Jenis Komoditas	Nilai MAPE
Beras Premium	0,23%
Beras Medium	0,3%
Rata-rata	0,265%

Berdasarkan pengujian dari 30 sampel untung setiap komoditas, didapatkanlah nilai MAPE seperti yang terlihat pada Tabel 2. Dimana pada Tabel 2, nilai MAPE dari Beras Premium ialah 0,23%, nilai MAPE dari Beras Medium ialah 0,3%. Rata-rata nilai MAPE dari seluruh tipe beras ialah 0,265%. Hasil pengujian menunjukkan bahwa model mampu memprediksi harga pada data validasi dengan sangat baik, dimana mampu meraih nilai MAPE dibawah 1%.

V. KESIMPULAN

TFT merupakan arsitektur *state-of-the-art* pada *time series forecasting*. Terdapat banyak keunggulan dari TFT seperti

prediksi yang bersifat *multi step, layer* untuk seleksi variabel, dan dapat menerima input statis dengan *static covariate encoders*. Penggunaan algoritma TFT juga memudahkan untuk integrasi berbagai jenis variasi input variabel seperti nilai kontinyu dan kategorikal, dan memudahkan melihat interpretasi dari bagaimana prediksi dapat dihasilkan. Pada perancangan, model TFT dilatih dengan 6 jenis data dengan target variabel yang diprediksi ialah harga Beras Premium dan Harga Beras Medium dengan interval harian. Model mampu melakukan prediksi hingga 30 hari kedepan dengan melihat pola temporal dari 90 hari terakhir. Pengujian dilakukan dengan memisahkan 30 baris terakhir data untuk masing-masing jenis beras dari proses *training*. Pada pengujian, model memperoleh MAPE sebesar 0,23% dan 0,3% untuk Beras Premium dan Beras Medium. Dari hasil pengujian dapat disimpulkan bahwa model memiliki performa dengan sangat baik dikarenakan persentase error dari harga prediksi dibawah 0,5% dari harga sebenarnya.

REFERENSI

- [1] A. Ray Farandy, "Analyzing Factors Affecting Indonesian Food Price Inflation," dalam *Jurnal Ekonomi dan Pembangunan*, 2020, hlm. 65–76. doi: 10.14203/JEP.28.1.2020.65-76.
- [2] R. Adhikari dan R. K. Agrawal, "An Introductory Study on Time Series Modeling and Forecasting." 2013. [Daring]. Tersedia pada: <https://arxiv.org/abs/1302.6613>
- [3] J. du Preez dan S. F. Witt, "Univariate versus multivariate time series forecasting: an application to international tourism demand," *Int J Forecast*, vol. 19, no. 3, hlm. 435–451, 2003, doi: [https://doi.org/10.1016/S0169-2070\(02\)00057-2](https://doi.org/10.1016/S0169-2070(02)00057-2).
- [4] B. Lim, S. Ö. Arik, N. Loeff, dan T. Pfister, "Temporal Fusion Transformers for interpretable multi-horizon time series forecasting," *Int J Forecast*, vol. 37, no. 4, hlm. 1748–1764, 2021, doi: <https://doi.org/10.1016/j.ijforecast.2021.03.012>.
- [5] D. Gunning, M. Stefik, J. Choi, T. Miller, S. Stumpf, dan G.-Z. Yang, "XAI—Explainable artificial intelligence," *Sci Robot*, vol. 4, no. 37, hlm. eaay7120, 2019, doi: 10.1126/scirobotics.aay7120.