

ARTICLE

Eksplorasi Model LSTM dengan Autoregressive Integrated Moving Average (ARIMA) dan Bayesian Optimization untuk Peningkatan Akurasi Prediksi Ketahanan Pangan

Exploration of LSTM Model with Autoregressive Integrated Moving Average (ARIMA) and Bayesian Optimization to Improve Accuracy of Food Security Prediction

Idi Jang Cik* dan Asep Syaputra

Teknik Informatika, Fakultas Ilmu Komputer, Institut Teknologi Pagar Alam, Pagar Alam, Indonesia

*Penulis Korespondensi: edijangcik@gmail.com

(Disubmit 17-07-25; Diterima 13-10-25; Dipublikasikan online pada 20-10-25)

Abstrak

Penelitian ini bertujuan untuk mengeksplorasi Model LSTM dengan Autoregressive Integrated Moving Average (ARIMA) dan Bayesian Optimization untuk Peningkatan Akurasi Prediksi Ketahanan Pangan Kota Pagar Alam. Kota Pagar Alam mengalami penurunan Indeks Ketahanan Pangan (IKP) yang berada pada batas level bawah <50 yakni mendapatkan skor indeks 46,47 dan merupakan indeks nomor 10 terendah dari 17 kabupaten dan kota seprovinsi sumatera selatan. Data menunjukkan penurunan angkut dari awalnya 56,7 % turun 10,23 % pada tahun 2024 padahal kota Pagar Alam merupakan daerah pegunungan dengan luas lahan yang subur. Penelitian ini menggunakan ARIMA dan LSTM dalam meramalkan Ketahanan Pangan Kota Pagar Alam menggunakan dua skenario data: basic LSTM dan ARIMA dan LSTM, ARIMA yang di optimasi dengan Bayes Optimization). Penelitian ini menghasilkan optimalisasi model LSTM dengan kemampuan mode yang Dapat menangkap pola jangka panjang dan non-linear dalam data, Mampu bekerja dengan multivariat time series (banyak variabel) serta Bagus untuk data besar dan kompleksitas tinggi. Namun Memerlukan banyak data dan waktu pelatihan, Sulit diinterpretasi (black-box model), Lebih rumit secara komputasi (butuh GPU untuk efisiensi tinggi) sehingga kekurangan dalam menginterpretasikan data tersebut dapat di atasi oleh ARIMA yang Cocok untuk data time series univariat (satu variabel) dan Bagus untuk data yang stasioner. Temuan penelitian terbukti berhasil menghasilkan MAPE hanya 10% hal ini menunjukkan keunggulan dalam memprediksi ketahanan pangan yang akurat dengan mencapai akurasi 92 %. Hal ini menunjukkan bahwa penelitian ini dapat dijadikan informasi dan bahan kajian dalam menentukan kebijakan dan antisipasi ketahanan pangan yang didapatkan trend akan meningkat sampai dengan 5 tahun kedepan

Kata kunci: ARIMA, LSTM, Ketahanan Pangan, Prediksi, SUMSEL

Abstract

This study aims to explore the LSTM Model with Autoregressive Integrated Moving Average (ARIMA) and Bayesian Optimization to Improve the Accuracy of Food Security Prediction in Pagar Alam City. Pagar Alam City experienced a decline in the Food Security Index (IKP) which was at the lower level limit <50, namely getting an index score of 46.47 and was the 10th lowest index out of 17 regencies and cities in South Sumatra province. The data shows a decline in the initial figure from 56.7% down to 10.23% in 2024 even though Pagar Alam City

This is an Open Access article - copyright on authors, distributed under the terms of the Creative Commons Attribution-ShareAlike 4.0 International License (CC BY SA) (<http://creativecommons.org/licenses/by-sa/4.0/>)


How to Cite: I. J. Cik *et al.*, "Eksplorasi Model LSTM dengan Autoregressive Integrated Moving Average (ARIMA) dan Bayesian Optimization untuk Peningkatan Akurasi Prediksi Ketahanan Pangan", *JIKO (JURNAL INFORMATIKA DAN KOMPUTER)*, Volume: 9, No.3, Pages 666–678, Oktober 2025, doi: 10.26798/jiko.v9i3.2077.

is a mountainous area with a large area of fertile land. This study uses ARIMA and LSTM in predicting Food Security in Pagar Alam City using two data scenarios: basic LSTM and ARIMA and LSTM, ARIMA optimized with Bayes Optimization). This research produces the optimization of the LSTM model with mode capabilities that can capture long-term and non-linear patterns in data, able to work with multivariate time series (many variables) and good for large data and high complexity. However, it requires a lot of data and training time, is difficult to interpret (black-box model), is more complex computationally (requires GPU for high efficiency) so that the shortcomings in interpreting the data can be overcome by ARIMA which is suitable for univariate time series data (one variable) and good for stationary data. The research findings have proven successful in producing MAPE of only 10%, this shows its superiority in predicting accurate food security by achieving 92% accuracy. This shows that this research can be used as information and study material in determining policies and anticipating food security which is getting a trend that will increase up to the next 5 years.

KeyWords: ARIMA, LSTM, Food Security, Predicted, SUMSEL

1. Pendahuluan

Ketahanan pangan (food security) merupakan salah satu isu paling sentral dalam pembangunan pertanian dan pembangunan nasional, terlebih bagi negara berkembang seperti Indonesia yang berpenduduk besar. Hal ini disebabkan oleh ketahanan pangan sangat terkait erat dengan ketahanan sosial, stabilitas sosial, ketahanan nasional serta stabilitas ekonomi[1]. Berdasarkan data dari badan ketahanan Pangan Nasional Pagar Alam tidak termasuk 20 besar dari 98 kota dengan indeks ketahanan pangan (IKP) yang baik karena data indeks ketahanan pangan Kota Pagar Alam berada di level 47,09 %. [2]. Hal tersebut menimbulkan kekhawatiran akan ketersediaan bahan pangan padahal kota Pagar Alam merupakan salah satu daerah yang subur di provinsi Sumatera Selatan[3]. Adapun data IKP dapat dilihat pada Gambar 1 berikut ini:



Gambar 1. Data Indeks Ketahanan Pangan

Ketimpangan yang terjadi dapat disebabkan oleh beberapa hal antara lain, berkurangnya luasan lahan-lahan produktif yang selama ini dimanfaatkan untuk kegiatan usaha tani sehingga luas tanam suatu komoditas berkurang[4]. Meningkatnya laju konversi lahan seiring dengan laju pembangunan infrastruktur. Permintaan yang sulit di prediksi tiap bulan dalam kurun waktu 1 tahun menjadikan komoditas menjadi rendah[5]. Model LSTM dengan *Autoregressive Integrated Moving Average* (ARIMA) dan *Bayesian Optimization* menawarkan solusi besar yang dapat digunakan oleh pemerintah kota dalam memprediksi kebutuhan akan pangan melalui *dataset timeseries* 10 tahun terakhir data produktifitas tanaman padi sehingga dapat dijadikan data antisipasi untuk solusi ketahanan pangan yang dibutuhkan setiap minggu, bulan hingga tahun[6].

2. Metode

Ketahanan pangan kota Sumatera Selatan tidak konsisten karena belum adanya Analisa yang mampu memberikan prediksi dan antisipasi untuk peningkatan program ketahanan pangan. Pendekatan pemecahan dalam penelitian ini adalah dengan pendekatan multidisiplin ilmu yaitu Kolaborasi ahli Teknologi, Pertanian dan ilmu sosial. Penelitian ini akan menggunakan Deep Learning dengan melakukan Teknik Model *Tuning* (Penyempurnaan Model)[7]. Model *tuning* adalah proses pengoptimalan *hyperparameter* model (parameter yang tidak dipelajari dari data) menggunakan data validasi untuk meningkatkan kinerja model LSTM sehingga menghasilkan prediksi ketahanan pangan di Kota Pagar Alam secara akurat[8].


Selanjutnya dilakukan Analisa data *time series* 10 tahun lampau dan desain parameter yang baru untuk menghasilkan akurasi prediksi yang tinggi. Proses prediksi akan dilakukan dengan model *tuning LSTM* dengan *ARIMA* dan *Bayesian Optimization* untuk menghasilkan akurasi yang tinggi prediksi data ketahanan pangan proyeksi 5 tahun mendatang[9]. Data akan disajikan dalam bentuk metrik, diagram dan infografis perihal kekurangan apa di masa lampau dan solusi yang direkomendasikan oleh sistem *web-based* untukantisipasi menurunnya ketahanan pangan. Data prediksi ini dapat dijadikan informasi penting untuk mengetahui kelemahan ketahanan pangan kota Pagar Alam sehingga pihak pemerintah dapat membuat program untuk meningkatkan sektor tersebut[10]. Sistem juga dapat merekomendasikan program apa saja untuk meningkatkan Indeks Ketahanan Pangan (IKP) sehingga pemerintah tidak perlu memikirkan ulang program apa saja yang harus dilakukan karena data *time series* merupakan data yang dilakukan 10 tahun terakhir oleh pemerintah sehingga untuk menuju mendapatkan IKP tertentu pemerintah harus menjadikan hasil prediksi sebagai data pelaksanaan program[11].

Secara spesifik, penelitian ini berfokus pada meningkatkan efisiensi pencarian *hyperparameter* melalui *Bayesian Optimization* untuk menggantikan *Grid Search* yang membutuhkan waktu yang lama[12]. Memanfaatkan ARIMA untuk meningkatkan kemampuan model dalam menangkap pola signifikan pada data *time series* data ketahanan Pangan untuk menghasilkan akurasi tinggi[13]. Uraian tersebut berdasarkan kajian yang dilakukan oleh tim peneliti yakni:

1. Penelitian menggunakan model *CNN-Bi-LSTM* dengan optimasi *hyperparameter* berbasis *Grid Search*, menghasilkan RMSE sebesar 34.87. Namun, pendekatan ini memiliki kelemahan, yaitu efisiensi komputasi yang rendah dan keterbatasan dalam eksplorasi ruang parameter. Penelitian ini menjadi acuan utama untuk pengembangan lebih lanjut dengan pendekatan *Bayesian Optimization*[?].
2. Penelitian Perbandingan LSTM dengan *Linear Regression*, menunjukkan bahwa LSTM lebih unggul dalam menangkap pola jangka panjang. Penelitian ini menjadi dasar untuk memilih arsitektur LSTM dalam pengembangan model prediksi yang lebih kompleks. Selanjutnya, mengevaluasi performa GRU, LSTM, HMM. GRU menunjukkan hasil terbaik dengan RMSE 16.32, namun penelitian ini menyoroti perlunya integrasi mekanisme tambahan, seperti *Moving Average*, untuk meningkatkan kemampuan model untuk data harga fluktuatif[14, 15].
3. Studi menggabungkan LSTM dengan *Association Rule* untuk seleksi fitur, meningkatkan prediksi dengan mempertimbangkan variabel makroekonomi. Pendekatan ini menginspirasi pengembangan lebih lanjut dalam eksplorasi variabel tambahan untuk prediksi ketahanan pangan. Sementara itu, penelitian oleh mengkombinasikan ARIMA dengan LSTM untuk menangkap pola linear dan non-linear, menekankan pentingnya *preprocessing* data yang optimal[16].
4. Penelitian model *CNN-Bi-LSTM* dengan optimasi *hyperparameter* berbasis *Grid Search*, menghasilkan RMSE sebesar 34.87. Namun, pendekatan ini memiliki kelemahan, yaitu efisiensi komputasi yang rendah dan keterbatasan dalam eksplorasi ruang parameter. Penelitian ini menjadi acuan utama untuk pengembangan lebih lanjut dengan pendekatan *Bayesian Optimization* [17].

Secara keseluruhan, penelitian-penelitian ini menunjukkan bahwa kombinasi LSTM, ARIMA dan *Bayesian Optimization* adalah pendekatan yang menjanjikan untuk meningkatkan akurasi prediksi ketahanan pangan Kajian ini memberikan kontribusi yang signifikan terhadap literatur dengan mengintegrasikan berbagai pendekatan terbaik untuk menciptakan model prediksi yang lebih efisien dan akurat[18].

Metode penelitian yang digunakan yakni *Cross-Industry Standard Process for Data Mining* (CRISP-DM) dengan Model LSTM dan *bayesian* untuk menganalisis dan menghasilkan data penelitian yang tepat[18]. Metode ini dibagi menjadi 6 tahapan yang saling terkait dan dapat diulang seperti terlihat pada Gambar 2 yakni:



Gambar 2. Metode Penelitian Crisp-DM

1. *Business Understanding*

Pada tahap ini peneliti mulai menganalisa dan memahami kebutuhan pemerintah kota Pagar Alam secara mendalam melalui serangkaian observasi, wawancara dan survei perihal ketahanan Pangan. Selain itu pada tahap ini yang dilakukan adalah menentukan tujuan yang akan dihasilkan setelah prediksi ketahanan pangan, menilai situasi ketersediaan sumber daya yang ada di kota Pagar alam dan menghasilkan rencana program kerja mengatasi ketahanan pangan dan meningkatkan nilai IKP[19].

2. *Data Understanding*

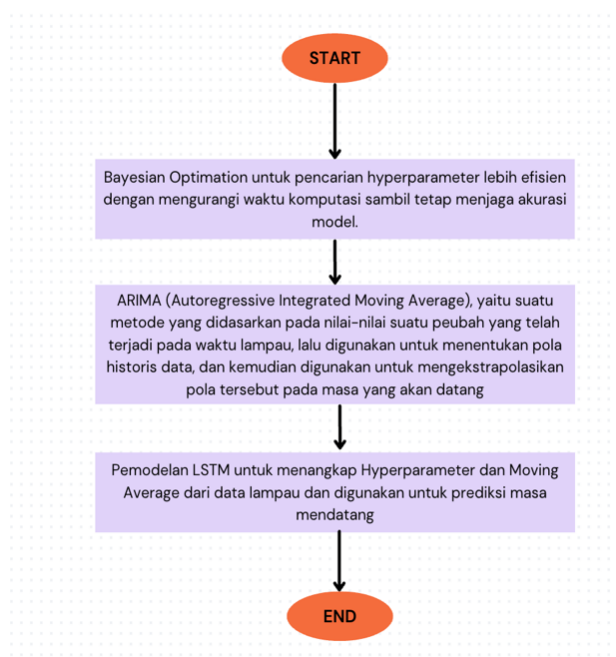
Selanjutnya adalah tahap pemahaman data *time series* 10 tahun terakhir terkait kondisi ketahanan Pangan tanaman padi kota pagar alam dengan cara mengidentifikasi, mengumpulkan, dan menganalisis kumpulan data yang dapat membantu untuk mencapai tujuan penelitian ini. Kegiatan pada tahap ini adalah mengumpulkan data awal, menjelaskan data, menjelajahi data, dan memverifikasi kualitas data sehingga menghasilkan *dataset* yang baik untuk memulai penelitian dengan parameter penelitian yang tepat.

3. *Data Preparation*

Tahap ini merupakan menyiapkan kumpulan data akhir untuk pemodelan. Kegiatan pada fase ini adalah memperbaiki kualitas data agar sesuai dengan proses modeling yang akan dilakukan berikutnya.

4. *Modeling*

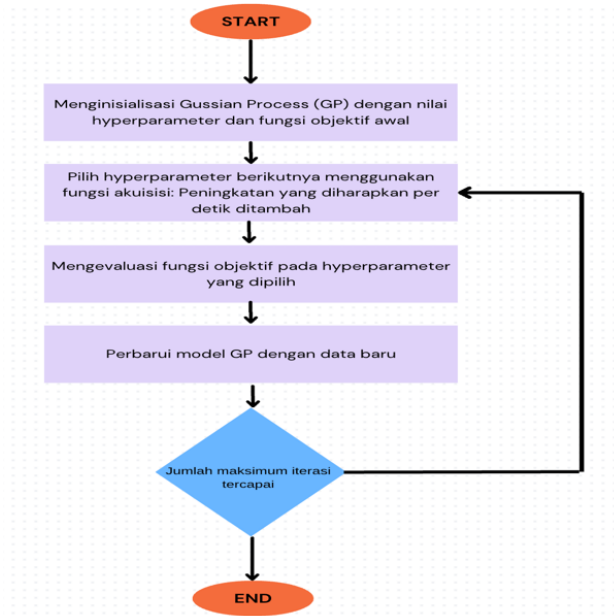
Tahap ini merupakan tahapan proses prediksi dapat dilihat pada *flowchart* (Gambar 3) berikut ini:



Gambar 3. Arsitektur Proses Optimalisasi LSTM

2.1 Bayesian Optimazition


Optimasi Bayesian adalah metode yang mengoptimalkan pengambilan keputusan dalam menetapkan *hyperparameter* dengan menerapkan fungsi objektif untuk memahami pengaturan masa lalu, dan akhirnya menemukan pengaturan *hyperparameter* terbaik secara efisien. *Hyperparamater* diatur menggunakan *Bayesian Optimazition* yakni dimulai dari menganalisa *Gaussian Process* (GP) data ketahanan pangan 10 tahun terakhir kemudian memilih *hyperparameter* sesuai hasil analisa GP tadi mengevaluasi data mana yang bisa di proses setelah itu menghasilkan pembaruan GP menjadi sebuah data baru. Data baru tersebut di proses mencapai iterasi maksimum sehingga data hasil *Bayesian optimization* adalah *dataset* dengan *hyperparameter* [20]. *Flowchart Bayesian Optimazition* dapat dilihat pada Gambar 4 berikut.



Gambar 4. Flowchart Bayesian Optimazition

2.2 ARIMA

Setelah tahap *Bayesian* diperoleh *Dataset* Jumlah Nilai Maksimum iterasi selanjutnya yakni tahap mengkombinasikan ARIMA dengan LSTM untuk menangkap pola linear dan non-linear, menekankan pentingnya *preprocessing* data yang optimal. Adapun tahapan mencapai *forecasting model* yang maksimal sebelum tahapan pemodelan LSTM [?] dapat dilihat pada Gambar 5 berikut ini:




Gambar 5. Flowchart ARIMA

2.3 Long-Short Term Memory (LSTM)

Preprocessing data terdiri dari *data cleansing* dan *normalisasi dataset*. Setelah tahap *preprocessing* data selesai dilakukan kemudian *dataset* dibagi menjadi dua, *dataset training* dan *dataset testing*[21]. Tahap selanjutnya dalam penelitian ini untuk mencapai hasil prediksi proses membangun sistem dibagi menjadi dua yaitu proses *training* dan proses *prediksi*. Karena saat menjalankan proses pembuatan model memakan waktu yang cukup lama, maka proses *training* dilakukan secara terpisah dengan proses prediksi. Tahap eksperimen model dimulai dengan pembuatan model dan *training LSTM Network*. Hasil training berupa model LSTM yang berupa *file HDF5* atau *.h5*.

Model yang diperoleh selanjutnya digunakan pada proses prediksi dengan memuat file model[22]. Tahap akhir eksperimen berupa proses *denormalisasi* data hasil testing untuk mendapatkan nilai hasil prediksi dan nilai evaluasi dari hasil kinerja model. Manfaat dari proses *training* dan prediksi dilakukan secara terpisah adalah ketika menjalankan proses prediksi jika tidak ada data baru. Tidak perlu melakukan *pemodelan data training* kembali melainkan langsung memuat dari *file .h5* tersebut. Hal itu akan mempercepat proses prediksi karena tanpa harus melakukan *training* kembali terhadap data yang sama. Adapun arsitektur lengkapnya dapat dilihat pada Gambar 6 berikut:



Gambar 6. Arsitektur LSTM

2.4 Evaluation

Penelitian ini digunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). *Root Mean Square Error* (RMSE) yaitu metode alternatif untuk mengevaluasi teknik peramalan yang digunakan untuk mengukur tingkat akurasi hasil perkiraan suatu model. Nilai yang dihasilkan RMSE merupakan nilai rata – rata kuadrat dari jumlah kesalahan pada model prediksi. *Root Mean Square Error* (RMSE) adalah teknik yang mudah diimplementasikan dan telah sering digunakan dalam berbagai studi yang berkaitan dengan peramalan. *Mean Absolute Percentage Error* (MAPE) merupakan rata – rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual. MAPE digunakan untuk menghitung persentase kesalahan antara nilai aktual dan nilai prediksi.


3. Hasil dan Pembahasan

3.1 Dataset dan Plotting Dataset

Dataset dan *Plotting Dataset* yakni Di bawah ini merupakan data produktifitas pangan provinsi Sumatera selatan (17 Kabupaten/kota) 2020-2024 dan dijadikan *dataset* dalam penelitian ini. Pada data yang terkumpul di lihat setiap bulan pada Tabel 1. Dari Tabel 1 dilakukan *plotting dataset* sehingga menghasilkan visualisasi seperti pada Gambar 7 berikut.

Tabel 1. Data IKP Provinsi SumSel


NO	Kab_kota	Tahun	kode_kab/kota	IKP	Kelompok_ikp	Klasifikasi
1	Ogan Komering Ulu	2018	16.01	46,47	4	Agak Tahan
2	Ogan Komering Ilir	2018	16.02	50,65	5	Tahan
3	Muara Enim	2018	16.03	46,57	4	Agak Tahan
4	Lahat	2018	16.04	53,96	5	Tahan
5	Musi Rawas	2018	16.05	50,15	5	Tahan
....	Empat Lawang	2018	16.11	41,73	4	Agak Tahan
102	Pali	2018	16.12	40,66	4	Agak Tahan

**Gambar 7.** Visualisasi data awal

Dari hasil visualisasi Gambar 7 tervisualisasi data yang tidak teratur sehingga akan mengalami kesulitan dalam membaca trend ketahanan pangan setiap kabupaten dan kota se Sumatera selatan sehingga dilakukan visualisasi ulang menggunakan LSTM dan Arima.

3.2 Stasioner dan Differencing

Fungsi *stasioner* dan *differencing* adalah dua konsep penting dalam analisis deret waktu, terutama dalam pemodelan ARIMA (*Autoregressive Integrated Moving Average*). Stasioneritas mengacu pada sifat data deret waktu yang rata-rata dan variansnya konstan sepanjang waktu, sedangkan *differencing* adalah teknik untuk mengubah data deret waktu yang tidak stasioner menjadi stasioner. Adapun *differencing data* nya dapat dilihat pada Gambar 8 berikut:

**Gambar 8.** Differencing Data

Berdasarkan Gambar 7 bahwa terlihat datanya tidak stabil, LSTM (*Long Short-Term Memory*) tidak secara eksplisit butuh data stasioner, karena LSTM bisa belajar dari pola panjang dan kompleks. Namun, dalam praktiknya: *Differencing* sering digunakan untuk memperbaiki performa. Setelah model memprediksi hasil (misalnya hasil dari *differencing*), kita perlu melakukan proses inverse differencing untuk mengembalikan ke skala aslinya untuk menghilangkan *trend* (naik/turun konstan), Membantu model mengenali pola musiman atau pola yang lebih bersih dan Membuat prediksi lebih stabil. Berdasarkan hal tersebut diperlukan uji ADF (*Augmented Dickey-Fuller*) yang berfungsi sebagai alat statistik untuk menguji *stasioneritas* dari data *time series*. Pada plot di atas terlihat bahwa data belum stasioner terhadap *mean* sehingga per-

lu dilakukan *differencing* terlebih dahulu. Selain itu uji *stasioneritas* bisa dengan menggunakan *ADF Test*. Didapatkan *output* seperti pada Tabel 2 berikut: Uji ADF menunjukkan bahwa nilai *p.value* sebesar 0.944


Tabel 2. Data uji ADF (*Augmented Dickey-Fuller*)

ADF Statistic	-8.5469
p-Value	9.44
ADF Statistic (Differenced)	-8.5469
p-Value (Differenced)	9.449

lebih besar dari $\alpha(0.05)$ sehingga Hipotesis nol yaitu data tidak stasioner diterima atau dapat dikatakan data belum stasioner.

3.3 Auto Correlation

Autokorelasi, yakni menganalisis data deret waktu untuk mencari korelasi nilai pada titik-titik yang berbeda dalam deret waktu. Salah satu asumsi utama adalah bahwa kesalahan dalam memprediksi variabel independen dalam model tersebut adalah independen. Sering kali, ketika bekerja dengan data deret waktu, Anda akan menemukan kesalahan yang bergantung pada waktu. Cara untuk mengatasinya adalah dengan meregresikan variabel dependen terhadap dirinya sendiri menggunakan jeda waktu yang diidentifikasi oleh uji autokorelasi. Adapun hasil autocorrelation pada penelitian ini dapat di lihat pada Gambar 9 ini:



Gambar 9. DAutocorellation


Gambar 9 menunjukkan bahwa fungsi mengukur seberapa besar hubungan (korelasi) antara nilai dalam deret waktu (*time series*) dengan nilai-nilai sebelumnya (*lag*-nya sendiri dengan skema:

1. *Lag 0* (pasti 1):Ini korelasi data dengan dirinya sendiri: Data dominan.
2. Batang keluar dari garis biru: Artinya signifikan nilai pada *lag* itu berkorelasi kuat dengan masa sekarang: Ada 3 buah Data
3. Batang dalam garis biru:Artinya tidak signifikan, tidak ada korelasi kuat pada *lag* itu: banyak Data
4. Polanya naik turun pelan:Menunjukkan adanya *trend*, data tidak stasioner: tidak Terjadi
5. Pola musiman:Jika ada pola berulang tiap beberapa *lag* (misalnya puncak di *lag* 12, 24, dst), itu indikasi musiman (*seasonality*).

3.4 Partial Auto Corellation

Fungsi Autokorelasi Parsial, sering disebut *PACF*, mirip dengan *ACF* kecuali bahwa ia hanya menampilkan korelasi antara dua pengamatan yang tidak dijelaskan oleh jeda yang lebih pendek di antara pengamatan tersebut. Plot *ACF* menunjukkan hubungan antara y_t dan y_{t-k} untuk nilai k yang berbeda. Bila y_t dan y_{t-1}

saling berkorelasi, maka kita dapat berasumsi bahwa y_{t-1} dan y_{t-2} juga akan berkorelasi karena keduanya terhubung oleh *lag* 1. Akan tetapi, ada kemungkinan pula bagi y_t dan y_{t-2} untuk berkorelasi hanya karena keduanya terhubung dengan y_{t-1} , dan bukan karena terdapat informasi baru dalam y_{t-2} yang dapat digunakan dalam peramalan y_t . Untuk mengatasi masalah ini, kami menggunakan autokorelasi parsial untuk menghilangkan sejumlah pengamatan jeda. *PACF* hanya mengukur hubungan antara y_t dan y_{t-k} dengan menghilangkan efek jeda 1 hingga k . Adapun hasil *partial auto correlation* dapat dilihat pada Gambar 10.



Gambar 10. *Partial Correlation*

Gambar 10 menunjukkan bahwa:

1. *Lag* 0 Selalu 1 (data dengan dirinya sendiri).
2. *Lag* 1 signifikan, sisanya kecil dan tidak signifikan: Hanya ada korelasi langsung dengan *lag* 1 → cocok untuk AR[?]
3. *Lag* 1 dan 2 signifikan, sisanya tidak: Korelasi langsung hanya sampai *lag* 2 → cocok untuk AR[2].
4. Semua *lag* turun perlahan tapi signifikan: Bisa jadi data tidak stasioner → perlu *differencing*
5. Pola musiman: Misalnya puncak signifikan di *lag* 12, 24, dst → indikasi *seasonality* (musiman)

Untuk skenario pertama yaitu skenario yang menggunakan keseluruhan data. Parameter yang direkomendasikan oleh *Auto-ARIMA* adalah parameter ARIMA (0,0,1) (0,0,0) [0] *intercept*:

```
Best model: ARIMA(0,0,1)(0,0,0)[0] intercept
Total fit time: 17.040 seconds
SARIMAX Results
=====
Dep. Variable: y No. Observations: 102
Model: SARIMAX(0, 0, 1) Log Likelihood: -335.674
Date: Mon, 07 Jul 2025 AIC: 677.347
Time: 13:34:08 BIC: 685.222
Sample: 0 HQIC: 680.536
Covariance Type: opg
=====
coef std err z P>|z| [0.025 0.975]
-----
intercept 48.7880 0.822 59.369 0.000 47.177 50.399
ma.L1 0.1565 0.096 1.626 0.104 -0.032 0.345
sigma2 42.2548 6.502 6.499 0.000 29.511 54.998
=====
Ljung-Box (L1) (Q): 0.00 Jarque-Bera (JB): 3.98
Prob(Q): 0.98 Prob(JB): 0.14
Heteroskedasticity (H): 0.97 Skew: 0.48
Prob(H) (two-sided): 0.94 Kurtosis: 2.89
=====
```


Gambar 11. Coefisien setelah Autocorrelation

ada Gambar 11 merupakan hasil dari *summary* pencarian parameter terbaik menggunakan *Auto-ARIMA* untuk skenario kedua ini, dan parameter *Auto-ARIMA* tidak mempertimbangkan komponen musiman,

meskipun pengaturan *seasonal=True* telah diterapkan. Hal ini menunjukkan bahwa algoritma tidak mendeteksi pola musiman yang signifikan dalam data atau bahwa parameter lain, seperti *m* (periode musiman), tidak diatur dengan tepat. Akibatnya, model yang dihasilkan cenderung berperilaku seperti ARIMA non-musiman, yang dapat mempengaruhi akurasi peramalan dalam memprediksi ketahanan pangan Sumatera selatan.


3.5 Forecasting ARIMA dan LSTM

Forecasting atau peramalan adalah proses memperkirakan kejadian di masa depan berdasarkan data dan informasi yang tersedia. Dalam konteks bisnis, *forecasting* digunakan untuk memprediksi berbagai hal seperti permintaan produk, penjualan, atau tren pasar, yang membantu perusahaan dalam pengambilan keputusan dan perencanaan. ARIMA dan LSTM mampu memprediksi bahwa ketahanan pangan akan mengalami kestabilan untuk 5 tahun ke depan.




Gambar 12. Visualisasi ARIMA vs LSTM

Visualisasi Gambar 12 menunjukkan bahwa ketahanan pangan diprediksi akan mengalami ketidakstabilan untuk 5 tahun ke depan melihat data yang terkadang naik begitu tinggi dan turun begitu tajam sehingga ketahanan pangan diprediksi tidak akan konsisten naik maupun turun. Namun setelah di optimalisasi dengan *Bayesian Optimization data actual LSTM* dan *Fitted Arima* hampir menunjukkan konsistensi dan visualisasi yang sama sehingga terjadi perubahan *trend* seperti terlihat pada Gambar 13:



Gambar 13. Visualisasi ARIMA-LSTM-BAYESIAN

hasil prediksi 5 tahun ke depan setelah di prediksi sehingga menghasilkan visualisasi seperti Gambar 14 berikut ini:



Gambar 14. Trend Ketahanan Pangan Sumsel

Data visualisasi pada Gambar 14 sudah terlihat bahwa pada tahun 2018 terjadi penurunan ketahanan pangan namun terjadi *fullback* dari 2019 sampai dengan tahun 2023 terjadi kenaikan ketahanan pangan yang stabil.

3.6 Evaluasi

Model Evaluasi penelitian ini menggunakan 3 model yakni MAS, MSE dan RMSE yakni

1. MAE, MSE, dan RMSE memberikan nilai absolut sementara MAPE memberikan nilai relative
2. MAE menghitung rata-rata dari selisih absolut antara prediksi dan nilai sebenarnya, sementara MSE dan RMSE menghitung rata-rata dari selisih kuadrat antara prediksi dan nilai sebenarnya.
3. RMSE merupakan pengembangan dari MSE dengan mengambil akar kuadrat dari MSE.
4. MAPE menghitung persentase kesalahan absolut rata-rata antara prediksi dan nilai sebenarnya.

Adapun hasilnya dapat dilihat pada Tabel 3 berikut ini: Penelitian ini merupakan optimalisasi model LS-

Tabel 3. Perbandingan Kinerja Model

Model	MAPE (%)	MAE	RMSE
ARIMA	10.92	5.29	6.50
LSTM	9.56	5.16	6.65
ARIMA + Bayesian Opt.	8.98	4.40	5.59
LSTM + Bayesian Opt.	8.50	4.62	6.09

TM (*Long Short-Term Memory*) dengan kemampuan mode yang Dapat menangkap pola jangka panjang dan non-linear dalam data, Mampu bekerja dengan *multivariat time series* (banyak variabel) serta baik untuk data besar dan kompleksitas tinggi. Namun Memerlukan banyak data dan waktu pelatihan, Sulit diinterpretasi (*black-box model*), Lebih rumit secara komputasi (butuh *GPU* untuk efisiensi tinggi) sehingga kekurangan dalam menginterpretasikan data tersebut dapat diatasi oleh ARIMA yang mampu dengan Mudah diinterpretasikan, Cocok untuk data *time series univariat* (satu variabel) dan baik untuk data yang stasioner (pola tetap sepanjang waktu).

Temuan penelitian terbukti berhasil menghasilkan MAPE hanya 10% hal ini menunjukkan keunggulan dalam memprediksi ketahanan pangan yang akurat dengan mencapai akurasi 92 %. Hal ini menunjukkan bahwa penelitian ini dapat dijadikan informasi dan bahan kajian dalam menentukan kebijakan danantisipasi ketahanan pangan yang didapatkan trend akan meningkat sampai dengan 5 tahun ke depan.

4. Simpulan

Penelitian ini mengevaluasi kinerja ARIMA dan LSTM dalam meramalkan Ketahanan Pangan Sumatera Selatan menggunakan dua skenario data: basic LSTM dan ARIMA dan LSTM, ARIMA yang di optimasi dengan *Bayes Optimization*). Hasil menunjukkan bahwa LSTM menghasilkan visualisasi data yang tidak konsisten dengan turun dan naik data yang *inbalancing* sedangkan arima mampu memprediksi data dengan lebih balance. Kedua visualisasi tersebut lebih di optimasi dengan *Bayesian Optimization* sehingga menghasilkan data yang balance dan beriringan satu sama lain MAPE nya juga dibawah 10% sehingga menunjukkan tingkat *error* data sangat sedikit. Temuan ini menegaskan bahwa pemilihan model peramalan harus disesuaikan dengan karakteristik data. Hasil penelitian ini dapat menjadi panduan dalam memilih metode prediksi ketahanan pangan Sumatera selatan.

Ucapan Terima kasih

Peneliti mengucapkan banyak terima kasih kepada DPPM KemdikSaintek yang telah memberikan pendanaan penelitian sehingga penelitian ini berjalan dengan maksimal.

Pustaka

- [1] Tim Penyusun, *Buku Pengembangan Teknologi Untuk Ketahanan Pangan Halal Indonesia*. Komite Nasional Ekonomi dan Keuangan Syariah, 2024.
- [2] M. A. F. L and A. P. N, "Analisis perkembangan ketahanan pangan di indonesia: Pendekatan menggunakan big data dan data mining," in *Seminar Nasional Official Statistics 2023*, 2023.
- [3] A. M, S. H, D. M.K., and M. H.N., "Pemanfaatan teknologi informasi dalam optimalisasi produksi tanaman pangan: Studi bibliometrik skala nasional," *Jurnal Multidisiplin West Science*, vol. 2, no. 8, pp. 668–683, 2024.
- [4] R. V, Virginia, N. Herman, and K. Neni, "Peran pemerintah dalam mewujudkan ketahanan pangan di kabupaten minahasa selatan (studi dinas ketahanan pangan minahasa selatan)," *Jurnal Governance*, vol. 1, no. 1, pp. 1–12, 2021.
- [5] "Strategi ketahanan pangan nasional guna meningkatkan kemandirian dan daya saing ekonomi dalam rangka ketahanan nasional."
- [6] W. L and S. M, "Penerapan long short term memory pada data time series untuk memprediksi penjualan produk pt. metiska farma," vol. 8.
- [7] A. H, J. I, G. D, I. T, T. I, A. P *et al.*, "Sistem penjadwalan kuliah menggunakan algoritma genetika di sekolah tinggi ilmu tarbiyah kota pagar alam," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, 2024.
- [8] S. A, M. B, P. N.S., and E. E, "Implementasi metode support vector machine dengan algoritma genetika pada prediksi konsumsi energi untuk gedung beton bertulang," *Faktor Exacta*, vol. 16, no. 2, Jul 2023.
- [9] H. H and E. E.A., "Enhancing stock price prediction: Lstm-rnn fusion model," in *Procedia Computer Science*. Elsevier B.V., 2024, pp. 920–929.
- [10] C. J, M. S, and F. T.P., "Implementasi metode long short term memory (lstm) untuk memprediksi harga bahan pokok nasional," *Jurnal Sistem dan Teknologi Informasi (JUSTIN)*, vol. 11, no. 2, p. 346, Jul 2023.
- [11] A. L. Lestari, D. M. Midyanti, and R. Hidayati, "Prediksi ketersediaan pangan di kalimantan barat dengan menggunakan metode madaline."
- [12] K. A, R. R, P. S. I, and R. F. J, "Pengujian algoritma long short term memory untuk prediksi kualitas udara dan suhu kota bandung," *Jurnal Telematika*, vol. 15, no. 1, 2020.
- [13] D. D.A., S. L, R. S, and K. M, "Lstm-based estimation of time-varying parameters in a spatiotemporal pde model for prediction of epidemic spread," in *IFAC-PapersOnline*. Elsevier B.V., 2024, pp. 468–473.

- [14] G. W, "Research on gold price forecasting based on lstm and linear regression," in *SHS Web of Conferences*, vol. 181, 2024, p. 02005.
- [15] A. A, C. N, and E. M. M.D., "Prediction of rice production to support food security in bogor regency using linear regression and support vector machine (svm)," *Jurnal Teknik*, vol. 16, no. 1, pp. 13–18, Apr 2024.
- [16] B. L, V. P, T. K, and T. P, "Gold-price forecasting method using long short-term memory and the association rule," *Journal of Mobile Multimedia*, vol. 19, no. 1, pp. 165–186, 2023.
- [17] F. N, "Optimasi prediksi harga emas menggunakan cnn-bi-lstm dengan mekanisme attention dan bayesian optimization," *Management, Accounting and Technology (Jematech)*, vol. 8, no. 1, 2025, [Online]. Available: <https://doi.org/10.32500/Jematech.V8i1.8668>. [Online]. Available: <https://doi.org/10.32500/Jematech.V8i1.8668>
- [18] P. F, "Penerapan metode support vector machine terhadap klasifikasi jenis jambu biji," *JIKO (Jurnal Informatika dan Komputer)*, vol. 8, no. 1, p. 193, Feb 2024.
- [19] P. F, R. C, and D. F, "Application of particle swarm optimization to improve the performance of the k-nearest neighbor in stunting classification in south sumatra, indonesia," *International Journal of Education and Management Engineering*, vol. 14, no. 6, pp. 32–43, 2024. [Online]. Available: <https://doi.org/10.5815/ijeme.2024.06.03>
- [20] K. G.D., P. K.C., and T. S, "Deep learning forecasting: An lstm neural architecture based approach to rainfall and flood impact predictions in bihar," in *Procedia Computer Science*. Elsevier B.V., 2024, pp. 1455–1466.
- [21] K. S and K. D.E., "Advancing short-term load forecasting with decomposed fourier arima: A case study on the greek energy market," *Energy*, 2025. [Online]. Available: <https://doi.org/10.1016/j.energy.2025.135854>
- [22] S. S, S. S.A., and R. T, "Modelling time series with temporal and spatial correlations in transport planning using hierarchical arima-copula model: A bayesian approach," *Expert Systems with Applications*, vol. 274, May 2025.