



Perbandingan Algoritma *Backpropagation* dan SARIMA dalam Memprediksi Kebutuhan Nasi untuk Penjualan (Studi Kasus: Restoran Grillme Pontianak)

Muhammad Khoir Nugraha

Teknik Informatika, Universitas Muhammadiyah Pontianak, Indonesia

Penulis Korespondensi: muhammadkhoirnugraha@gmail.com

Abstract. This study aims to design, implement, and compare the performance of the Backpropagation algorithm from Artificial Neural Networks and the Seasonal Autoregressive Integrated Moving Average (SARIMA) model in predicting the optimal daily rice requirement at Grillme Restaurant in Pontianak. The main problem faced by the restaurant is the uncertainty in determining the required daily rice stock, which periodically results in either understocking (shortage) or overstocking (wastage), leading to operational losses. To address this, the study utilizes historical daily rice sales data from January 2023 to April 2025 as the database for training and testing both predictive models. The SARIMA approach is employed to capture time series components (trend and seasonality), while Backpropagation is utilized to model non-linear patterns. Comparative test results indicate that the SARIMA model achieved superior accuracy compared to the Backpropagation model. This is confirmed by the Mean Absolute Percentage Error (MAPE) value of the SARIMA algorithm being 17.35%, which is lower than the MAPE value of Backpropagation at 19.62%. The MAPE values obtained by both models demonstrate good predictive capability, but it is concluded that SARIMA is more recommended for a more efficient and planned management of rice stock at Grillme Restaurant in Pontianak.

Keywords: Artificial Neural Network; Backpropagation; Prediction; Rice; SARIMA.

Abstrak. Penelitian ini bertujuan untuk merancang, mengimplementasikan, dan membandingkan kinerja algoritma *Backpropagation* dari Jaringan Saraf Tiruan dan model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) untuk memprediksi kebutuhan nasi harian yang optimal di Restoran Grillme Pontianak. Permasalahan utama yang dihadapi oleh restoran adalah adanya ketidakpastian dalam menentukan jumlah stok nasi yang dibutuhkan setiap hari, yang secara berkala mengakibatkan *understock* (kekurangan) atau *overstock* (pemborosan) yang berujung pada kerugian operasional. Untuk mengatasi hal tersebut, penelitian ini memanfaatkan data historis penjualan nasi harian dari Januari 2023 hingga April 2025 sebagai basis data untuk pelatihan dan pengujian kedua model prediktif tersebut. Pendekatan SARIMA digunakan untuk menangkap komponen deret waktu (tren dan musiman), sementara *Backpropagation* dimanfaatkan untuk memodelkan pola *non-linear*. Hasil pengujian komparatif menunjukkan bahwa model SARIMA berhasil memberikan akurasi yang lebih unggul dibandingkan dengan model *Backpropagation*. Hal ini dikonfirmasi melalui nilai *Mean Absolute Percentage Error* (MAPE) algoritma SARIMA sebesar 17,35%, yang lebih rendah dibandingkan dengan nilai MAPE *Backpropagation* sebesar 19,62%. Nilai MAPE yang diperoleh kedua model menunjukkan kemampuan prediksi yang baik, namun disimpulkan bahwa SARIMA lebih direkomendasikan untuk pengelolaan stok nasi secara lebih efisien dan terencana di Restoran Grillme Pontianak.

Kata kunci: *Backpropagation*; Jaringan Syaraf Tiruan; Nasi; Prediksi; SARIMA

1. LATAR BELAKANG

Restoran Grillme sering mengalami kendala operasional akibat ketidakakuratan prediksi stok nasi. Saat ini, pesanan nasi ke dapur pusat hanya didasarkan pada perkiraan karyawan restoran, sehingga sering terjadi kekurangan stok pada jam sibuk yang memicu keterlambatan penyajian. Masalah ini krusial karena nasi memiliki masa simpan yang singkat; kelebihan stok menyebabkan pemborosan, sedangkan kekurangan stok menurunkan kepuasan pelanggan.

Untuk mengatasi hal ini, diperlukan metode prediksi yang akurat sebagaimana yang telah dibuktikan dalam beberapa penelitian. Contohnya, penggunaan algoritma *Backpropagation*

Neural Network telah terbukti efektif memprediksi permintaan beras dengan tingkat kesalahan (MSE) yang sangat rendah (Marthasari et al., 2021). Kemudian terdapat penelitian dari (Mufinnun et al., 2022) yaitu memprediksi jumlah penjualan Toyota Avanza dengan menganalisa jumlah penjualan menggunakan *Backpropagation*. Selanjutnya oleh (Iqbal Ulumando, 2022) yaitu memprediksi hasil produksi kopi di (NTT) setiap tahunnya menggunakan *Backpropagation*. Selain itu, metode SARIMA juga menunjukkan akurasi tinggi dalam memprediksi produksi komoditas pangan lainnya (Sunariadi et al., 2022). Model SARIMA juga diterapkan dalam memprediksi produksi minyak kelapa sawit oleh (Tokan & Hermawan, 2023).

Berdasarkan referensi tersebut, penelitian ini berfokus pada prediksi kebutuhan nasi harian menggunakan data penjualan. Tujuannya adalah untuk mengoptimalkan ketersediaan stok, mengurangi beban kerja dapur, dan memastikan kelancaran pelayanan kepada pelanggan.

2. KAJIAN TEORITIS

Prediksi (Peramalan)

Prediksi (peramalan) adalah usaha menduga atau memperkirakan sesuatu yang akan terjadi di waktu mendatang dengan memanfaatkan berbagai informasi yang relevan pada waktu-waktu sebelumnya (historis) melalui suatu metode ilmiah. Tujuan dari prediksi adalah mendapatkan informasi apa yang akan terjadi di masa datang dengan probabilitas kejadian terbesar. Metode prediksi dapat dilakukan secara kualitatif melalui pendapat para pakar atau secara kuantitatif dengan perhitungan secara matematis. Salah satu metode prediksi kuantitatif adalah menggunakan analisis deret waktu (*time series*) (Nurmahaludin, 2017).

Jaringan Syaraf Tiruan

Jaringan syaraf tiruan bisa dibayangkan seperti otak buatan di dalam cerita fiksi ilmiah. Otak buatan ini dapat berpikir seperti manusia, dan juga sepandai manusia dalam menyimpulkan sesuatu dari potongan-potongan informasi yang diterimanya. Khayalan manusia tersebut mendorong para peneliti untuk mewujudkannya. Komputer diusahakan agar bisa berpikir sama seperti cara berpikir manusia. Caranya adalah dengan melakukan peniruan terhadap aktivitas yang terjadi di dalam sebuah jaringan saraf biologis (Fitriyanti, 2023).

Algoritma Backpropagation

Pendekatan jaringan syaraf tiruan dapat meniru perilaku yang kompleks dan *non-linear* melalui *neuron*, dan telah banyak digunakan dalam prediksi. Model yang paling banyak digunakan pada kecerdasan buatan adalah model *backpropagation*. Ciri khas *backpropagation* melibatkan tiga lapisan : lapisan *input*, dimana data diperkenalkan ke jaringan; *hidden layer*,

dimana data diproses; dan lapisan *output*, dimana hasil dari masukan yang diberikan oleh lapisan *input* (Huang & Wu, 2017). Adapun langkah-langkah dalam melakukan tahapan pelatihan algoritma *backpropagation* oleh (Lestari, 2017) antara lain :

a. Fase Propagasi Maju (*feedforward*)

Pada tahap ini masing-masing *unit input* (x_i) menerima sinyal *input* dan akan mendistribusikan sinyal tersebut ke tiap-tiap *hidden unit* (z_j). Masing-masing *hidden unit* selanjutnya akan menghitung aktivasinya kemudian mengirim sinyal pada setiap *unit output* (y_k). Selanjutnya *unit output* juga menghitung aktivasinya untuk mendapatkan nilai terhadap *input* yang diberikan.

b. Fase Propagasi Mundur (*backpropagation*)

Pada tahap ini masing-masing *unit output* y_k ($k = 1,2,\dots,m$) menerima target *output* yang diharapkan, yang akan dikomparasikan dengan *output* yang didapat. Faktor (δ_k) dipakai untuk menghitung koreksi *error* (Δw_{jk}) yang digunakan dalam memperbarui bobot di *output layer* ke masing-masing *hidden layer* yang terhubung dengan *output layer*. Menggunakan pendekatan yang serupa, dihitung faktor koreksi *error* Δv_{ji} (δ_j) pada masing-masing *unit hidden layer* sebagai acuan perubahan bobot.

c. Fase Perubahan Bobot

Pada tahap ini masing-masing *unit output* y_k ($k = 1,2,\dots,m$) akan mengganti bobot dan biasanya ke setiap *hidden unit*, dan setiap *hidden unit* akan memperbarui bobotnya dengan setiap *unit input*. Tahap-tahap tersebut diulangi hingga kondisi penghentian terpenuhi. Biasanya kondisi penghentian yang selalu dipakai adalah jumlah iterasi atau kesalahan. Iterasi akan berhenti bila jumlah iterasi yang dilaksanakan telah melebihi jumlah maksimum iterasi yang ditetapkan atau bila kesalahan yang terjadi lebih kecil dari batas toleransi yang diizinkan.

SARIMA

Secara ringkas SARIMA adalah sebuah algoritma pemrosesan data berbentuk deret waktu, yang dipergunakan untuk menganalisa dan memprediksi berdasarkan pola musiman. Algoritma ini adalah pengembangan dari model sebelumnya yaitu ARIMA (*Autoregressive Integrated Moving Average*), namun SARIMA sudah di lengkapi penanganan pola musiman yang tidak sederhana (Dabral & Murry, 2017). Secara umum model SARIMA yaitu $(\rho, d, q)(P, D, Q)$, dan dapat dituliskan dalam persamaan 1 dibawah ini (Amanda et al., 2024) :

$$(Bs)(1 - Bd)(1 - Bs)DYt = (B)t \quad (1)$$

Feature Engineering

Feature Engineering adalah suatu permasalahan dalam mengubah data mentah menjadi kumpulan data. pada sebagian besar masalah praktis, *feature engineering* adalah proses *labor-intensive* yang mempunyai domain *knowledge*. Dalam hal ini, peran dari seorang data analis adalah menciptakan fitur informatif yang memungkinkan algoritma pembelajaran membangun model yang berfungsi dengan baik dalam memprediksi label data yang digunakan untuk pelatihan (Reid Turner et al., 1999).

Evaluasi Model

a. *Mean Absolute Error (MAE)*

Evaluasi dilakukan menggunakan *Mean Absolute Error (MAE)*. Mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual. Semakin kecil nilai MAE, semakin baik model (Yulis et al., 2025). MAE dihitung dengan persamaan 2 dibawah ini :

$$MAE = \frac{1}{n} \sum_{k=1}^n |tk - yk| \quad (2)$$

b. *Mean Absolute Percentage Error (MAPE)*

MAPE adalah metrik evaluasi yang sering digunakan dalam peramalan untuk mengukur akurasi prediksi dalam bentuk persentase kesalahan absolut, sehingga hasilnya mudah dipahami dan dibandingkan antar *dataset* (Goodfellow et al., 2016). MAPE dihitung dengan persamaan 3 dibawah ini :

$$MAPE = \frac{100\%}{n} \sum_{k=1}^n \left| \frac{tk - yk}{tk} \right| \quad (3)$$

Hasil MAPE dinyatakan dalam persentase, semakin kecil MAPE semakin baik akurasi prediksi berikut seperti tabel 1 dibawah ini :

Tabel 1. Kriteria MAPE.

Kategori	MAPE	Interpretasi
Sangat Baik	< 10%	Presisi tinggi
Baik	10% – 20%	Dapat diterima
Cukup	20% – 30%	Perlu perhatian
Buruk	> 30%	Tidak direkomendasikan

3. METODE PENELITIAN

Penelitian ini menggunakan data penjualan dari restoran Grillme yaitu penjualan nasi harian dari bulan Januari 2023 hingga April 2025 yang mencakup variabel tanggal, bulan, tahun, dan penjualan nasi.

Ketika data diproses data di konversi dari satuan porsi menjadi kg kemudian dibersihkan agar menghindari bias dari nilai 0 dengan nilai rata-rata penjualan. Selanjutnya ditentukanlah pembagian *dataset* menjadi data pelatihan 20% dan pengujian 80% yang di normalisasi bertujuan untuk mengubah data mentah menjadi format dalam rentang nilai tertentu (Han et al., 2012).

Pengujian menggunakan MAPE untuk mengevaluasi tingkat akurasi model prediksi yang telah dibangun. MAPE digunakan untuk mengetahui seberapa besar persentase kesalahan terhadap nilai sebenarnya (Goodfellow et al., 2016).

4. HASIL DAN PEMBAHASAN

Hasil dari penerapan algoritma *Backpropagation* dan SARIMA menunjukkan keduanya dapat diterapkan pada studi kasus memprediksi kebutuhan nasi untuk penjualan, namun dari kedua algoritma tersebut di lakukan perbandingan mana yang mendapatkan hasil terbaik dalam memprediksi.

Model *Backpropagation*

Data penjualan nasi pada restoran Grillme Pontianak dianalisis untuk memahami pola musiman, harian dan pengaruh faktor eksternal seperti hari libur. *Dataset* terdiri dari tanggal dan jumlah porsi nasi yang terjual setiap harinya data berjumlah 851 dari tahun 2023 Januari hingga 2025 April, berikut 10 data pertama pada gambar 1.

```
1. Memuat dan memproses data...
1.1. Data asli yang dimuat:
      date  nasi_terjual
0 2023-01-01      0.0
1 2023-01-02     394.0
2 2023-01-03     368.0
3 2023-01-04     292.0
4 2023-01-05     329.0
5 2023-01-06     385.0
6 2023-01-07     442.0
7 2023-01-08     363.0
8 2023-01-09     317.0
9 2023-01-10     308.0
```

Gambar 1. Proses *input* data.

Selanjutnya data di konversi ke dalam satuan kg, yang mana hitungannya adalah 1 porsi sama dengan 200gr, berikut pada gambar 2.

	date	nasi_terjual	nasi_terjual_kg
0	2023-01-01	0.0	0.0
1	2023-01-02	394.0	78.8
2	2023-01-03	368.0	73.6
3	2023-01-04	292.0	58.4
4	2023-01-05	329.0	65.8
5	2023-01-06	385.0	77.0
6	2023-01-07	442.0	88.4
7	2023-01-08	363.0	72.6
8	2023-01-09	317.0	63.4
9	2023-01-10	308.0	61.6

Gambar 2. Proses konversi satuan.

Selanjutnya data di praproses untuk menangani nilai 0 dengan menginterpolasi agar pola musiman tetap terjaga, berikut pada gambar 4.3.

	date	nasi_terjual_kg
1	2023-01-02	78.8
2	2023-01-03	73.6
3	2023-01-04	58.4
4	2023-01-05	65.8
5	2023-01-06	77.0
6	2023-01-07	88.4
7	2023-01-08	72.6
8	2023-01-09	63.4
9	2023-01-10	61.6
10	2023-01-11	51.8

Gambar 3. Proses *Handling missing values*.

Kemudian data ditambahkan fitur untuk membatu performa model dalam membaca pola beberapa fitur, berikut pada gambar 4.

	date	nasi_terjual_kg	day_of_week	month	day_of_month	is_weekend
1	2023-01-02	78.8	0	1	2	0
2	2023-01-03	73.6	1	1	3	0
3	2023-01-04	58.4	2	1	4	0
4	2023-01-05	65.8	3	1	5	0
5	2023-01-06	77.0	4	1	6	0
6	2023-01-07	88.4	5	1	7	1
7	2023-01-08	72.6	6	1	8	1
8	2023-01-09	63.4	0	1	9	0
9	2023-01-10	61.6	1	1	10	0
10	2023-01-11	51.8	2	1	11	0

Gambar 4. Proses *feature engineering*.

Selanjutnya data di bagi 80% data *training* dan 20% data *testing* berikut pada gambar 5 dan gambar 6.

	date	nasi_terjual_kg
671	2024-11-02	58.2
672	2024-11-03	68.8
673	2024-11-04	29.6
674	2024-11-05	33.4
675	2024-11-06	44.4
676	2024-11-07	45.4
677	2024-11-08	42.0
678	2024-11-09	57.6
679	2024-11-10	47.6
680	2024-11-11	42.4

Gambar 4. Data *training* 80%.

	date	nasi_terjual_kg
681	2024-11-12	23.4
682	2024-11-13	35.0
683	2024-11-14	35.0
684	2024-11-15	42.0
685	2024-11-16	58.2
686	2024-11-17	48.8
687	2024-11-18	28.2
688	2024-11-19	29.6
689	2024-11-20	35.2
690	2024-11-21	30.4

Gambar 5. Data *testing* 20%.

Selanjutnya data x_{train} dan y_{train} di normalisasikan berikut pada gambar 4.7 dan gambar 8.

0	0.756032	0.686327	0.482574	0.581769	0.731903	0.884718	0.672922
1	0.686327	0.482574	0.581769	0.731903	0.884718	0.672922	0.549598
2	0.482574	0.581769	0.731903	0.884718	0.672922	0.549598	0.525469
3	0.581769	0.731903	0.884718	0.672922	0.549598	0.525469	0.394102
4	0.731903	0.884718	0.672922	0.549598	0.525469	0.394102	0.297587

Gambar 6. Proses normalisasi data *training* X.

0	0.549598
1	0.525469
2	0.394102
3	0.297587
4	0.498660

Gambar 7. Proses normalisasi data *training* Y.

Selanjutnya mengoptimasi model dengan mencari model terbaik menggunakan *randomized search*, berikut pada gambar 9.

```
[CV] END activation=relu, alpha=0.0966255307264138, batch_size=32, early_stopping=True, hidden_layer_
sizes=(3, 5, 50), learning_rate_init=0.030627350570408243, max_iter=1000, n_iter_no_change=20, random
_state=42, solver=adam; total time= 0.0s
[CV] END activation=relu, alpha=0.0966255307264138, batch_size=32, early_stopping=True, hidden_layer_
sizes=(3, 5, 50), learning_rate_init=0.030627350570408243, max_iter=1000, n_iter_no_change=20, random
_state=42, solver=adam; total time= 0.1s
[CV] END activation=relu, alpha=0.016626693906300248, batch_size=32, early_stopping=True, hidden_lay
e_r_sizes=(3, 50), learning_rate_init=0.043340148070636964, max_iter=1000, n_iter_no_change=20, random_
state=42, solver=adam; total time= 0.0s
[CV] END activation=relu, alpha=0.016626693906300248, batch_size=32, early_stopping=True, hidden_lay
e_r_sizes=(3, 50), learning_rate_init=0.043340148070636964, max_iter=1000, n_iter_no_change=20, random_
state=42, solver=adam; total time= 0.0s
[CV] END activation=relu, alpha=0.016626693906300248, batch_size=32, early_stopping=True, hidden_lay
e_r_sizes=(3, 50), learning_rate_init=0.043340148070636964, max_iter=1000, n_iter_no_change=20, random_
state=42, solver=adam; total time= 0.0s
```

Gambar 8. Proses *randomized search* pada *backpropagation*.

Model SARIMA

Pada model SARIMA dilakukan penentuan parameter terbaik menggunakan *randomized search*, berikut pada gambar 10.

```
2. Melakukan randomized search untuk parameter SARIMA...
Iterasi 1/20: SARIMA(1, 0, 1)x(1, 1, 1, 7) - MAE: 7.56
Iterasi 2/20: SARIMA(2, 1, 0)x(1, 1, 1, 7) - MAE: 7.19
Iterasi 3/20: SARIMA(2, 0, 2)x(0, 0, 1, 7) - MAE: 9.88
Iterasi 4/20: SARIMA(0, 1, 1)x(1, 1, 1, 7) - MAE: 7.22
Iterasi 5/20: SARIMA(2, 0, 0)x(0, 1, 0, 7) - MAE: 8.98
Iterasi 6/20: SARIMA(1, 1, 1)x(1, 1, 0, 7) - MAE: 30.74
Iterasi 7/20: SARIMA(1, 1, 0)x(0, 0, 0, 7) - MAE: 10.00
Iterasi 8/20: SARIMA(0, 1, 1)x(0, 0, 1, 7) - MAE: 9.95
Iterasi 9/20: SARIMA(0, 0, 2)x(1, 1, 0, 7) - MAE: 8.05
Iterasi 10/20: SARIMA(1, 0, 1)x(1, 0, 0, 7) - MAE: 9.55
Iterasi 11/20: SARIMA(0, 1, 0)x(1, 1, 1, 7) - MAE: 7.93
Iterasi 12/20: SARIMA(0, 0, 2)x(1, 0, 0, 7) - MAE: 14.69
Iterasi 13/20: SARIMA(2, 1, 1)x(0, 0, 1, 7) - MAE: 9.93
Iterasi 14/20: SARIMA(1, 0, 1)x(1, 0, 0, 7) - MAE: 9.55
Iterasi 15/20: SARIMA(0, 1, 2)x(0, 1, 0, 7) - MAE: 7.83
Iterasi 16/20: SARIMA(2, 1, 2)x(1, 1, 1, 7) - MAE: 7.61
Iterasi 17/20: SARIMA(2, 1, 1)x(1, 1, 0, 7) - MAE: 7.38
Iterasi 18/20: SARIMA(2, 1, 1)x(0, 1, 0, 7) - MAE: 8.16
Iterasi 19/20: SARIMA(1, 0, 1)x(1, 1, 0, 7) - MAE: 8.12
Iterasi 20/20: SARIMA(2, 0, 0)x(0, 0, 1, 7) - MAE: 35.57
```

Gambar 9. Proses *randomized search* pada SARIMA.

Evaluasi Model

Dari hasil evaluasi pada model *backpropagation* didapatkanlah model terbaik dengan nilai *error* terkecil yaitu MAE dan MAPE, berikut pada gambar 4.11.

Tanggal	Aktual	Prediksi	Selisih
2024-11-19	29.60	32.39	-2.79
2024-11-20	35.20	36.01	-0.81
2024-11-21	30.40	36.78	-6.38
2024-11-22	47.00	41.01	5.99
2024-11-23	55.80	55.95	-0.15

Gambar 10. Evaluasi model *backpropagation*.

Kemudian hasil yang di dapatkan dari penentuan parameter yaitu berikut pada gambar 12.

```

Parameter terbaik:
{'activation': 'relu', 'alpha': np.float64(0.09747555188414593), 'batch_size': 128, 'early_stopping':
 True, 'hidden_layer_sizes': (10,), 'learning_rate_init': np.float64(0.03924619912671628), 'max_iter'
 : 1000, 'n_iter_no_change': 20, 'random_state': 42, 'solver': 'adam'}

Iterasi training: 103
Final loss: 0.0104

Tabel Evaluasi:
      Model MAE (kg) MAPE (%) Arsitektur Fungsi Aktivasi
Neural Network 7.18 19.62 (10,) relu

```

Gambar 11. Evaluasi parameter model backpropagation.

Dari evaluasi pada model SARIMA didapatkanlah model terbaik dengan nilai *error* terkecil yaitu MAE dan MAPE, berikut pada gambar 13.

Tanggal	Aktual	Prediksi	Selisih
680	NaN	34.316044	NaN
681 2024-11-12	23.4	37.033580	-13.633580
682 2024-11-13	35.0	38.518677	-3.518677
683 2024-11-14	35.0	41.802572	-6.802572
684 2024-11-15	42.0	62.469543	-20.469543
685 2024-11-16	58.2	54.101846	4.098154
686 2024-11-17	48.8	37.325698	11.474302
687 2024-11-18	28.2	35.082081	-6.882081
688 2024-11-19	29.6	36.812546	-7.212546
689 2024-11-20	35.2	36.851144	-1.651144

Gambar 12. Evaluasi model SARIMA.

Kemudian hasil yang didapatkan dari penentuan parameter yaitu berikut pada gambar 4.14.

```

SARIMAX Results
=====
Dep. Variable:      nasi_terjual_kg      No. Observations:      680
Model:              SARIMAX(2, 1, 0)x(1, 1, [1], 7)      Log Likelihood          -2477.432
Date:                Tue, 15 Jul 2025      AIC                     4964.863
Time:                16:35:35              BIC                     4987.414
Sample:              0                      HQIC                    4973.597
                    - 680
Covariance Type:    opg
=====
              coef      std err      z      P>|z|      [0.025      0.975]
-----
ar.L1          -0.5275      0.030     -17.651     0.000     -0.586     -0.469
ar.L2          -0.2330      0.033     -6.986     0.000     -0.298     -0.168
ar.S.L7         0.0911      0.038      2.389     0.017      0.016      0.166
ma.S.L7        -0.9999      3.372     -0.297     0.767     -7.608      5.609
sigma2         89.0561     299.083      0.298     0.766    -497.135     675.247
=====
Ljung-Box (L1) (Q):      2.51      Jarque-Bera (JB):      19.21
Prob(Q):                 0.11      Prob(JB):               0.00
Heteroskedasticity (H):  0.56      Skew:                   0.00
Prob(H) (two-sided):     0.00      Kurtosis:               3.83
=====

Warnings:
[1] Covariance matrix calculated using the outer product of gradients (complex-step).

Tabel Evaluasi:
      Model Parameter MAE MAPE (%)
SARIMA (2, 1, 0)x(1, 1, 1, 7) 7.24 17.35

```

Gambar 13. Evaluasi parameter model SARIMA.

Dari percobaan pemilihan arsitektur terbaik dengan mengevaluasi hasil pengujian dan pelatihan inisialisasi parameter di dapatkan arsitektur terbaik *backpropagation* yaitu 1 *hidden layer* 10 *neuron* dengan nilai *error* MAE 7.18 dan MAPE 19.62%. Kemudian hasil pengujian dan pelatihan inisialisasi parameter di dapatkan arsitektur terbaik pada model SARIMA yaitu (2,1,0)x(1,1,1,7) dengan nilai *error* MAE 7.24 dan MAPE 17.35%.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil membandingkan algoritma *backpropagation* dan SARIMA pada data penjualan nasi yang berbentuk *time series* dari tahun 2023 Januari hingga 2025 April dengan mengukur nilai MAE dan MAPE. Setelah dilakukan proses *training* dan *testing*, hasil yang diperoleh adalah algoritma SARIMA memiliki performa terbaik dibandingkan *backpropagation* dalam memprediksi permintaan nasi pada restoran Grillme Pontianak, dibuktikan dengan nilai uji coba lebih kecil *backpropagation* yaitu MAE 7.18 dan MAPE 19.62% dengan SARIMA yaitu MAE 7.24 dan MAPE 17.35%, sehingga dengan prediksi SARIMA dapat membantu dalam peramalan permintaan nasi untuk restoran Grillme Pontianak.

DAFTAR REFERENSI

- Amanda, M. F., Syafar, M., Wulandari, J., Shavira, N., Aulia, H. M., Syahfitri, D., & Dalimunthe, D. Y. (2024). Perbandingan metode SARIMA dan exponential smoothing dalam memprediksi curah hujan di Kabupaten Bangka Tengah. *Fraction: Jurnal Teori Dan Terapan Matematika*, 4(2), 41–48. <https://doi.org/10.33019/fraction.v4i2.64>
- Dabral, P. P., & Murry, M. Z. (2017). Modelling and forecasting of rainfall time series using SARIMA. *Environmental Processes*, 4(2), 399–419. <https://doi.org/10.1007/s40710-017-0226-y>
- Fitriyanti, F. (2023). Aplikasi jaringan syaraf tiruan backpropagation dalam prediksi curah hujan bulanan di Kabupaten Wajo Sulawesi Selatan. *JPF (Jurnal Pendidikan Fisika) Universitas Islam Negeri Alauddin Makassar*, 11(1), 44–55. <https://doi.org/10.24252/jpf.v11i1.33142>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Han, J., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques* (3rd ed.). Morgan Kaufmann Publishers. http://www.amazon.de/Data-Mining-Concepts-Techniques-Management/dp/0123814790/ref=tmm_hrd_title_0?ie=UTF8&qid=1366039033&sr=1-1
- Huang, D., & Wu, Z. (2017). Forecasting outpatient visits using empirical mode decomposition coupled with back-propagation artificial neural networks optimized by particle swarm optimization. *PLOS ONE*, 12(2), e0172539. <https://doi.org/10.1371/journal.pone.0172539>

- Iqbal Ulumando, M. (2022). Prediksi hasil produksi tanaman kopi di wilayah NTT dengan menggunakan backpropagation. *Jurnal Agroteknologi Pertanian & Publikasi Riset Ilmiah*, 4(2), 28–45. <https://doi.org/10.55542/jappri.v4i2.391>
- Lestari, Y. D. (2017). Jaringan syaraf tiruan untuk prediksi penjualan jamur menggunakan algoritma backpropagation. *Jurnal ISD*, 2(1), 2477–2863.
- Marthasari, G. I., Astiti, S. A., & Azhar, Y. (2021). Prediksi data time-series menggunakan jaringan syaraf tiruan algoritma backpropagation pada kasus prediksi permintaan beras. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(3), 187–193. <https://doi.org/10.30591/jpit.v6i3.2627>
- Mufinnun, N. F., Rahman, H., & Jauhari, M. N. (2022). Implementasi backpropagation neural network pada prediksi jumlah penjualan Toyota Avanza di Indonesia. *Jurnal Riset Mahasiswa Matematika*, 1(6), 288–297. <https://doi.org/10.18860/jrmm.v1i6.14594>
- Nurmahaludin, N. (2017). Analisis perbandingan metode jaringan syaraf tiruan dan regresi linear berganda pada prakiraan cuaca. *INTEKNA Jurnal Informasi Teknik Dan Niaga*, 14(2). <https://ejurnal.poliban.ac.id/index.php/intekna/article/view/389>
- Reid Turner, C., Fuggetta, A., Lavazza, L., & Wolf, A. L. (1999). A conceptual basis for feature engineering. *Journal of Systems and Software*, 49(1), 3–15. [https://doi.org/10.1016/S0164-1212\(99\)00062-X](https://doi.org/10.1016/S0164-1212(99)00062-X)
- Sunariadi, N. M., Intan, P. K., Novitasari, D. C. R., & Hariningsih, Y. (2022). Prediksi produksi bawang merah di Kabupaten Nganjuk dengan metode seasonal ARIMA (SARIMA). *Transformasi: Jurnal Pendidikan Matematika Dan Matematika*, 6(1), 49–60. <https://doi.org/10.36526/tr.v6i1.1672>
- Tokan, L. F., & Hermawan, A. (2023). Implementasi model SARIMA untuk memprediksi produksi minyak kelapa sawit. *JURNAL FASILKOM*, 13(3), 456–463. <https://doi.org/10.37859/jf.v13i3.6033>
- Yulis, N., Anhar, Muh. A., & Rombe, A. S. (2025). Analisis perbandingan peramalan penggunaan bahan baku menggunakan metode weighted moving average (WMA) dan evaluasi dengan mean absolute error (MAE). *SISITI: Seminar Ilmiah Sistem Informasi Dan Teknologi Informasi*, 14(1), 57–64. <https://doi.org/10.36774/sisiti.v14i1.1675>