



Peramalan Volume Sampah di Kota Samarinda Menggunakan Metode *Feedforward Neural Network*

Fredicus Van Becum^a, Meiliyani Siringoringo^{b}, Siti Mahmuda^c, Sri Wahyuningsih^b, Rito Goejantoro^c*

^a. Program Studi Statistika, Universitas Mulawarman, Indonesia.

^b. Laboratorium Statistika Ekonomi dan Bisnis, FMIPA, Universitas Mulawarman, Indonesia.

^c. Laboratorium Statistika Komputasi, FMIPA, Universitas Mulawarman, Indonesia.

*Corresponding author: meiliyani.siringoringo@gmail.com

ABSTRACT

Population growth in various major cities in Indonesia has triggered an increase in the volume of waste produced, one of which is Samarinda as the capital of East Kalimantan Province. According to data from the Central Statistics Agency (BPS), the population growth rate in Samarinda City is 0.41%. This condition indicates that waste management in Samarinda City still faces quite serious challenges, so accurate forecasting efforts are needed to support future waste management planning. One forecasting method that can be used is the Feed Forward Neural Network (FFNN) method. The FFNN method is a network that is interconnected between one point and another that flows forward without any feedback. The algorithm that can be used in artificial neural network forecasting is the backpropagation algorithm, where this algorithm works by optimizing weights and biases to minimize errors. This study aims to forecast the volume of waste in Samarinda City using the best FFNN architecture. The results show that the best FFNN architecture used is 5 neurons in the hidden layer with a proportion of training and testing data of 80:20. The architecture produced a MAPE of 1.8506% on the training data and a RMSE of 1,280.23, and a MAPE of 3.1823% on the testing data and a RMSE of 2,139.48. The forecasting results for the period July 2024 to June 2025 show an increasing trend in waste volume, with the highest peak in April 2025 (56,141.13 m³) and the lowest point in May 2025 (54,432.84 m³). This increasing trend needs to be a serious concern for the Samarinda City Government, especially in terms of the adequacy of the transportation fleet, the capacity of the final disposal site, and the community-based waste management program.

Keywords: *Backpropagation, Feedforward Neural Network, Forecasting, Waste Volume*

ABSTRAK

Pertumbuhan penduduk di berbagai kota besar di Indonesia memicu peningkatan volume sampah yang dihasilkan, salah satunya Samarinda sebagai Ibu Kota Provinsi Kalimantan Timur. Menurut data Badan Pusat Statistik (BPS) laju pertumbuhan penduduk di Kota Samarinda sebesar 0,41%. Kondisi ini menunjukkan bahwa pengelolaan sampah di Kota Samarinda masih menghadapi tantangan yang cukup serius, sehingga diperlukan upaya peramalan yang akurat untuk mendukung perencanaan pengelolaan sampah ke depan. Salah satu metode peramalan yang dapat digunakan yaitu metode *Feed Forward Neural Network* (FFNN). Metode FFNN merupakan jaringan yang saling terhubung antara satu titik dengan titik lainnya yang mengalir maju tanpa adanya umpan balik. Algoritma yang dapat digunakan dalam peramalan jaringan saraf tiruan adalah algoritma *backpropagation*, dimana algoritma



ini bekerja dengan mengoptimalkan bobot dan bias untuk meminimumkan *error*. Penelitian ini bertujuan untuk meramalkan volume sampah Kota Samarinda menggunakan arsitektur FFNN terbaik. Hasil penelitian menunjukkan arsitektur FFNN terbaik yang digunakan adalah sebanyak 5 *neuron* pada lapisan tersembunyi dengan proporsi data *training* dan *testing* sebesar 80:20. Arsitektur tersebut menghasilkan MAPE pada data *training* sebesar 1,8506% dan RMSE sebesar 1.280,23, serta MAPE pada data *testing* sebesar 3,1823% dan RMSE sebesar 2.139,48. Hasil peramalan untuk periode Juli 2024 hingga Juni 2025 menunjukkan tren volume sampah yang cenderung meningkat, dengan puncak tertinggi pada April 2025 (56.141,13 m³) dan titik terendah pada Mei 2025 (54.432,84 m³). Tren kenaikan ini perlu menjadi perhatian serius bagi Pemerintah Kota Samarinda, khususnya dalam hal kecukupan armada pengangkutan, kapasitas tempat pembuangan akhir, dan program pengelolaan sampah berbasis masyarakat.

Kata kunci: *Backpropagation*, *Feedforward Neural Network*, Peramalan, Volume Sampah.

Diterima: 21-04-2026; Disetujui: 30-06-2026;

Doi: <https://doi.org/10.29303/ijasds.v3i1.10026>

1. Pendahuluan

Pertumbuhan penduduk Indonesia yang meningkat setiap tahunnya diberbagai kota besar di Indonesia berdampak langsung pada meningkatnya volume sampah yang dihasilkan setiap harinya. Kota Samarinda sebagai ibu kota Provinsi Kalimantan Timur mencatat laju pertumbuhan penduduk sebesar 0,41% pada tahun 2022, yang turut mendorong peningkatan konsumsi dan produksi sampah masyarakat. Berdasarkan data Dinas Lingkungan Hidup Kota Samarinda, volume sampah harian yang terangkut mencapai 2.257 m³, dengan total sampah terangkut sebesar 660.514 m³ dan sampah tidak terangkut sebesar 163.653 m³ pada tahun yang sama (Badan Pusat Statistik, 2023). Kondisi ini menunjukkan bahwa pengelolaan sampah di Kota Samarinda masih menghadapi tantangan yang cukup serius, sehingga diperlukan upaya peramalan yang akurat untuk mendukung perencanaan pengelolaan sampah ke depan. Peramalan diartikan sebagai suatu perkiraan dimasa depan dari beberapa peristiwa atau kejadian yang tercatat dalam suatu runtun waktu (Montgomery, Jennings & Kulahci, 2011). Salah satu metode peramalan runtun waktu yang berkembang adalah jaringan saraf tiruan atau yang dikenal dengan *neural network* (NN). *Neural network* memiliki kemampuan untuk mempelajari dan mengadaptasi situasi baru dengan mengingat pola data masa lalu bahkan ketika terjadi *noise* pada data (Yuliandar, Warsito & Yasin, 2012).

Jaringan saraf tiruan merupakan sistem komputasi arsitektur dan operasi yang bentuknya mengikuti sistem sel saraf biologi di dalam otak (Kristanto, 2004). Salah satu jenis jaringan saraf tiruan yang digunakan untuk peramalan adalah jaringan umpan maju atau *feedforward neural network* (FFNN). *Feedforward neural network* merupakan suatu jaringan yang menghubungkan *neuron-neuron* secara terstruktur dari lapisan *input* ke lapisan *output*, sehingga semua hubungan dapat terjadi antara satu titik dengan titik lainnya yang mengalir maju tanpa adanya umpan balik, secara lebih jelas dapat dikatakan jaringan tersebut mempunyai *neuron-neuron* yang hanya mempunyai satu jalur hubungan dengan *neuron* lainnya (Adiwana & Kartini, 2020). Salah satu algoritma yang dikenal dalam jaringan syaraf tiruan adalah algoritma *backpropagation*. Algoritma *backpropagation* merupakan algoritma pembelajaran terawasi dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyinya (*hidden layer*) (Fitriani, Ispriyanti & Prahutama, 2015). Keunggulan FFNN dibandingkan dengan metode runtun waktu lainnya terletak pada kemampuan model jaringan ini dalam mempelajari pola data non linier yang umumnya terdapat pada data sampah yang cenderung mengalami perubahan yang cukup besar berdasarkan peningkatan jumlah penduduk yang bermigrasi dari suatu wilayah ke wilayah lainnya.

Terdapat beberapa penelitian terdahulu yang mengkaji tentang metode peramalan FFNN, di antaranya adalah Aljaaf, Mohsin, Al-Jumeily, dan Alloghani (2021) yang meramalkan perkiraan wabah COVID-19, serta membandingkannya dengan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Smoothing State Space* (ETS) pada data harian Kasus COVID-19, dengan periode pengambilan data 24 Februari hingga Agustus 2020. Pola data pada penelitian ini, menunjukan data harian pada periode Februari hingga awal Juni tidak menunjukkan pergerakan yang yang besar dan selanjutnya adanya pergerakan tren meningkat kasus harian COVID-19 di Irak pada periode Juni hingga Agustus. Hasil penelitian menunjukkan model jaringan saraf FFNN memberikan hasil akurasi peramalan yang lebih baik dengan hasil akurasi peramalan RMSE (*Root Mean Square Error*), MAE

(*Mean Absolute Error*), dan MAPE (*Mean Absolute Percentage Error*) masing-masing adalah 32,33%, 22,21% dan 12,4%. Penelitian ini menjelaskan jika metode FFNN lebih baik dalam memodelkan hubungan non linier pada data COVID-19 yang dipengaruhi oleh beberapa faktor eksternal yang menjadi penyebab tinggi rendahnya jumlah kasus harian, seperti jumlah kunjungan dari luar negeri ke dalam negeri, aturan *lockdown* dalam negeri, atau aktivitas penduduk dalam satu hari yang menjadi penyebab langsung meningkat dan penurunan drastis jumlah kasus harian.

Saputri dan Oktaviana (2023) yang melakukan penelitian terhadap data finansial, di mana penelitian ini melakukan peramalan dengan membandingkan metode FFNN dan ARIMA terhadap data piutang pembiayaan bulanan yang diambil dari periode November 2012 hingga Juni 2021. Pola data yang dihasilkan menunjukkan adanya tren positif hingga awal tahun 2020 dan penurunan tren negatif sejak Maret 2020 hingga Juni 2021 yang disebabkan oleh wabah COVID -19. Hasil penelitian ini, menunjukkan model jaringan saraf FFNN memberikan hasil akurasi yang lebih baik dengan MAPE sebesar 0,37% dibandingkan ARIMA, serta dengan keunggulannya yang tidak memerlukan asumsi khusus dalam pembentukan modelnya, sehingga dianggap lebih fleksibel dibandingkan metode ARIMA. Selanjutnya penelitian yang dilakukan oleh Aminy dan Walid (2024) yang melakukan perbandingan antara metode ARIMA dan FFNN terhadap perkembangan COVID-19 di Indonesia. Pola data pada penelitian ini menunjukkan kasus harian COVID-19 memiliki tren naik positif, terutama pada rentang Juli hingga Oktober yang memiliki peningkatan yang signifikan. Hasil penelitian ini, menunjukkan peramalan menggunakan model FFNN memberikan hasil peramalan yang lebih baik dibandingkan model ARIMA, dengan nilai evaluasi akurasi peramalan menggunakan RMSE sebesar 367,448, MAE sebesar 287,220, dan MAPE sebesar 7,23%.

Penelitian-penelitian terdahulu yang telah disebutkan menerapkan FFNN pada data kesehatan yaitu terkait wabah COVID-19 dan finansial yaitu terakut piutang, oleh karena itu pada penelitian ini FFNN akan diterapkan pada data sampah. Tujuan dari penelitian ini adalah untuk mendapatkan nilai peramalan volume sampah Kota Samarinda periode bulan Juli 2024 sampai dengan Juni 2025 menggunakan arsitektur FFNN terbaik berdasarkan nilai MAPE dan RMSE terkecil.

2. Metode

Data penelitian ini adalah volume sampah bulanan Kota Samarinda yang terakut dari Januari 2019 sampai dengan Juni 2024. Data tersebut diperoleh dari Dinas Lingkungan Hidup Kota Samarinda. Analisis data dilakukan dengan bantuan *software R*. Tahapan analisis data menggunakan *Feedforward Neural Network* adalah sebagai berikut:

1. Melakukan analisis statistika deskriptif untuk melihat gambaran umum data penelitian menggunakan grafik runtun waktu.
2. Melakukan normalisasi data menggunakan persamaan dengan tujuan agar data berada pada rentang fungsi aktivasi yang digunakan. Pada penelitian ini fungsi aktivasi yang digunakan untuk lapisan *input* adalah fungsi sigmoid biner yang berada pada rentang 0 sampai 1 menggunakan persamaan (2.1) (Rachman, Cholissodin & Fauzi. 2018).

$$Z' = \frac{Z - \min}{\max - \min}(\text{newmax} - \text{newmin}) + \text{newmin}, \quad (2.1)$$

dengan Z merupakan data asli, \min merupakan nilai minimum data, \max merupakan nilai maksimum data, newmin adalah nilai minimum yang diinginkan, dan newmax adalah nilai maksimum yang diinginkan.

3. Membagi data menjadi dua bagian, yakni data *training* dan data *testing* di mana pembagian data bersifat subjektif dari peneliti, dengan persentase data *training* lebih besar dibandingkan data *testing*. Beberapa komposisi yang digunakan pada penelitian ini masing-masing 70:30, 80:20, dan 90:10 (Juliana, Hamidatun & Muslima. 2019).
4. Membentuk grafik fungsi otokorelasi atau fungsi autokorelasi parsial dari data *training* untuk menentukan banyaknya unit *input* awal. Penentuan variabel *input* dilihat berdasarkan *lag* yang menunjukkan nilai fungsi otokorelasi yang keluar dari batas interval kepercayaan. Hal tersebut

dilakukan karena fungsi otokorelasi atau fungsi otokorelasi parsial yang keluar dari batas interval kepercayaan menunjukkan adanya hubungan linier antara data pengamatan periode sebelum (Z_{t-k}) atau sesudahnya (Z_{t+k}) data pengamatan periode saat ini (Z_t) yang mana juga memiliki pengaruh terhadap data pengamatan saat ini sehingga diharapkan dapat meningkatkan kemampuan prediksi model arsitektur jaringan FFNN.

5. Membentuk arsitektur NN berupa jaringan multilapis dengan variasi *neuron* tersembunyi pada lapisan tersembunyi yaitu 1, 2, 3, 4 dan 5 *neuron*. Menurut Pasini (2015), beberapa aturan perlu diterapkan untuk menghindari *overfitting*, salah satunya aturan yang memungkinkan untuk menentukan berapa banyak *neuron* pada lapisan tersembunyi tanpa terjebak dalam kondisi *overfitting*, sehingga penelitian ini membatasi penggunaan *neuron* pada lapisan tersembunyi sebanyak 5 *neuron*.
6. Melakukan Peramalan menggunakan metode *feedforward neural network* dengan algoritma *backpropagation*. Pada penelitian ini, laju pembelajaran (*learning rate*) yang digunakan sebesar 0,01, iterasi sebesar 10.000 dan ambang batas *error* yang digunakan sebesar 0,05. Selanjutnya langkah-langkah peramalan adalah sebagai berikut:

a. Menetapkan bobot dan bias awal (Siang, 2009):

1. Mengatur semua bobot (v_{ab} (lama)) dengan bilangan acak interval (-0.5, 0.5).
2. Menghitung $\|v_{ab}\|$ dengan menggunakan persamaan (2.2)

$$\|v_{ab}\| = \sqrt{v_{1b}^2 + v_{2b}^2 + \dots + v_{hb}^2} \quad (2.2)$$

dengan h = jumlah unit masukan

3. Menghitung faktor skala, di mana faktor skala Nguyen Widrow didefinisikan pada persamaan (2.3):

$$\beta = 0,7 \sqrt[p]{p}, \text{ dengan } p = \text{jumlah unit tersembunyi} \quad (2.3)$$

4. Penetapan bobot awal yang digunakan, disajikan pada persamaan (2.4):

$$v_{ab} = \frac{\beta v_{ab} (\text{lama})}{\|v_{ab}\|} \quad (2.4)$$

5. Penetapan bias awal yang digunakan merupakan bilangan acak antara $-\beta$ dan β .

b. Melakukan fase *feedforward* dengan langkah sebagai berikut (Fausset, 1994):

1. Setiap *neuron input* ($x_a, a = 1, 2, \dots, h$), menerima masing-masing sinyal *input* dan mengirimkan sinyal tersebut ke seluruh lapisan tersembunyi (*hidden layer*).
2. Setiap *neuron* tersembunyi ($y_b, b = 1, 2, \dots, p$) menjumlahkan sinyal *input* yang telah diberikan bobot menggunakan persamaan (2.5)

$$y_in_b = v_{0b} + \sum_{a=1}^h x_a v_{ab}, \quad (2.5)$$

lalu digunakan fungsi aktivasi sigmoid biner untuk menentukan sinyal *output* dari *neuron* tersembunyi menggunakan persamaan (2.6)

$$y_b = f_1(y_in_b) = \frac{1}{1 + \exp(-y_in_b)} \quad (2.6)$$

dan mengirimkan sinyal ini ke seluruh *neuron output*.

3. Setiap *neuron output* ($\hat{a}_c, c = 1, \dots, m$) menjumlahkan sinyal *output* dari *neuron* tersembunyi yang telah diberi bobot menggunakan persamaan (2.7)

$$\hat{a}_{in_c} = w_{0c} + \sum_{b=1}^p y_b w_{bc}, \quad (2.7)$$

dan menerapkan fungsi aktivasi linier untuk menentukan sinyal *output* dari *neuron output* menggunakan persamaan (2.8)

$$\hat{a}_c = f_2(\hat{a}_{in_c}) = \hat{a}_{in_c}. \quad (2.8)$$

- c. Melakukan fase *backpropagation* dengan langkah sebagai berikut (Fausset, 1994):

1. Setiap *neuron output* ($\hat{a}_c, c = 1, \dots, m$) menerima pola target yang berhubungan dengan pola *input* pembelajaran, kemudian menghitung *error term* dengan persamaan (2.9)

$$\delta_1 = (a_c - \hat{a}_c) f_2'(\hat{a}_{in_1}) = (a_1 - \hat{a}_1) \times (1) \quad (2.9)$$

lalu menghitung bobot koreksi untuk w_{bc} menggunakan persamaan (2.10)

$$\Delta w_{bc} = \alpha \delta_c y_b, \quad (2.10)$$

lalu menghitung bobot koreksi untuk w_{0c} menggunakan persamaan (2.11)

$$\Delta w_{0c} = \alpha \delta_c, \quad (2.11)$$

Kemudian mengirimkan δ_c ke seluruh lapisan *neuron* tersembunyi.

2. Setiap *neuron* tersembunyi ($y_b, b = 1, \dots, p$) menjumlahkan *error term* yang telah diberi bobot menggunakan persamaan (2.12)

$$\delta_{in_b} = \sum_{c=1}^m \delta_c w_{bc}, \quad (2.12)$$

lalu menghitung kembali *error term* dengan mengalikan δ_{in_b} dengan turunan dari fungsi aktivasi sigmoid biner menggunakan persamaan (2.13)

$$\delta_b = \delta_{in_b} f_1'(y_{in_b}) = f_1(y_{in_b}) [1 - f_1(y_{in_b})], \quad (2.13)$$

selanjutnya menghitung bobot koreksinya v_{ab} menggunakan persamaan (2.14)

$$\Delta v_{ab} = \alpha \delta_b x_a, \quad (2.14)$$

dan bobot koreksi untuk bias v_{0b} menggunakan persamaan (2.15)

$$\Delta v_{0b} = \alpha \delta_b. \quad (2.15)$$

3. Memperbarui bobot dan bias pada lapisan tersembunyi dan lapisan *output* menggunakan persamaan (2.16) dan (2.17):

$$v_{ab}(\text{baru}) = v_{ab}(\text{lama}) + \Delta v_{ab} \quad (2.16)$$

$$w_{bc}(\text{baru}) = w_{bc}(\text{lama}) + \Delta w_{bc}. \quad (2.17)$$

4. Pemeriksaan kondisi berhenti. Menurut Rachman, Cholissodin dan Fauzi (2018), memeriksa kondisi berhenti, apabila nilai *error* sudah lebih kecil dari nilai minimum *error* atau iterasi sudah mencapai maksimum maka proses pelatihan dihentikan.
5. Setelah memperoleh nilai bobot optimum dari pelatihan *backpropagation*, dapat dilakukan prediksi dan peramalan dengan cara menghitung *output* dari *neuron* lapisan *output*. Adapun persamaan yang digunakan dalam memperoleh hasil prediksi dan peramalan dituliskan pada persamaan (2.18).

$$\hat{Z}_t = w_{0c} + \sum_{b=1}^p \left(\frac{1}{1 + e^{-(v_{0b} + \sum_{a=1}^h x_a v_{ab})}} \right) w_{bc} \quad (2.18)$$

7. Melakukan prediksi untuk data *training* menggunakan persamaan (2.18) dan melakukan denormalisasi untuk melihat nilai yang sebenarnya menggunakan persamaan (2.19) berikut:

$$Z = \frac{Z' - \text{newmin}}{\text{newmax} - \text{newmin}} (\text{max} - \text{min}) + \text{min} \quad (2.19)$$

8. Menghitung akurasi MAPE dan RMSE data *training*. Menurut Makridakis, Wheelwright dan McGee (1999), MAPE dapat dihitung menggunakan persamaan (2.20):

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% \quad (2.20)$$

Menurut Chang, Wang dan Liu (2007), penggunaan MAPE digunakan untuk mengevaluasi hasil peramalan. Kriteria MAPE ditunjukkan pada Tabel 1 berikut:

Tabel 1. Kriteria Nilai MAPE	
Nilai MAPE	Kriteria
MAPE <10%	Sangat Baik
10% ≤ MAPE <20%	Baik
20% ≤ MAPE ≤ 50%	Cukup
MAPE >50%	Buruk

Perhitungan RMSE dituliskan menggunakan persamaan (2.21) (Syaharuddin, Pramita, Nusantara, & Subanji. 2019):

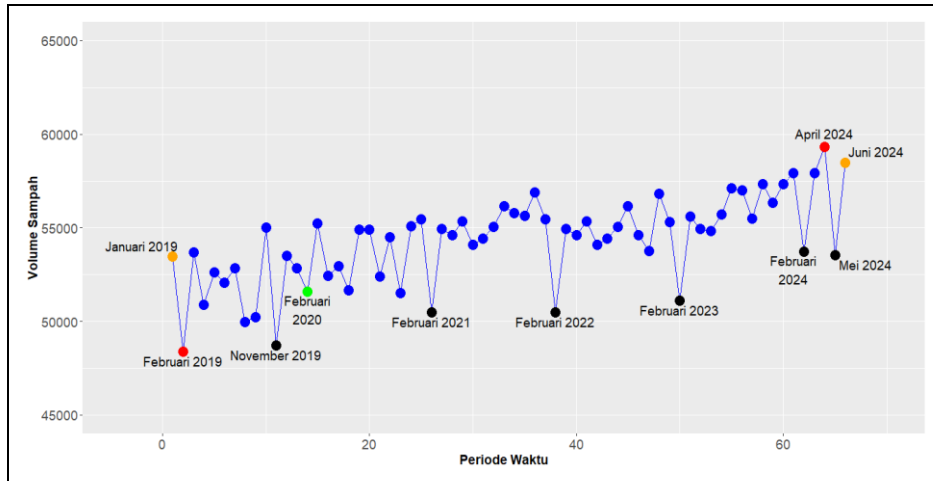
$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}} \quad (2.21)$$

9. Menghitung peramalan menggunakan data *testing* pada setiap *neuron* untuk semua proporsi menggunakan persamaan (2.18) dan melakukan denormalisasi data *testing* menggunakan persamaan (2.19), serta menghitung akurasi peramalan MAPE dan RMSE menggunakan persamaan (2.20) dan (2.21).
10. Melakukan peramalan untuk periode ke depan dengan menggunakan arsitektur NN terbaik yang dilihat berdasarkan hasil akurasi MAPE dan RMSE terkecil menggunakan persamaan (2.18).
11. Membuat grafik perbandingan runtun waktu antara data aktual dengan hasil peramalan.

3. Hasil dan Pembahasan

3.1. Statistika Deskriptif

Data yang digunakan adalah volume sampah bulanan Kota Samarinda yang terangkut periode Januari 2019 sampai dengan Juni 2024 atau sebanyak 66 periode data. Data volume sampah tersebut, digambarkan dengan menggunakan grafik runtun waktu yang ditunjukkan pada Gambar 1.



Gambar 1. Grafik runtun waktu volume sampah bulanan Kota Samarinda yang terangkut periode Januari 2018 sampai dengan Juni 2024

Berdasarkan Gambar 1, sumbu horizontal merupakan periode waktu (bulan) dan sumbu vertikal merupakan volume sampah Kota Samarinda (m^3). Secara umum, dapat dilihat bahwa grafik runtun waktu volume sampah Kota Samarinda periode bulan Januari 2019 sampai dengan Juni 2024 atau $t = 1, 2, \dots, 66$, menunjukkan adanya fluktuasi dari bulan ke bulan. Fluktuasi tersebut dapat disebabkan perbedaan jumlah hari dalam setiap bulan, aktivitas masyarakat, serta faktor faktor tertentu seperti hari libur nasional, cuti bersama, dan kegiatan gotong royong yang dapat mempengaruhi jumlah sampah yang terkumpul.

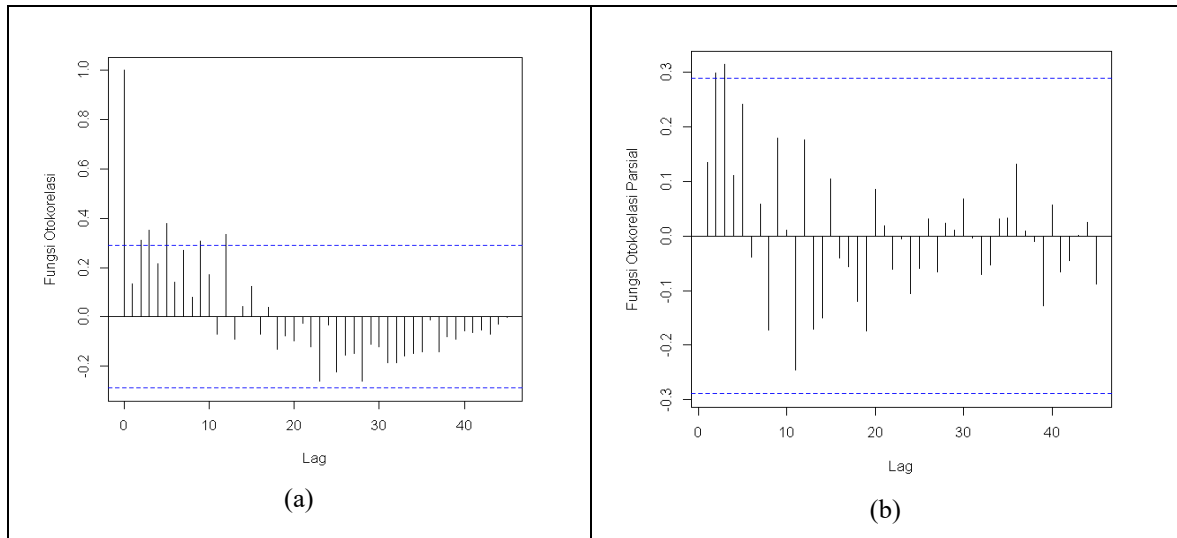
Selain menunjukkan fluktuasi, data juga menunjukkan adanya pola musiman (pola berulang) yang ditandai dengan penurunan volume sampah yang relatif konsisten pada bulan februari pada setiap tahunnya. Kondisi ini disebabkan jumlah hari yang lebih sedikit dibandingkan bulan lainnya, yaitu 28 atau 29 hari sehingga volume sampah yang dihasilkan dan terangkut cenderung lebih rendah, dimana penurunan terendah pada keseluruhan periode pengamatan, tercatat pada bulan Februari 2019.

Selanjutnya, secara keseluruhan grafik menunjukkan kecenderungan tren meningkat dari tahun ke tahun. Hal ini mengindikasikan adanya peningkatan volume sampah yang dihasilkan dikota samarinda selama periode pengamatan. Tren peningkatan tersebut, dapat dikaitkan pada pertumbuhan jumlah penduduk, peningkatan aktivitas ekonomi, dan perkembangan kawasan permukiman yang berkontribusi terhadap bertambahnya volume sampah. Volume sampah tertinggi pada periode pengamatan ini tercatat pada bulan April 2026, yang menunjukkan peningkatan yang cukup signifikan dibandingkan periode periode sebelumnya. Sehingga, dengan demikian data volume sampah memiliki kombinasi pola tren dan musiman. Karakteristik ini menunjukkan bahwa metode peramalan perlu mampu menangkap baik komponen tren dan musiman yang terdapat pada data volume sampah.

3.2. Peramalan *Feedforward Neural Network* Menggunakan Algoritma *Backpropagation*

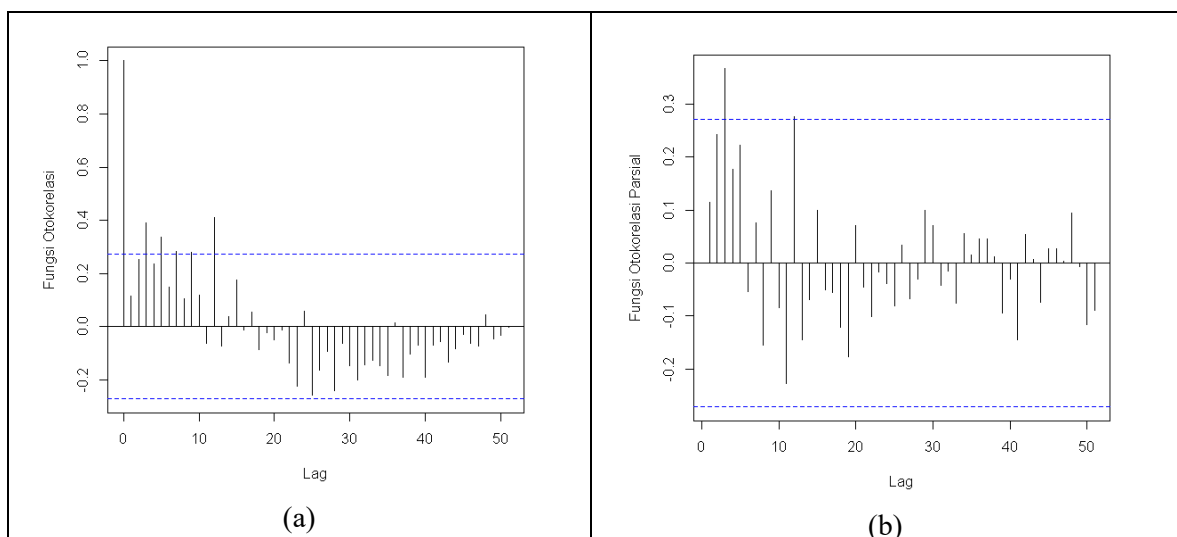
Tahapan awal dalam melakukan peramalan *feedforward neural network* (FFNN) dengan algoritma *backpropagation*, diawali dengan menormalisasi data berdasarkan persamaan (2.1) dan melakukan pembagian data *training* dan *testing* dengan komposisi pembagian data 70:30, 80:20 dan 90:10. Pada pembagian data dengan proporsi 70:30, periode data *training* adalah dari Januari 2019 hingga Oktober 2022 (46 data), sedangkan periode data *testing* adalah November 2022 hingga Juni 2024 (20 data). Pada pembagian data dengan proporsi 80:20, periode data *training* adalah dari Januari 2019 hingga April 2023 (52 data), sedangkan periode data *testing* adalah Mei 2023 hingga Juni 2024 (14 data). Pembagian

data dengan proporsi 90:10 menghasilkan periode data *training* yaitu dari Januari 2019 hingga November 2023 (59 data) dan periode data *testing* yaitu Desember 2023 hingga Juni 2024 (7 data). Proses ini kemudian dilanjutkan dengan menentukan *input* dan *output* target sebagai awal pembentukan arsitektur jaringan. Penentuan *input* jaringan dan *output* target dilakukan dengan melihat *lag* yang menunjukkan nilai fungsi otokorelasi yang keluar dari batas interval pada grafik fungsi otokorelasi dan fungsi autokorelasi parsial dengan menggunakan data *training*. Adapun grafik fungsi otokorelasi dan otokorelasi parsial dapat dilihat pada Gambar 2.



Gambar 2. Grafik fungsi otokorelasi dan fungsi otokorelasi parsial proporsi data 70:30

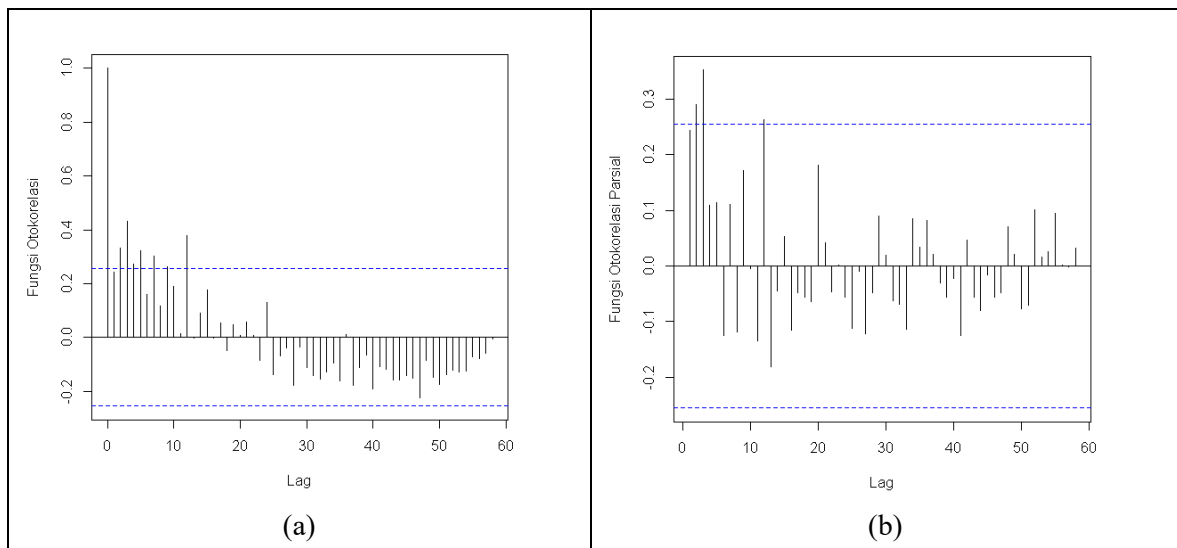
Berdasarkan Gambar 2(a), dapat dilihat bahwa terdapat lima nilai otokorelasi yang keluar dari batas interval kepercayaan pada grafik fungsi otokorelasi, yaitu pada *lag* ke-2, *lag* ke-3, *lag* ke-5, *lag* ke-9, dan *lag* ke-12 sehingga diduga Z_t yang merupakan *output* target dan kemudian disimbolkan Y_{target} pada pembentukan arsitektur FFNN, dipengaruhi oleh Z_{t-2} , Z_{t-3} , Z_{t-5} , Z_{t-9} , dan Z_{t-12} yang kemudian akan disimbolkan dengan X . Pada grafik fungsi orokorelasi parsial (Gambar 2(b)), terdapat dua nilai yang keluar dari batas interval interval, yaitu pada *lag* ke-2 dan *lag* ke-3 yang menunjukkan bahwa *output* target dipengaruhi oleh Z_{t-2} dan Z_{t-3} .



Gambar 3. Grafik fungsi otokorelasi dan fungsi otokorelasi parsial proporsi 80:20

Gambar 3(a) menunjukkan bahwa terdapat lima nilai otokorelasi yang keluar dari batas interval, yaitu pada *lag* ke-3, *lag* ke-5, *lag* ke-7, *lag* ke-9, dan *lag* ke-12 sehingga diduga yang memengaruhi *output* target adalah Z_{t-3} , Z_{t-5} , Z_{t-7} , dan Z_{t-9} . Grafik fungsi otokorelasi parsial pada Gambar 3(b) menunjukkan terdapat dua nilai otokorelasi parsial yang keluar dari batas interval kepercayaan, yaitu

pada *lag* ke-3 dan *lag* ke-12 sehingga Z_{t-3} dan Z_{t-12} diduga memengaruhi *output* target.



Gambar 4. Grafik fungsi otokorelasi dan fungsi otokorelasi parsial proporsi 90:10

Pada Gambar 4(a), dapat dilihat bahwa terdapat tujuh nilai otokorelasi yang keluar dari batas interval kepercayaan, yaitu pada *lag* ke-2, *lag* ke-3, *lag* ke-4, *lag* ke-5, *lag* ke-7, *lag* ke-9, dan *lag* ke-12 sehingga diduga yang memengaruhi *output* target adalah Z_{t-2} , Z_{t-3} , Z_{t-4} , Z_{t-5} , Z_{t-7} , Z_{t-9} , dan Z_{t-12} . Pada Gambar 4(b), terdapat tiga nilai otokorelasi parsial yang keluar dari batas interval kepercayaan pada grafik fungsi otokorelasi parsial, yaitu pada *lag* ke-2, *lag* ke-3 dan *lag* ke-12 sehingga Z_{t-2} , Z_{t-3} , dan Z_{t-12} yang diduga memengaruhi *output* target.

Untuk menentukan variabel *input* yang optimal bagi jaringan *feedforward neural network*, dilakukan pembentukan arsitektur jaringan dengan menggunakan seluruh *lag* yang keluar dari batas interval pada grafik fungsi autokorelasi dan fungsi autokorelasi parsial. Hasil dari pembentukan jaringan ini kemudian akan dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE). Selanjutnya, *input* dan *output* target untuk kedua grafik disajikan pada Tabel 2.

Tabel 2. Rentang waktu untuk data yang digunakan dalam memodelkan jaringan

Proporsi	Input Grafik Fungsi Autokorelasi		Input Grafik Fungsi Autokorelasi Parsial	
	Variabel	Waktu	Variabel	Waktu
70:30	Y_{target}	Januari 2020 - Oktober 2022	Y_{target}	April 2019 - Oktober 2022
	X_{t-2}	November 2019 - Agustus 2022	X_{t-2}	Februari 2019 - Agustus 2022
	X_{t-3}	Oktober 2019 - Juli 2022	X_{t-3}	Januari 2019 - Juli 2022
	X_{t-5}	Agustus 2019 - Mei 2022		
	X_{t-9}	April 2019 - Januari 2022		
	X_{t-12}	Januari 2019 - Oktober 2021		
80:20	Y_{target}	Januari 2020 - April 2023	Y_{target}	Januari 2020 - April 2023
	X_{t-3}	Oktober 2019 - Januari 2023	X_{t-3}	Oktober 2019 - Januari 2023
	X_{t-5}	Agustus 2019 - November 2022	X_{t-12}	Januari 2019 - April 2022
	X_{t-7}	Juni 2019 - September 2022		
	X_{t-9}	April 2019 - Juli 2022		
	X_{t-12}	Januari 2019 - April 2022		
90:10	Y_{target}	Januari 2020 - November 2023	Y_{target}	Januari 2020 - November 2023
	X_{t-2}	November 2019 - September 2023	X_{t-2}	November 2019 - September 2023
	X_{t-3}	Oktober 2019 - Agustus 2023	X_{t-3}	Oktober 2019 - Agustus 2023
	X_{t-4}	September 2019 - Juli 2023	X_{t-12}	Januari 2019 - November 2022
	X_{t-5}	Agustus 2019 - Juni 2023		
	X_{t-7}	Juni 2019 - April 2023		

Proporsi	Input Grafik Fungsi Autokorelasi		Input Grafik Fungsi Autokorelasi Parsial	
	Variabel	Waktu	Variabel	Waktu
	X_{t-9}	April 2019 - Februari 2023		
	X_{t-12}	Januari 2019 – November 2022		

Berdasarkan Tabel 2, langkah selanjutnya dilakukan pemodelan arsitektur, yang dimulai dari menentukan bobot dan bias awal berdasarkan persamaan (2.2) sampai dengan persamaan (2.4). Kemudian melakukan peramalan FFNN dengan algoritma *backpropagation* berdasarkan persamaan (2.5) sampai dengan persamaan (2.15). Langkah selanjutnya adalah memperbarui bobot dan bias pada lapisan tersembunyi dan lapisan *output* berdasarkan persamaan (2.16) dan persamaan (2.17). Setelah diperoleh arsitektur jaringan yang optimal, kemudian akan dihitung MAPE menggunakan persamaan (2.20) dan RMSE menggunakan persamaan (2.21). Pemodelan arsitektur FFNN dilakukan dengan bantuan *software* R. Hasil dari MAPE dan RMSE untuk kedua grafik disajikan pada Tabel 3.

Tabel 3. Nilai akurasi MAPE dan RMSE untuk data *training* dan data *testing* pada masing-masing *input* jaringan

Proporsi Data	Neuron	Input Grafik Fungsi Autokorelasi				Input Grafik Fungsi Autokorelasi Parsial*			
		MAPE (%)		RMSE		MAPE (%)		RMSE	
		<i>training</i>	<i>testing</i>	<i>training</i>	<i>testing</i>	<i>training</i>	<i>testing</i>	<i>training</i>	<i>testing</i>
70:30	1	2,3916	3,8749	1.601,99	2.575,52	3,1135	4,3848	1.942,72	2.927,39
	2	2,5616	4,0671	1.701,73	2.718,79	3,1507	4,4712	1.949,4	2.976,22
	3	2,4639	3,9327	1.638,32	2.556,79	2,6620	3,7341	1.747,68	2.266,84
	4	2,3634	4,0048	1.596,45	2.764,78	2,5412	3,5187	1.711,73	2.222,14
	5	2,4691	4,0033	1.660,69	2.662,21	2,6912	3,7718	1.757,49	2.392,67
80:20	1	1,8008	3,3690	1.292,83	2.228,87	2,3738	4,2552	1.603,39	2.824,49
	2	2,5952	4,5459	1.736,85	3.002,13	1,8871	3,6250	1.273,49	2.429,57
	3	2,2972	3,9324	1.573,42	2.498,05	2,0438	3,4414	1.418,75	2.226,51
	4	1,8178	3,5630	1.260,18	2.386,20	1,8644	3,2263	1.281,49	2.172,71
	5	1,8854	3,2188	1.333,21	2.102,98	1,8506*	3,1823*	1.280,23*	2.139,48*
90:10	1	2,3903	4,8598	1.691,41	3.090,67	1,9514	3,5818	1.343,89	2.357,79
	2	1,8813	3,7524	1.307,37	2.352,97	1,9063	3,5367	1.310,19	2.363,53
	3	2,0545	4,1103	1.455,81	2.531,20	2,1262	3,8678	1.460,92	2.411,75
	4	1,9170	4,0400	1.401,76	2.501,09	1,9813	3,6825	1.361,24	2.380,81
	5	2,1732	4,4690	1.556,05	2.771,84	1,9172	3,4159	1.322,97	2.204,37

*Ket: Nilai *error* terkecil dan *input* terpilih

Berdasarkan Tabel 3, seluruh model menghasilkan nilai MAPE di bawah 10%, sehingga berdasarkan kriteria Tabel 1, semua model masuk dalam kategori "sangat baik". Hal tersebut menunjukkan FFNN bekerja sangat baik pada seluruh proporsi data, input jaringan, dan *neuron* yang digunakan. Karena seluruh model sudah memenuhi kriteria tersebut, pemilihan model terbaik tidak hanya mempertimbangkan nilai MAPE, tetapi juga nilai RMSE sebagai ukuran kesalahan absolut, serta kesederhanaan dan stabilitas model.

Model FFNN terbaik bekerja pada proporsi data *training* dan *testing* 80:20 dengan 5 *neuron* tersembunyi menggunakan input jaringan, yaitu model 2-5-1 (2 *neuron* input yaitu X_{t-3} dan X_{t-12} , 5 *neuron* tersembunyi, dan 1 *neuron* output). Struktur ini dipilih sebagai model optimal karena menghasilkan kombinasi MAPE dan RMSE terkecil sekaligus menunjukkan generalisasi yang baik, yakni perbedaan antara performa pada data *training* dan *testing* yang tidak terlalu besar. Model terbaik ini menghasilkan nilai MAPE data *training* sebesar 1,8506% dan data *testing* sebesar 3,1823%, serta nilai RMSE data *training* sebesar 1.280,23 dan data *testing* sebesar 2.139,48.

Bobot dan bias awal yang digunakan pada model FFNN terbaik (5 *neuron* tersembunyi, proporsi 80:20) adalah sebagai berikut:

$$v = \begin{bmatrix} v_{01} & v_{02} & v_{03} & v_{04} & v_{05} \\ v_{11} & v_{12} & v_{13} & v_{14} & v_{15} \\ v_{21} & v_{22} & v_{23} & v_{24} & v_{25} \end{bmatrix} = \begin{bmatrix} -0,82675 & -0,47846 & 1,26766 & 0,41416 & 0,54573 \\ -0,46873 & 1,05709 & 1,42007 & 1,23731 & -1,46346 \\ -1,49342 & -1,15435 & 0,65832 & -0,95868 & -0,55523 \end{bmatrix}$$

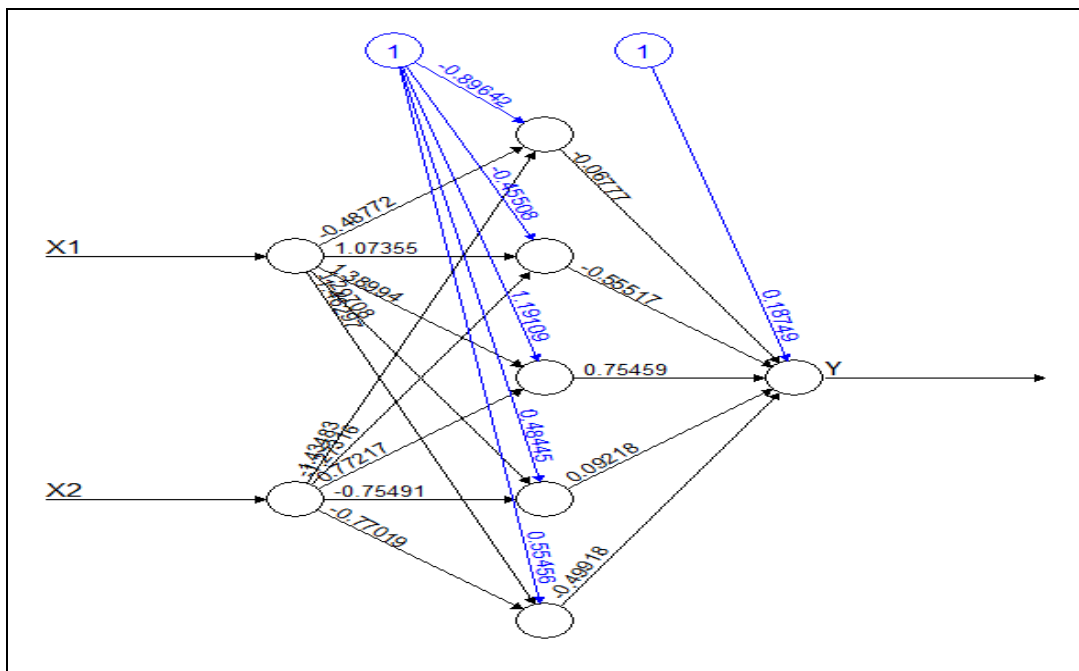
$$w = \begin{bmatrix} w_{01} \\ w_{11} \\ w_{21} \\ w_{31} \\ w_{41} \\ w_{51} \end{bmatrix} = \begin{bmatrix} -0,32827 \\ 0,47005 \\ 0,06048 \\ 0,05531 \\ 0,24324 \\ -0,12987 \end{bmatrix}$$

Bobot dan bias optimum dari FFNN 5 neuron tersembunyi proporsi 80:20 diperoleh pada iterasi ke-901 dengan error sebesar 0,04997. Adapun bobot dan bias optimum yang diperoleh adalah sebagai berikut:

$$v = \begin{bmatrix} v_{01} & v_{02} & v_{03} & v_{04} & v_{05} \\ v_{11} & v_{12} & v_{13} & v_{14} & v_{15} \\ v_{21} & v_{22} & v_{23} & v_{24} & v_{25} \end{bmatrix} = \begin{bmatrix} -0,89642 & -0,45508 & 1,19109 & 0,48445 & 0,55456 \\ -0,48772 & 1,07355 & 1,38994 & 1,29708 & -1,46297 \\ -1,43483 & -1,27316 & 0,77217 & -0,75491 & -0,77019 \end{bmatrix}$$

$$w = \begin{bmatrix} w_{01} \\ w_{11} \\ w_{21} \\ w_{31} \\ w_{41} \\ w_{51} \end{bmatrix} = \begin{bmatrix} 0,18749 \\ -0,06777 \\ -0,55517 \\ 0,75459 \\ 0,09218 \\ -0,49917 \end{bmatrix}$$

Adapun arsitektur jaringan FFNN untuk 5 neuron tersembunyi disajikan pada Gambar 5.



Gambar 5. Arsitektur FFNN *backpropagation* 5 neuron tersembunyi proporsi *training* dan *testing* 80:20

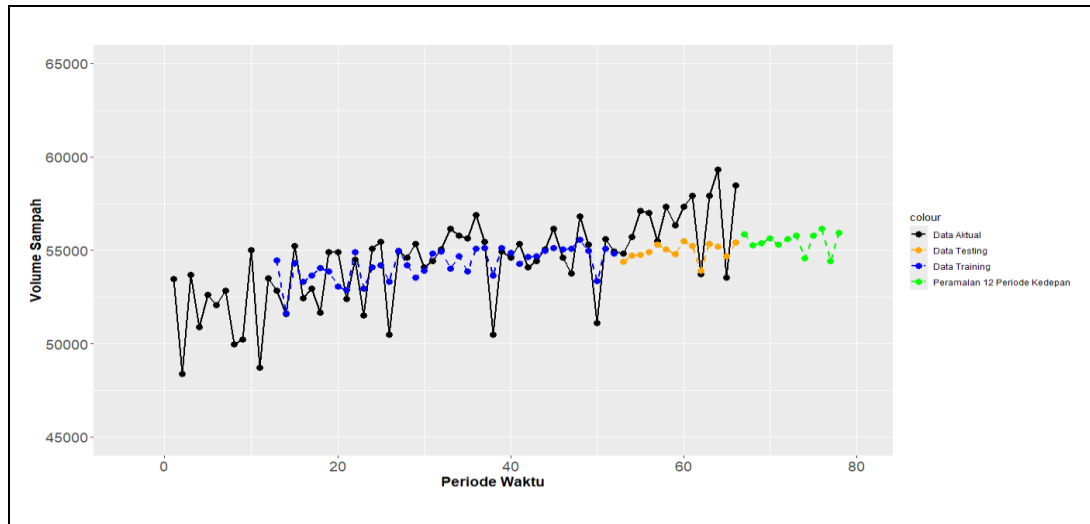
Setelah melakukan proses tahapan *training* dan *testing* dan diperoleh model arsitektur FFNN terbaik dengan bobot dan bias optimal, maka selanjutnya dilakukan peramalan jumlah volume sampah di Kota Samarinda untuk 12 periode ke depan. Hasil peramalan disajikan pada Tabel 4.

Tabel 4. Hasil Peramalan 12 Periode Kedepan

Periode	<i>t</i>	Hasil Ramalan
Juli 2024	67	55.860,93
Agustus 2024	68	55.263,96
September 2024	69	55.395,05
Oktober 2024	70	55.652,82
November 2024	71	55.314,13
Desember 2024	72	55.600,77
Januari 2025	73	55.782,14
Februari 2025	74	54.589,10
Maret 2025	75	55.775,18

Periode	t	Hasil Ramalan
April 2025	76	56.141,13
Mei 2025	77	54.432,84
Juni 2025	78	55.934,09

Adapun grafik runtun waktu perbandingan antara data aktual dengan hasil peramalan FFNN dengan algoritma *backpropagation* dengan arsitektur terbaik dapat dilihat pada Gambar 6.



Gambar 6. Grafik perbandingan data aktual dan hasil peramalan

Berdasarkan Gambar 6, terlihat bahwa grafik runtun waktu hasil peramalan data volume sampah Kota Samarinda menggunakan metode FFNN dengan algoritma *backpropagation*, menunjukkan pergerakan hasil prediksi menggunakan data *training* memiliki pola berfluktuasi yang cenderung tren seperti pada pola data aktual, yang mana dapat diartikan jika metode FFNN cukup mampu mempelajari karakteristik data dengan baik selama proses pelatihan. Sedangkan pada data *testing*, pola pergerakan hasil peramalan masih mengikuti pola data aktual yaitu berfluktuasi dengan kecenderungan tren meskipun masih dengan deviasi yang cukup besar antara data aktual dan hasil peramalan.

Hasil peramalan untuk 12 periode kedepan (Juli 2024 hingga Juni 2025) diperkirakan volume sampah di Kota Samarinda cenderung stabil dengan peningkatan yang relatif kecil, yang mengindikasikan jika pada periode mendatang, volume sampah di kota Samarinda tidak menunjukkan penambahan yang besar dibandingkan periode sebelumnya. Selanjutnya, pada hasil peramalan tersebut, terdapat pola penurunan yang cenderung sama setiap bulan february di setiap tahunnya yang mengindikasikan adanya musiman yang dikarenakan jumlah hari yang lebih sedikit (28 Hari/29 Hari) dibandingkan bulan biasa di setiap tahunnya.

Berdasarkan pola data secara keseluruhan, volume sampah Kota Samarinda pada dasarnya menunjukkan pola tren meningkat, hal ini sejalan dengan pertumbuhan penduduk di Kota Samarinda yang bertumbuh sebesar 0,41% pada tahun 2023 menurut Badan Pusat Statistik, yang dapat diartikan peningkatan volume sampah pada periode mendatang bisa lebih besar dibandingkan perkiraan pada penelitian ini, sehingga hal ini bisa menjadi perhatian khusus untuk pemerintah Kota Samarinda dalam mengatur tata kelola dan penanganan sampah di Kota Samarinda.

4. Kesimpulan

Penelitian ini menerapkan model arsitektur FFNN dengan algoritma *backpropagation* untuk meramalkan volume sampah bulanan Kota Samarinda. Berdasarkan perbandingan 30 kombinasi arsitektur jaringan yang melibatkan variasi proporsi data *training* dan *testing* (70:30, 80:20, 90:10) dan jumlah *neuron* tersembunyi (1–5 *neuron*) pada dua jenis penentuan *input* (ACF dan PACF), arsitektur FFNN yang terbaik bekerja pada proporsi data *training* dan *testing* sebesar 80:20 dengan model 2-5-1 yaitu 2 *neuron input*, 5 *neuron* tersembunyi, dan 1 *neuron output* dengan. Model ini menghasilkan MAPE sebesar 1,8506% dan RMSE sebesar 1.280,23 pada data *training*, serta MAPE sebesar 3,1823% dan RMSE sebesar 2.139,48 pada data *testing*, yang jika berdasarkan nilai MAPE masuk dalam kategori "sangat baik."

Hasil peramalan untuk periode Juli 2024 hingga Juni 2025 menunjukkan tren volume sampah meningkat namun relatif kecil, dengan puncak tertinggi pada April 2025 (56.141,13 m³) dan titik terendah pada Mei 2025 (54.432,84 m³). Tren kenaikan ini perlu menjadi perhatian serius bagi Pemerintah Kota Samarinda, khususnya dalam hal kecukupan armada pengangkutan, kapasitas tempat pembuangan akhir, dan program pengelolaan sampah berbasis masyarakat.

DAFTAR PUSTAKA

- Adiwana, M. N., & Kartini, U. T. (2020). Desain Photovoltaic Dan Peramalan Jangka Pendek Radiasi Sinar Matahari Menggunakan Metode Feed-Forward Neural Network. *Jurnal Teknik Elektro*, 9(1), 757–764.
- Aljaaf, A. J., Mohsin, T. M., Al-Jumeily, D., & Alloghani, M. (2021). A fusion of data science and feed-forward neural network-based modelling of COVID-19 outbreak forecasting in IRAQ. *Journal of Biomedical Informatics*, 118(August 2020), 103766. <https://doi.org/10.1016/j.jbi.2021.103766>
- Aminy, L. N., & Walid. (2024). Perbandingan Model Feed Forward Neural Network Dan Arima Untuk Meramalkan Perkembangan Covid-19 Di Indonesia. *Jurnal Ilmiah Matematika*, 12(1), 1–10.
- Badan Pusat Statistik. (2023). *Kota Samarinda Dalam Angka 2023*. Samarinda: Badan Pusat Statistik Kota Samarinda.
- Chang, P. C., Wang, Y. W., & Liu, C. H. (2007). The development of a weighted evolving fuzzy neural network for PCB sales forecasting. *Journal Expert Systems with Applications*, 32(1), 86–96. <https://doi.org/10.1016/j.eswa.2005.11.021>
- Fausset, L. (1994). *Fundamental Of Neural Network (Architectures, Algorithms, and Applications)*. Upper Saddle River, New Jersey: Prentice-hall.
- Fitriani, B. E., Ispriyanti, D., & Prahutama, A. (2015). Peramalan Beban Pemakaian Listrik Jawa Tengah Dan Daerah Istimewa Yogyakarta Dengan Menggunakan Hybrid Autoregresive Integrated Moving Average-Neural Network. *Gaussian*, 4(4), 745–754. <https://doi.org/10.14710/j.gauss.4.4.745-754>
- Juliana, A., Hamidatun, & Muslima, R. (2019). *Modern Forecasting: Garch, Artificial Neural Network, Neuro-Garch (Teori dan Aplikasi)*. Yogyakarta: Depublish.
- Kristanto, A. (2004). *Jaringan Saraf Tiruan (Konsep Dasar, Algoritma Dan Aplikasi)*. Yogyakarta: Penerbit Gava Media.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan Jilid 1*. Jakarta: Erlangga.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2011). *Introduction to Time Series Analysis and Forecasting*. New York: John Wiley & Sons.
- Pasini, A. (2015). *Artificial neural networks for small dataset analysis*. 7(5), 953–960. <https://doi.org/10.3978/j.issn.2072-1439.2015.04.61>
- Rachman, A. S., Cholissodin, I., & Fauzi, M. A. (2018). Peramalan Produksi Gula Menggunakan Metode Jaringan Saraf Tiruan Backpropagation Pada PG Candi Baru Sidoarjo. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(4), 1683–1689.
- Saputri, P. D., & Oktaviana, P. P. (2023). Perbandingan Metode Feedforward Neural Network dan Metode Statistika Klasik: Aplikasi di Bidang Finansial. *Jurnal Matematika, Statistika Dan Komputasi*, 19(3), 537–548. <https://doi.org/10.20956/j.v19i3.25379>
- Siang, J. J. (2009). *Jaringan Saraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: CV Andi Offset.
- Syahrudin, Pramita, D., Nusantara, T., & Subanji. (2019). *Peramalan Artificial Neural Network Berbasis GUI dan NNTool Matlab*. Ponorogo: Wade Group.
- Yuliandar, D., Warsito, B., & Hasbi, Y. (2012). Pelatihan Feedforward Neural Network Menggunakan Algoritma Genetika Dengan Metode Seleksi Turnamen Untuk Data Time Series. *Jurnal Gaussian*, 1(1), 65–72. <https://doi.org/10.14710/j.gauss.1.1.65-72>