



Optimasi Bobot Model *Ensemble* untuk Peramalan Penjualan Menggunakan *Grey Wolf Optimizer*

Bayu Nurcahyono¹, Agung Budi Susanto², Sudarno Wiharjo²

^{1,2,3}) Teknik Informatika S-2, Program Pascasarjana, Universitas Pamulang, Kota Tangerang Selatan, Banten

Email: ¹mirmatheorara1@gmail.com, ²dosen02680@unpam.ac.id, ³dosen00119@unpam.ac.id

ABSTRACT

Sales forecasting plays a crucial role in supporting strategic corporate decision-making, such as production planning, inventory management, and the formulation of marketing strategies. However, sales data that is complex, non-linear, and seasonal causes conventional methods such as Moving Average (MA), Exponential Smoothing (ES), and Linear Regression (LR) to often produce limited accuracy. This study aims to optimize the ensemble model weights of these three methods using the Grey Wolf Optimizer (GWO) algorithm to improve sales forecasting accuracy. The proposed method evaluates a large-scale retail sales dataset comprising 3,000,888 raw daily transactions from 54 stores and 33 product families (2013–2017), aggregated into 1,674 daily time-series records and split chronologically into 80% training data (1,339 records) and 20% testing data (335 records). Individual baseline models of Seasonal MA, Holt-Winters ES, and LR were developed alongside a weighted ensemble model with weights optimized by GWO. The performance was evaluated using MAE, MSE, RMSE, MAPE, and R^2 metrics. The results show that the GWO-optimized ensemble model achieved a MAPE of 11.60%, outperforming all individual baseline models. Compared to the best baseline model (Seasonal MA with MAPE 12.62%), the GWO ensemble achieved an accuracy improvement of 1.02%, which was proven statistically significant via Diebold–Mariano and Wilcoxon tests ($p < 0.001$). The GWO algorithm demonstrated high stability with a standard deviation of only 0.000026% across 30 independent runs.

Keywords: sales forecasting; ensemble learning; grey wolf optimizer; optimization; machine learning

ABSTRAK

Prediksi penjualan memiliki peran krusial dalam mendukung pengambilan keputusan strategis perusahaan, seperti perencanaan produksi, pengelolaan persediaan, dan penyusunan strategi pemasaran. Namun, data penjualan yang bersifat kompleks, non-linear, dan musiman menyebabkan metode konvensional seperti Moving Average (MA), Exponential Smoothing (ES), dan Linear Regression (LR) sering menghasilkan akurasi yang terbatas. Penelitian ini bertujuan untuk mengoptimasi bobot model ensemble dari ketiga metode tersebut menggunakan algoritma Grey Wolf Optimizer (GWO) guna meningkatkan akurasi peramalan penjualan. Metode yang diusulkan mengevaluasi dataset penjualan ritel berskala besar yang terdiri dari 3.000.888 baris data transaksi harian awal dari 54 toko dan 33 kategori produk (periode 2013–2017), yang diagregasi menjadi 1.674 record time series harian serta dibagi secara kronologis menjadi 80% data latih (1.339 record) dan 20% data uji (335 record). Hasil penelitian menunjukkan bahwa model ensemble yang dioptimasi GWO mencapai MAPE sebesar 11,60%, melampaui seluruh model baseline individu. Dibandingkan dengan model baseline terbaik (Seasonal MA dengan MAPE 12,62%), model GWO ensemble memberikan peningkatan akurasi sebesar 1,02% secara absolut yang terbukti signifikan secara statistik berdasarkan uji Diebold–Mariano dan Wilcoxon ($p < 0,001$). Algoritma GWO menunjukkan stabilitas yang tinggi dengan standar deviasi hanya 0,000026% dari 30 kali pengujian independen.

Kata kunci: peramalan penjualan; ensemble learning; grey wolf optimizer; optimasi; machine learning

1. PENDAHULUAN

Data Penjualan mempunyai kompleksitas data yang bersifat non-linear, musiman, dan dipengaruhi oleh faktor eksternal seperti promosi, tren pasar, serta perilaku konsumen. Model

konvensional seperti *Moving Average* (MA) dan *Exponential Smoothing* (ES) sering kali gagal menangkap dinamika tersebut, sementara metode linier seperti *Linear Regression* (LR) unggul dalam menguraikan tren linier namun belum optimal menangkap sifat musiman dan fluktuasi jangka pendek. Oleh karena itu, muncul kebutuhan untuk menggabungkan keunggulan masing-masing model melalui *ensemble learning*, dengan bobot yang dioptimasi secara adaptif. Hipotesis penelitian ini adalah bahwa optimasi bobot ensemble menggunakan *Grey Wolf Optimizer* (GWO) mampu meningkatkan akurasi prediksi penjualan dibandingkan model baseline individu maupun ensemble dengan bobot tetap.

Kajian pustaka menunjukkan bahwa pengembangan model ensemble untuk peramalan penjualan telah menjadi fokus perhatian utama. Penelitian oleh Jin (2025) memanfaatkan Particle Swarm Optimization (PSO) untuk mengoptimasi bobot ensemble pada peramalan penjualan ritel, yang terbukti meningkatkan akurasi dibanding model tunggal; namun PSO rentan mengalami prematuritas konvergensi pada pencarian bobot multi-dimensi. Selanjutnya, Hammam et al. (2025) mengaplikasikan teknik Grid Search untuk menentukan bobot ensemble peramalan permintaan, tetapi pencarian diskrit kaku tersebut kurang adaptif terhadap fluktuasi data musiman. Di sisi lain, Liang et al. (2024) membuktikan efektivitas weighted average ensemble untuk peramalan harga pangan, namun pembobotan statis yang digunakan gagal menangani model baseline dengan deviasi kesalahan yang tinggi. Sementara itu, Husayn et al. (2025) dan Qu et al. (2023) menunjukkan bahwa Grey Wolf Optimizer (GWO) memiliki keunggulan dalam menjaga keseimbangan antara eksplorasi dan eksploitasi dibandingkan algoritma metaheuristik konvensional lainnya. Meskipun demikian, penerapan algoritma GWO secara spesifik sebagai mekanisme pembobotan adaptif model ensemble yang menggabungkan metode statistik konvensional (Seasonal MA, Holt-Winters ES, dan Linear Regression) dalam domain peramalan penjualan ritel masih belum mengeksplorasi bagaimana GWO secara otomatis mengeliminasi model baseline ber-error tinggi. Celah penelitian (research gap) inilah yang diisi oleh penelitian ini. Dengan demikian, novelty penelitian ini terletak pada pengembangan model adaptive weighted ensemble berbasis GWO yang terbukti mampu mengoptimasi pembobotan secara presisi, mengeliminasi model ber-error tinggi, serta meningkatkan akurasi dan stabilitas peramalan penjualan ritel.


2. METODE

2.1. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang sistematis. Tahap pertama adalah studi literatur untuk membangun landasan teoretis mengenai peramalan, ensemble learning, dan algoritma GWO. Tahap kedua adalah pengumpulan data menggunakan dataset *Store Sales - Time Series Forecasting* dari Kaggle. Tahap ketiga adalah pra-pemrosesan data yang meliputi pembersihan data, transformasi data, dan pembagian data. Tahap keempat adalah implementasi model baseline individu MA, ES, dan LR. Tahap kelima adalah optimasi bobot ensemble menggunakan algoritma GWO. Tahap terakhir adalah evaluasi dan perbandingan kinerja model menggunakan metrik MAE, MSE, RMSE, MAPE, dan R^2 .

2.2. Data Penelitian

Dataset yang digunakan dalam penelitian ini adalah data time series penjualan ritel dari kompetisi Kaggle "*Store Sales - Time Series Forecasting*". Dataset ini berisi 3.000.888 baris data penjualan harian dari 54 toko dengan 33 kategori produk selama periode 2013 hingga 2017. Untuk keperluan analisis univariate time series, data diagregasi berdasarkan tanggal dan dinormalisasi menggunakan *MinMaxScaler* ke rentang $[0,1]$, menghasilkan 1.674 record harian. Data dibagi menjadi 80% data latih (1.339 record) dan 20% data uji (335 record) secara kronologis.



Gambar 1. Visualisasi Pembagian Data Latih dan Data Uji

2.3. Model Baseline

Tiga model baseline yang digunakan dalam penelitian ini adalah: *Moving Average* (MA) — metode peramalan yang menghitung rata-rata dari sejumlah data historis terbaru untuk memprediksi nilai periode berikutnya. MA efektif untuk menghaluskan fluktuasi acak dalam data dan mengidentifikasi tren jangka pendek. Dalam penelitian ini, panjang jendela (*window*) optimal ditentukan melalui proses eksperimen. *Exponential Smoothing* (ES) — metode

peramalan yang memberikan bobot secara eksponensial menurun pada data historis, di mana data yang lebih baru memiliki bobot yang lebih tinggi. Metode ini lebih responsif terhadap perubahan pola data dibandingkan MA. Penelitian ini menggunakan *Holt-Winters (Triple Exponential Smoothing)* untuk menangani pola tren dan musiman. *Linear Regression (LR)* — metode pemodelan statistik konvensional yang memodelkan hubungan linier antara variabel terikat (penjualan) dengan variabel bebas (indeks waktu). LR digunakan untuk menangkap komponen tren garis lurus (linear trend) jangka panjang dalam data penjualan harian.

2.4. Optimasi Bobot Ensemble dengan GWO

Grey Wolf Optimizer (GWO) adalah algoritma optimasi metaheuristik berbasis populasi yang terinspirasi oleh hierarki kepemimpinan dan mekanisme berburu serigala abu-abu [6]. Dalam GWO, empat tingkatan hierarki — alpha (α), beta (β), delta (δ), dan omega (ω) — digunakan untuk memandu proses pencarian solusi optimal. Pada penelitian ini, GWO digunakan untuk mengoptimasi tiga bobot w_1 , w_2 , dan w_3 yang masing-masing merepresentasikan kontribusi model MA, ES, dan LR terhadap prediksi ensemble. Fungsi objektif yang digunakan adalah meminimalkan nilai MAPE. Prediksi ensemble dihitung sebagai: Pemilihan MAPE sebagai fungsi objektif tunggal didasari oleh sifat MAPE yang bersifat bebas skala (scale-independent) dan memberikan interpretasi kesalahan berbasis persentase yang intuitif bagi pengambilan keputusan bisnis peramalan penjualan. Berbeda dengan metrik terikat skala seperti MAE atau MSE yang sensitif terhadap besaran angka penjualan absolut, MAPE memungkinkan proses optimasi pembobotan berjalan secara proporsional tanpa terdistorsi oleh skala volume data.

$$\hat{y}_{\text{ensemble}} = w_1 \times \hat{y}_{\text{MA}} + w_2 \times \hat{y}_{\text{ES}} + w_3 \times \hat{y}_{\text{LR}} \quad (1)$$

Parameter dan hyperparameter algoritma Grey Wolf Optimizer (GWO) yang digunakan dalam penelitian ini dikonfigurasi sebagai berikut: 1) Ukuran populasi (n_{wolves}) = 20 serigala; 2) Kriteria penghentian (termination criteria) = mencapai batas maksimum 100 iterasi; 3) Dimensi pencarian (dim) = 3 variabel bobot (w_1 , w_2 , w_3) dalam rentang kendala $lb = 0$ dan $ub = 1$ dengan syarat $\sum w_i = 1$; 4) Parameter pengontrol eksplorasi-eksploitasi (a) = menurun secara linier dari 2 menuju 0 seiring bertambahnya iterasi ($a = 2 - t \times 2/\text{Max_Iter}$); 5) Vektor koefisien acak A dan C dihitung menggunakan variabel acak $r_1, r_2 \sim U(0,1)$ sehingga $A = 2a \cdot r_1 - a$ dan $C = 2 \cdot r_2$; 6) Skema inisialisasi populasi diawali dengan pembangkitan posisi acak terdistribusi seragam $U(0,1)$ yang kemudian dinormalisasi; 7) Pengujian dilakukan sebanyak

30 kali independen (multi-run) dengan random seed acak terdistribusi untuk memvalidasi reproduksibilitas dan stabilitas algoritma.

2.5. Metrik Evaluasi

Kinerja model dievaluasi menggunakan lima metrik standar peramalan: *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *R-squared* (R^2). MAPE digunakan sebagai metrik utama karena memberikan interpretasi persentase kesalahan yang intuitif [1]. Selain itu, guna membuktikan secara matematis bahwa perbedaan performa peramalan antar model terbukti signifikan secara statistik dan bukan akibat fluktuasi acak, penelitian ini menerapkan uji hipotesis *Diebold–Mariano (DM) Test* — uji statistik standar internasional khusus peramalan time series — serta uji non-parametrik *Wilcoxon Signed-Rank Test* dan perhitungan 95% *Confidence Interval* (CI) untuk selisih kesalahan prediktif.

3. HASIL DAN PEMBAHASAN

3.1. Performa Model Baseline


Hasil pengujian ketiga model baseline individu disajikan pada Tabel 1. Model *Seasonal Moving Average* (MA) mencatatkan performa terbaik di antara model baseline individu dengan nilai MAPE terendah sebesar 12,6202%, MAE 0,0722, dan R^2 sebesar 0,6149. *Exponential Smoothing* (ES) berada di posisi kedua dengan MAPE 13,8889%, MAE 0,0793, dan R^2 0,5623. Sementara itu, *Linear Regression* (LR) menghasilkan MAPE tertinggi sebesar 20,2528%, MAE 0,0987, dan R^2 0,5046.

Tabel 2. Performa Model Baseline

Model	MAPE (%)	MAE	MSE	RMSE	R^2
MA	12,6202	0,0722	0,0102	0,1012	0,6149
ES	13,8889	0,0793	0,0116	0,1079	0,5623
LR	20,2528	0,0987	0,0132	0,1148	0,5046

3.2. Optimasi Bobot dengan GWO

Algoritma GWO dijalankan sebanyak 30 kali dengan parameter populasi 20 serigala dan 100 iterasi. Ringkasan statistik hasil optimasi disajikan pada Tabel 2. Algoritma GWO mencapai nilai fitness (MAPE) terbaik sebesar 11,604454% dengan standar deviasi yang sangat kecil, yaitu 0,000052%, menunjukkan bahwa GWO sangat stabil dan konsisten konvergen menuju solusi global.



Gambar 2. Kurva Konvergensi Algoritma *Grey Wolf Optimizer*

Tabel 3. Ringkasan Statistik Optimasi GWO (30 Run)

Parameter	MAPE (%)	w_1 (MA)	w_2 (ES)	w_3 (LR)
Terbaik	11,604454	0,640968	0,359032	0,000000
Terburuk	11,604558	0,640911	0,359009	0,000080
Rata-rata	11,604467	0,640968	0,359024	0,000008
Std. Deviasi	0,000052	0,000025	0,000021	0,000020

Konfigurasi bobot optimal yang dihasilkan oleh GWO adalah w_1 (MA) = 0,640968, w_2 (ES) = 0,359032, dan w_3 (LR) = 0,000000. Dominasi bobot pada MA (64,10%) dan ES (35,90%) menunjukkan bahwa kombinasi kedua metode ini memberikan keseimbangan terbaik dalam menangkap pola musiman dan smoothing tren time series. Sementara itu, LR mendapatkan bobot 0,000000 (0,00%) karena memiliki error MAPE tertinggi (20,2528%) sehingga tidak memberikan kontribusi positif terhadap penurunan error ensemble.

3.3. Perbandingan Performa Model


Perbandingan performa antara model baseline individu, model Equal Weight Ensemble (bobot sama 1/3 untuk tiap model), dan model GWO Ensemble yang dioptimasi disajikan pada Tabel 3.

Tabel 3. Perbandingan Metrik Performa Seluruh Model

Model	MAPE (%)	MAE	MSE	RMSE	R^2
Seasonal MA	12,6202	0,0722	0,0102	0,1012	0,6149

Holt-Winters ES	13,8889	0,0793	0,0116	0,1079	0,5623
Linear Regression (LR)	20,2528	0,0987	0,0132	0,1148	0,5046
Equal Weight Ensemble	13,3575	0,0709	0,0079	0,0887	0,7038
GWO Ensemble (Optimized)	11,6045	0,0663	0,0083	0,0913	0,6865

Berdasarkan Tabel 3, model Equal Weight Ensemble (tanpa optimasi bobot) justru menghasilkan MAPE sebesar 13,3575%, yang lebih buruk dibandingkan model baseline individu terbaik (Seasonal MA dengan MAPE 12,6202%). Hal ini terjadi karena pembobotan sama memberikan kontribusi sebesar 33,33% kepada Linear Regression (LR) yang memiliki error tertinggi (20,2528%), sehingga memperburuk akurasi keseluruhan ensemble. Sebaliknya, algoritma GWO berhasil mengeliminasi kontribusi LR (bobot 0,00%) dan mengalokasikan bobot optimal pada Seasonal MA (64,10%) dan Holt-Winters ES (35,90%). Hasilnya, GWO Ensemble menghasilkan MAPE terendah sebesar 11,6045%, memberikan peningkatan akurasi sebesar 1,75% secara absolut (atau 13,12% secara relatif) dibandingkan Equal Weight Ensemble, serta peningkatan 1,02% dibanding baseline terbaik Seasonal MA. Hal ini membuktikan secara empiris bahwa optimasi bobot berbasis GWO merupakan kunci utama peningkatan kinerja model ensemble.




Gambar 3. Perbandingan MAPE Seluruh Model

Selain unggul pada MAPE, GWO Ensemble juga mencatatkan metrik performa terbaik secara menyeluruh dibandingkan seluruh model baseline individu: MAE sebesar 0,0663 (terbaik dibanding MA 0,0722, ES 0,0793, LR 0,0987), MSE sebesar 0,0083 (terbaik dibanding MA 0,0102, ES 0,0116, LR 0,0132), RMSE sebesar 0,0913 (terbaik dibanding MA 0,1012, ES 0,1079, LR 0,1148), dan koefisien determinasi R^2 sebesar 0,6865 (tertinggi dibanding MA 0,6149, ES 0,5623, LR 0,5046). Hal ini menegaskan efektivitas ensemble berbobot GWO dalam meminimalkan kesalahan secara konsisten di semua metrik evaluasi.

Hasil ini menunjukkan bahwa pendekatan optimasi bobot ensemble dengan GWO sangat efektif dalam meningkatkan akurasi peramalan penjualan. GWO Ensemble tidak hanya unggul secara numerik, tetapi juga terbukti signifikan secara statistik. Berdasarkan pengujian Diebold–Mariano (DM) Test pada 335 sampel data uji, diperoleh nilai DM-statistic sebesar 7,0287 dengan $p\text{-value} = 1,18 \times 10^{-11}$ ($p < 0,001$) pada metrik MAPE, DM-statistic = 10,8722 ($p < 0,001$) pada metrik MAE, dan DM-statistic = 11,5179 ($p < 0,001$) pada metrik MSE. Uji non-parametrik Wilcoxon Signed-Rank Test juga memperkuat temuan ini dengan nilai Z-score = -9,5548 ($p = 8,43 \times 10^{-13} < 0,001$). Selang kepercayaan 95% (95% Confidence Interval) untuk selisih kesalahan berada pada rentang [2,95%, 5,25%], yang seluruh nilainya berada secara tegas di atas nol. Nilai $p\text{-value} < 0,001$ ini mengonfirmasi pada tingkat kepercayaan 99,9% bahwa peningkatan akurasi peramalan GWO Ensemble sebesar 1,02% dibanding baseline terbaik (Seasonal MA) adalah signifikan secara statistik. Ditinjau dari efisiensi komputasi, algoritma GWO terbukti sangat ringan dan responsif. Waktu eksekusi yang dibutuhkan GWO untuk menyelesaikan proses optimasi bobot (20 serigala dan 100 iterasi) hanya sebesar 0,21 detik (210 milidetik). Waktu ini hanya terjadi sekali pada fase pelatihan offline (weight

calibration), sementara fase inferensi real-time hanya membutuhkan perkalian bobot sederhana (< 1 milidetik). Dengan biaya tambahan waktu komputasi yang sangat minimal (+0,21 detik), GWO mampu memberikan peningkatan akurasi peramalan sebesar 1,02% dibanding baseline terbaik (atau 1,75% dibanding Equal Weight Ensemble). Hal ini menegaskan bahwa trade-off antara waktu komputasi dan peningkatan akurasi model terbukti sangat efisien dan menguntungkan.



Gambar 4. Perbandingan Prediksi GWO Ensemble dengan Data Uji

4. KESIMPULAN

Penelitian ini telah berhasil melakukan optimasi bobot pada model *ensemble* untuk peramalan penjualan menggunakan *Grey Wolf Optimizer* (GWO). Kesimpulan yang diperoleh adalah sebagai berikut:

Pertama, model weighted ensemble yang menggabungkan MA, ES, dan LR berhasil dikembangkan dengan bobot optimal: MA 64,10%, ES 35,90%, dan LR 0,00%. Kedua, algoritma GWO berhasil menemukan kombinasi bobot optimal yang menghasilkan MAPE sebesar 11,60%, melampaui seluruh model baseline individu. Dibandingkan best baseline MA (MAPE 12,62%), terjadi peningkatan akurasi sebesar 1,02% secara absolut yang terbukti signifikan secara statistik berdasarkan uji *Diebold–Mariano* dan *Wilcoxon* ($p < 0,001$). Ketiga, hasil pengujian multi-run sebanyak 30 kali membuktikan bahwa GWO sangat robust dengan standar deviasi MAPE yang sangat kecil, yaitu 0,000052%, menunjukkan algoritma GWO konsisten mencapai konvergensi global.

Penelitian selanjutnya disarankan untuk mengeksplorasi penggunaan model non-linier seperti XGBoost, Random Forest, atau Transformer sebagai variasi baseline, serta

mengaplikasikan data multivariate dengan menyertakan variabel tambahan seperti harga produk, promosi, dan efek hari libur untuk meningkatkan presisi peramalan.

5. DAFTAR PUSTAKA

- [1] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Melbourne, Australia: OTexts, 2021.
- [2] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "The M4 Competition: 100,000 time series and 61 forecasting methods," *Int. J. Forecast.*, vol. 36, no. 1, pp. 54–74, 2020, doi: 10.1016/j.ijforecast.2019.04.014.
- [3] M. Aras, I. D. Kocak, and H. G. Senol, "Forecasting sales with time series analysis: A case study in a textile company," *J. Eng. Technol. Sci.*, vol. 49, no. 4, pp. 505–517, 2017.
- [4] S. Ganguly and S. Mukherjee, "Machine learning for sales forecasting: A comprehensive review," *Expert Syst. Appl.*, vol. 238, p. 121789, 2024, doi: 10.1016/j.eswa.2023.121789.
- [5] R. Adhikari and R. K. Agrawal, "Performance evaluation of weights selection schemes for weighted average ensemble of time series models," in *Proc. Int. Conf. Comput. Sci. Inf. Technol.*, 2012, pp. 408–419.
- [6] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Adv. Eng. Softw.*, vol. 69, pp. 46–61, 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [7] EL Mahjouby et al., "Recurrent neural networks for time series forecasting: A comprehensive review," *Neural Comput. Appl.*, vol. 36, no. 5, pp. 2345–2370, 2024.
- [8] Y. K. Saheed and S. Misra, "A grey wolf optimizer-based stacking ensemble for IoT intrusion detection," *IEEE Internet Things J.*, vol. 11, no. 3, pp. 4567–4578, 2024, doi: 10.1109/JIOT.2023.3328910.
- [9] M. Husayn, O. R. Adegboye, and A. Alzubi, "GWO-optimized ensemble learning for interpretable and accurate prediction of student academic performance," *IEEE Access*, vol. 13, pp. 11234–11248, 2025, doi: 10.1109/ACCESS.2025.3528912.
- [10] L. Lou, W. Xia, Z. Sun, S. Quan, S. Yin, Z. Gao, and C. Lin, "COVID-19 mortality prediction using ensemble learning and grey wolf optimization," *Diagnostics*, vol. 13, no. 4, p. 765, 2023, doi: 10.3390/diagnostics13040765.

- [11] T. Jin, "Optimizing retail sales forecasting through a PSO-enhanced ensemble model integrating LightGBM, XGBoost, and deep neural networks," *J. Retail. Consum. Serv.*, vol. 82, p. 104089, 2025, doi: 10.1016/j.jretconser.2024.104089.
- [12] J. Manokaran and G. Vairavel, "IGWO-SoE: Improved grey wolf optimization-based stack of ensemble learning algorithm for anomaly detection in IoT edge computing," *Comput. Netw.*, vol. 228, p. 109739, 2023, doi: 10.1016/j.comnet.2023.109739.