



OPTIMASI ARSITEKTUR DEEP NEURAL NETWORK(DNN) MENGGUNAKAN PARTICLE SWARM OPTIMIZATION (PSO) UNTUK PREDIKSI NILAI EKSPOR KOPI DI INDONESIA

Chofifah Fara Amlati

Program Studi Teknik Informatika, Fakultas Sains dan Teknologi,

Universitas PGRI Kanjuruhan Malang

Email: chofchofifahgreat@gmail.com

Abstrak

Penelitian ini bertujuan memprediksi nilai ekspor kopi Indonesia menggunakan Deep Neural Network (DNN) dan mengoptimalkan arsitekturnya menggunakan Particle Swarm Optimization (PSO). Dataset diperoleh dari Trade Map untuk periode 2021-2025 dengan variabel input Quantity (Ton), Unit Value (US\$/Ton), dan Growth in Value (%), sedangkan target penelitian adalah Value (US\$). Tahapan penelitian meliputi pembersihan data, normalisasi Min-Max, pembentukan data untuk pemodelan, pembagian data menjadi training, validation, dan testing, pembangunan tiga arsitektur DNN, serta optimasi arsitektur menggunakan PSO. Tiga arsitektur DNN diuji dengan dua, tiga, dan empat hidden layer. Hasil pengujian menunjukkan bahwa DNN empat hidden layer memberikan hasil terbaik sebelum optimasi, dengan MSE 21.467.553,21, MAE 3.242,41, dan R^2 0,9145. Optimasi PSO menggunakan delapan partikel dan 100 iterasi menghasilkan konfigurasi terbaik berupa 113 neuron pada hidden layer pertama, 46 neuron pada hidden layer kedua, 19 neuron pada hidden layer ketiga, serta learning rate 0,000896. Model DNN-PSO menghasilkan MSE 1.703.856,56, MAE 798,74, dan R^2 0,9932. Dibandingkan DNN empat hidden layer, MSE turun 92,06%, MAE turun 75,36%, dan R^2 meningkat 8,61%. Hasil tersebut menunjukkan bahwa PSO mampu membantu pencarian arsitektur DNN yang lebih optimal dan menghasilkan prediksi yang lebih mendekati nilai aktual.

Kata Kunci: Deep Neural Network, Particle Swarm Optimization, optimasi arsitektur, prediksi nilai ekspor, kopi Indonesia

Abstract

This study aims to predict the export value of Indonesian coffee using a Deep Neural Network (DNN) and optimize its architecture using Particle Swarm Optimization (PSO). The dataset was obtained from Trade Map for the 2021-2025 period, using Quantity (Ton), Unit Value (US\$/Ton), and Growth in Value (%) as input variables and Value (US\$) as the target. The research stages consisted of data cleaning, Min-Max normalization, data preparation, chronological data splitting into training, validation, and testing sets, construction of three DNN architectures, and architecture optimization using PSO. Three DNN architectures with two, three, and four hidden layers were evaluated. The four-hidden-layer DNN achieved the best baseline performance with an MSE of 21,467,553.21, MAE of 3,242.41, and R^2 of 0.9145. PSO optimization using eight particles and 100 iterations produced an optimal configuration of 113 neurons in the first hidden layer, 46 neurons in the second, 19 neurons in the third, and a learning rate of 0.000896. The DNN-PSO model achieved an MSE of 1,703,856.56, MAE of 798.74, and R^2 of 0.9932. Compared with the four-hidden-layer DNN, MSE decreased by 92.06%, MAE decreased by 75.36%, and R^2 increased by 8.61%. These results indicate that PSO can support the search for a more optimal DNN architecture and produce predictions closer to the actual export values.

Keywords: Deep Neural Network, Particle Swarm Optimization, architecture optimization, export value prediction, Indonesian coffee

Article History

Received: September 2026

Reviewed: September 2026

Published: September 2026

Plagiarism Checker No
237.u873247.fh8374

Copyright : Author

Publish by : Kohesi



This work is licensed under
a [Creative Commons
Attribution-NonCommercial
4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)



1. PENDAHULUAN

Indonesia merupakan salah satu negara penting dalam perdagangan kopi dunia. Nilai ekspor kopi memiliki karakteristik yang berfluktuasi karena dipengaruhi perubahan permintaan, kondisi pasar, dan faktor perdagangan internasional. Kondisi tersebut membuat prediksi nilai ekspor menjadi penting untuk mendukung perencanaan dan pengambilan keputusan. Penelitian terdahulu mengenai peramalan menunjukkan bahwa pola deret waktu dapat mengandung hubungan linier dan nonlinier sehingga model tunggal tidak selalu mampu menangkap seluruh karakteristik data [2]. Pada konteks ekspor kopi Indonesia, penerapan beberapa algoritma pembelajaran mesin telah dilakukan, tetapi hasil model dapat berbeda bergantung pada karakteristik data dan konfigurasi model [9].

Regresi linier memiliki keunggulan pada pola yang relatif teratur, tetapi keterbatasannya menjadi lebih terlihat ketika hubungan antarvariabel bersifat kompleks. Artificial Neural Network mampu memodelkan hubungan nonlinier, sedangkan Deep Neural Network (DNN) menggunakan beberapa hidden layer untuk membentuk representasi fitur secara bertingkat [11]. Penelitian mengenai DNN menunjukkan bahwa arsitektur jaringan, jumlah neuron, dan parameter pelatihan berpengaruh terhadap kinerja prediksi. Namun, penentuan arsitektur secara manual dapat membutuhkan banyak percobaan dan berisiko menghasilkan konfigurasi yang belum optimal [5].

Permasalahan tersebut mendorong penggunaan metode optimasi untuk mencari konfigurasi DNN secara lebih sistematis. Particle Swarm Optimization (PSO) merupakan algoritma optimasi berbasis populasi yang menggunakan informasi personal best (pBest) dan global best (gBest) dalam mengarahkan kandidat solusi menuju posisi yang lebih baik. Penerapan PSO untuk optimasi arsitektur DNN telah dilaporkan dapat meningkatkan performa dibandingkan konfigurasi yang ditentukan secara manual [6], [10]. PSO juga dapat digunakan untuk mencari kombinasi jumlah neuron dan parameter pelatihan pada ruang pencarian yang luas [7], [8].

Penelitian ini menerapkan DNN untuk memprediksi nilai ekspor kopi Indonesia dan menggunakan PSO untuk mengoptimalkan arsitektur DNN. Data yang digunakan berasal dari Trade Map pada periode 2021-2025 dengan input Quantity, Unit Value, dan Growth in Value, sedangkan targetnya adalah Value. Penelitian membandingkan tiga arsitektur DNN standar, kemudian menggunakan PSO untuk mencari konfigurasi arsitektur yang lebih baik. Kinerja model diukur menggunakan Mean Squared Error (MSE), Mean Absolute Error (MAE), dan Coefficient of Determination (R^2). Kontribusi penelitian ini adalah memberikan konfigurasi DNN-PSO yang diperoleh melalui pencarian otomatis dan mengukur peningkatan kinerjanya terhadap model DNN baseline.


Tujuan penelitian adalah (1) menghasilkan prediksi nilai ekspor kopi Indonesia menggunakan DNN, (2) memperoleh konfigurasi arsitektur DNN melalui optimasi PSO, dan (3) mengukur peningkatan kinerja DNN-PSO terhadap DNN berdasarkan MSE, MAE, dan R^2 . Ruang lingkup dibatasi pada data Trade Map periode 2021-2025 dan perbandingan antara DNN serta DNN-PSO tanpa menguji algoritma prediksi lain sebagai model utama.

2. METODE / ALGORITMA

Penelitian dilakukan melalui tahapan pengumpulan data, preprocessing, pembangunan model DNN, optimasi arsitektur dengan PSO, prediksi menggunakan konfigurasi hasil optimasi, evaluasi, dan perbandingan kinerja. Implementasi dilakukan menggunakan Python pada Google



Colab. Alur penelitian disusun agar model baseline tersedia terlebih dahulu sehingga peningkatan yang diperoleh dari PSO dapat dibandingkan secara langsung.



Gambar 3. 1 Diagram Alir Rancangan Penelitian

Gambar 1. Diagram alir rancangan penelitian

2.1 Pengumpulan Data

Data penelitian merupakan data sekunder yang diperoleh dari Trade Map. Objek data adalah kategori kopi yang mencakup coffee whether or not roasted or decaffeinated, coffee husks and skins, serta coffee substitutes containing coffee in any proportion. Data yang digunakan mencakup periode tahunan 2021-2025. Variabel yang tersedia meliputi Year, Country, Quantity (Ton), Value (US\$), Unit Value (US\$/Ton), dan Growth in Value (%). Dalam pemodelan, Country dan Year tidak digunakan sebagai variabel input numerik; input yang digunakan adalah Quantity, Unit Value, dan Growth in Value, sedangkan Value menjadi target.

Tabel 1. Variabel penelitian

Variabel	Keterangan	Peran
Quantity (Ton)	Volume ekspor kopi	Input
Unit Value (US\$/Ton)	Nilai rata-rata ekspor per ton	Input
Growth in Value (%)	Pertumbuhan nilai ekspor	Input
Value (US\$)	Nilai total ekspor kopi	Target

2.2 Preprocessing Data

Preprocessing dilakukan untuk meningkatkan kesiapan data sebelum pelatihan. Tahap pertama adalah data cleaning dengan memeriksa missing value dan format numerik. Dataset awal berjumlah 760 baris. Missing value ditemukan pada Quantity sebanyak 165 data, Value sebanyak 165 data, Unit Value sebanyak 189 data, dan Growth in Value sebanyak 225 data. Karena Growth

in Value memiliki missing value terbanyak dan setiap baris harus memiliki variabel lengkap, sebanyak 225 baris dihapus sehingga tersisa 535 data.


Tahap berikutnya adalah normalisasi Min-Max untuk mengubah variabel numerik ke rentang 0-1. Persamaan yang digunakan adalah $x' = (x - x_{\min}) / (x_{\max} - x_{\min})$. Setelah normalisasi, data dibagi berdasarkan urutan waktu tanpa pengacakan menjadi training set, validation set, dan testing set dengan rasio nominal 70%:15%:15%. Hasil aktual pembagian adalah 374 data training (69,91%), 80 data validation (14,95%), dan 81 data testing (15,14%). Data validasi digunakan dalam proses optimasi PSO, sedangkan data testing digunakan untuk evaluasi akhir.

Tabel 2. Hasil preprocessing dan pembagian data

Tahap	Hasil
Data awal	760 data
Data setelah cleaning	535 data
Training	374 data (69,91%)
Validation	80 data (14,95%)
Testing	81 data (15,14%)

2.3 Pembangunan Model Deep Neural Network

Model DNN digunakan sebagai baseline. Arsitektur yang diuji terdiri atas tiga skenario, yaitu dua, tiga, dan empat hidden layer. Setiap hidden layer menggunakan fungsi aktivasi ReLU dan dropout 0,2 sebagai regularisasi. Lapisan output terdiri atas satu neuron untuk menghasilkan nilai prediksi. Struktur arsitektur ditentukan secara manual pada tahap baseline untuk mengetahui konfigurasi yang memberikan kinerja terbaik sebelum optimasi.



Gambar 2. Arsitektur model Deep Neural Network yang diuji

Tabel 3. Arsitektur model DNN baseline


Model	Hidden layer	Jumlah neuron
DNN 2 hidden layer	2	32 - 16
DNN 3 hidden layer	3	64 - 32 - 16
DNN 4 hidden layer	4	128 - 64 - 32 - 16

2.4 Optimasi Arsitektur Menggunakan Particle Swarm Optimization

PSO digunakan untuk mencari konfigurasi arsitektur DNN yang lebih optimal. Setiap partikel merepresentasikan satu kandidat konfigurasi yang terdiri atas jumlah neuron pada tiga hidden

layer dan learning rate optimizer Adam. Ruang pencarian ditetapkan pada 32-128 neuron untuk hidden layer pertama, 16-64 neuron untuk hidden layer kedua, 8-32 neuron untuk hidden layer ketiga, dan learning rate 0,0001-0,001. Optimasi menggunakan 8 partikel, koefisien $c1 = 0,5$, $c2 = 0,3$, bobot inersia $w = 0,7$, dan 100 iterasi.

Pada setiap iterasi, kandidat arsitektur dilatih menggunakan data training dan dinilai menggunakan MAE pada data validation sebagai fungsi fitness. Nilai fitness yang lebih kecil menunjukkan konfigurasi yang lebih baik. Posisi dan kecepatan partikel diperbarui berdasarkan pBest dan gBest. Setelah proses berhenti, konfigurasi dengan fitness terbaik digunakan untuk membangun model DNN-PSO final.



Gambar 3. Kurva konvergensi PSO

Kurva konvergensi digunakan untuk melihat perubahan best cost selama 100 iterasi. Penurunan best cost menunjukkan bahwa partikel secara bertahap menemukan konfigurasi yang lebih baik. Pada penelitian ini, nilai best cost akhir yang dilaporkan adalah 0,020214736, yang menunjukkan bahwa proses pencarian telah mendekati kondisi konvergen.

2.5 Evaluasi Kinerja Model

Kinerja model dievaluasi pada data testing menggunakan MSE, MAE, dan R^2 . MSE menghitung rata-rata kuadrat selisih antara nilai aktual dan prediksi sehingga memberikan penalti lebih besar pada kesalahan yang tinggi. MAE menghitung rata-rata nilai absolut selisih prediksi dan aktual sehingga mudah diinterpretasikan dalam satuan data asli. R^2 mengukur proporsi variasi target yang dapat dijelaskan oleh model; nilai yang semakin mendekati 1 menunjukkan kemampuan penjelasan yang semakin tinggi.

Perbandingan kinerja dihitung menggunakan persentase perubahan. Untuk MSE dan MAE, penurunan dihitung dengan $(\text{nilai DNN} - \text{nilai DNN-PSO}) / \text{nilai DNN} \times 100\%$. Untuk R^2 , peningkatan dihitung dengan $(R^2 \text{ DNN-PSO} - R^2 \text{ DNN}) / R^2 \text{ DNN} \times 100\%$.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Preprocessing

Setelah cleaning, dataset berkurang dari 760 menjadi 535 data. Penghapusan dilakukan terhadap baris yang memiliki missing value pada variabel penelitian. Selanjutnya, normalisasi Min-Max menghasilkan seluruh variabel numerik pada skala 0-1. Pembagian data secara kronologis menghasilkan 374 data training, 80 data validation, dan 81 data testing. Pembagian tanpa pengacakan dipertahankan agar urutan data tidak berubah dan data testing tetap merepresentasikan data yang belum digunakan selama pembelajaran.


3.2 Hasil Prediksi Model DNN Baseline

Tiga arsitektur DNN diuji untuk mengetahui pengaruh kedalaman jaringan terhadap prediksi nilai ekspor. Hasil pengujian pada sampel data testing menunjukkan bahwa model empat hidden layer cenderung menghasilkan prediksi yang lebih mendekati nilai aktual dibandingkan dua dan tiga hidden layer. Contohnya, pada data 2023 negara Georgia dengan nilai aktual US\$39.201, model dua hidden layer menghasilkan US\$51.826,94, model tiga hidden layer US\$47.137,83, sedangkan model empat hidden layer US\$43.781,07. Pada data 2024 Taipei, Chinese, model empat hidden layer menghasilkan US\$26.450,11, lebih dekat terhadap nilai aktual US\$35.599 dibandingkan dua model lainnya.

Tabel 4. Contoh hasil prediksi tiga arsitektur DNN

Tahun	Negara	Aktual	DNN 2 HL	DNN 3 HL	DNN 4 HL
2021	Singapore	1.814,00	707,04	1.686,56	912,80
2022	Ecuador	5.456,00	9.013,28	7.560,23	6.792,47
2022	Israel	9.175,00	18.730,78	7.553,93	9.420,45
2023	Georgia	39.201,00	51.826,94	47.137,83	43.781,07
2024	Taipei, Chinese	35.599,00	23.489,69	19.439,80	26.450,11

Temuan tersebut menunjukkan bahwa penambahan hidden layer tidak selalu memberikan peningkatan secara linear, tetapi pada dataset penelitian ini arsitektur empat hidden layer memberikan hasil baseline yang paling mendekati data aktual. Hal tersebut menjadi dasar pemilihan model empat hidden layer sebagai pembanding utama pada evaluasi akhir terhadap DNN-PSO.



Gambar 4. 5 Arsitektur model DNN-PSO

Gambar 4. Arsitektur DNN-PSO hasil optimasi



3.3 Hasil Optimasi PSO


Hasil optimasi selama 100 iterasi menghasilkan konfigurasi terbaik berupa 113 neuron pada hidden layer pertama, 46 neuron pada hidden layer kedua, 19 neuron pada hidden layer ketiga, dan learning rate 0,000896. Konfigurasi tersebut membentuk struktur yang lebih lebar pada lapisan awal kemudian semakin mengecil pada lapisan berikutnya. Nilai learning rate yang relatif kecil memberikan pembaruan bobot secara bertahap selama proses pelatihan.

Tabel 5. Konfigurasi terbaik hasil optimasi PSO

Parameter	Nilai terbaik
Hidden layer 1	113 neuron
Hidden layer 2	46 neuron
Hidden layer 3	19 neuron
Learning rate	0,000896
Best cost	0,020214736

3.4 Hasil Prediksi DNN-PSO

Model DNN-PSO dibangun menggunakan konfigurasi hasil optimasi dan kemudian digunakan pada data testing. Hasil prediksi menunjukkan kedekatan yang lebih baik terhadap nilai aktual pada beberapa sampel. Pada data 2021 Singapore, nilai aktual US\$1.814 dan prediksi DNN-PSO US\$1.758,99. Pada data 2023 Georgia, nilai aktual US\$39.201 dan prediksi US\$38.971,11. Pada data 2022 Israel, nilai aktual US\$9.175 dan prediksi US\$9.050,98. Sementara pada data 2024 Taipei, Chinese, model menghasilkan US\$32.800,96 dari nilai aktual US\$35.599.



Gambar 5. Perbandingan nilai aktual dan prediksi DNN-PSO

3.5 Evaluasi Kinerja DNN dan DNN-PSO


Evaluasi akhir difokuskan pada DNN empat hidden layer sebagai baseline terbaik dan DNN-PSO. Hasil menunjukkan bahwa DNN-PSO memberikan nilai error yang lebih kecil dan R^2 yang lebih tinggi. MSE DNN empat hidden layer sebesar 21.467.553,21 turun menjadi 1.703.856,56 pada DNN-PSO. MAE turun dari 3.242,41 menjadi 798,74. Sementara itu, R^2 meningkat dari 0,9145 menjadi 0,9932.



Tabel 6. Hasil evaluasi kinerja model

Model	MSE	MAE	R ²
DNN 4 hidden layer	21.467.553,21	3.242,41	0,9145
DNN-PSO	1.703.856,56	798,74	0,9932

Nilai MSE yang lebih rendah menunjukkan bahwa DNN-PSO lebih mampu mengurangi kesalahan kuadrat, terutama kesalahan yang besar. MAE sebesar 798,74 berarti rata-rata selisih absolut antara prediksi dan nilai aktual pada data evaluasi yang digunakan dalam perhitungan adalah sekitar US\$798,74. Nilai R² sebesar 0,9932 menunjukkan bahwa model mampu menjelaskan sekitar 99,32% variasi data aktual pada evaluasi yang dilaporkan dalam skripsi.

Gambar 6. Perbandingan MSE, MAE, dan R² antara DNN dan DNN-PSO

3.6 Perbandingan Kinerja dan Pembahasan

Perbandingan menunjukkan penurunan MSE sebesar 92,06%, penurunan MAE sebesar 75,36%, dan peningkatan R² sebesar 8,61%. Penurunan MSE merupakan indikator bahwa konfigurasi hasil PSO lebih mampu mengendalikan deviasi prediksi yang besar. Penurunan MAE menunjukkan bahwa rata-rata jarak absolut prediksi terhadap aktual menjadi lebih kecil. Peningkatan R² menunjukkan bahwa model DNN-PSO memiliki kemampuan yang lebih tinggi dalam menjelaskan variasi target dibandingkan baseline.

Hasil tersebut sejalan dengan penelitian terdahulu yang menunjukkan manfaat optimasi arsitektur DNN menggunakan pendekatan PSO. Pham et al. melaporkan peningkatan kinerja DNN setelah optimasi PSO [10], sedangkan Kurniawati menunjukkan bahwa PSO-DNN dapat menghasilkan akurasi lebih tinggi dibandingkan DNN standar pada tugas klasifikasi [6]. Penelitian Hosseini et al. juga menunjukkan bahwa optimasi arsitektur DNN dapat menurunkan error dan meningkatkan kualitas peramalan [5]. Perbedaan penelitian ini terletak pada objek yang digunakan, yaitu nilai ekspor kopi Indonesia, serta konfigurasi ruang pencarian yang diarahkan pada jumlah neuron dan learning rate.

3.7 Perbandingan Nilai Aktual dan Hasil Prediksi


Perbandingan langsung pada lima sampel testing memperlihatkan bahwa DNN-PSO cenderung lebih dekat dengan nilai aktual. Perbedaan paling terlihat pada data 2024 Taipei, Chinese. Nilai aktual sebesar US\$35.599 diprediksi DNN sebesar US\$26.450,11, sedangkan DNN-PSO menghasilkan US\$32.800,96. Dengan demikian, selisih DNN-PSO jauh lebih kecil. Temuan tersebut memperkuat hasil metrik evaluasi bahwa optimasi PSO membantu model mengikuti perubahan nilai ekspor dengan lebih baik.

Tabel 7. Perbandingan prediksi pada data testing

Tahun	Negara	Aktual	DNN 4 HL	DNN-PSO
2021	Singapore	1.814,00	912,80	1.759,00
2022	Ecuador	5.456,00	6.792,47	6.242,77



2022	Israel	9.175,00	9.420,45	9.050,98
2023	Georgia	39.201,00	43.781,07	38.971,11
2024	Taipei, Chinese	35.599,00	26.450,11	32.800,96



Gambar 7. Perbandingan nilai aktual, prediksi DNN, dan prediksi DNN-PSO

3.8 Kelebihan dan Keterbatasan

Kelebihan pendekatan yang digunakan adalah PSO dapat melakukan pencarian konfigurasi arsitektur secara otomatis berdasarkan fungsi fitness sehingga tidak sepenuhnya bergantung pada trial-and-error manual. Hasil penelitian juga menunjukkan peningkatan kinerja yang konsisten pada tiga metrik evaluasi utama. Namun, penelitian memiliki keterbatasan pada jumlah dan rentang waktu data, sehingga model DNN berpotensi membutuhkan data historis yang lebih panjang untuk mempelajari pola ekspor yang lebih kompleks. Variabel input juga masih terbatas pada Quantity, Unit Value, dan Growth in Value. Selain itu, penelitian hanya membandingkan DNN baseline dengan DNN-PSO sehingga belum dapat menyimpulkan keunggulan PSO terhadap seluruh metode optimasi lainnya.

4. KESIMPULAN

Penelitian menghasilkan tiga temuan utama. Pertama, dari tiga arsitektur DNN yang diuji, model empat hidden layer memberikan hasil baseline terbaik dan menjadi pembanding utama terhadap model hasil optimasi. Kedua, PSO menghasilkan konfigurasi optimal berupa 113, 46, dan 19 neuron pada tiga hidden layer dengan learning rate 0,000896 dan best cost 0,020214736. Ketiga, DNN-PSO memberikan MSE 1.703.856,56, MAE 798,74, dan R^2 0,9932. Dibandingkan DNN empat hidden layer, MSE turun 92,06%, MAE turun 75,36%, dan R^2 meningkat 8,61%. Berdasarkan hasil tersebut, optimasi PSO terbukti meningkatkan kinerja DNN pada data ekspor kopi yang digunakan dalam penelitian.

Penelitian selanjutnya disarankan menggunakan data historis yang lebih panjang dan mempertimbangkan variabel eksternal seperti kurs, produksi kopi nasional, inflasi, dan kondisi ekonomi global. Penelitian berikutnya juga dapat membandingkan PSO dengan metode optimasi lain, seperti Grey Wolf Optimizer, untuk mengetahui efektivitas relatif setiap pendekatan.



5. REFERENSI

- [1] I. Ardhanur, Martanto, Dikananda, A. R., and Mulyawan, "Analisis Prediksi Penjualan Tisu Menggunakan Regresi Linear," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 13, no. 2, pp. 739-746, 2025.
- [2] A. Atesongun and M. Gulsen, "A Hybrid Forecasting Structure Based on Arima and Artificial Neural Network Models," *Applied Sciences*, vol. 14, no. 16, 2024.
- [3] M. A. Azis, A. Fauzi, and I. Nawawi, "Klasifikasi Human Stress Menggunakan Adagrad Optimization untuk Arsitektur Deep Neural Network," *Jurnal Teknik Informatika Unika ST. Thomas*, vol. 7, no. 1, pp. 56-62, 2022.
- [4] A. Faisal and A. Subekti, "Deep Neural Network untuk Prediksi Stroke," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 7, no. 3, pp. 443-449, 2021.
- [5] E. Hosseini et al., "Optimized Deep Neural Network Architectures for Energy Consumption and PV Production Forecasting," *Energy Strategy Reviews*, vol. 59, p. 101704, 2025.
- [6] I. Kurniawati, "Deep Learning Model Based on Particle Swarm Optimization for Buzzer Detection," *Journal of Informatics Information System Software Engineering and Applications*, vol. 7, no. 1, pp. 22-32, 2024.
- [7] D. Liu, W. Ding, Z. S. Dong, and W. Pedrycz, "Optimizing Deep Neural Networks to Predict the Effect of Social Distancing on COVID-19 Spread," *Computers & Industrial Engineering*, vol. 166, p. 107970, 2022.
- [8] S. C. Nistor and G. Czibula, "IntelliSwAS: Optimizing Deep Neural Network Architectures Using a Particle Swarm-Based Approach," *Expert Systems with Applications*, vol. 187, p. 115945, 2022.
- [9] H. Y. Novita et al., "Pemodelan Prediksi Ekspor Kopi Indonesia Berbasis Algoritma Machine Learning," *Jurnal Media Informatika (JUMIN)*, vol. 6, no. 6, pp. 2848-2856, 2025.
- [10] T. A. Pham, V. Q. Tran, and H. L. T. Vu, "Evolution of Deep Neural Network Architecture Using Particle Swarm Optimization to Improve the Performance in Determining the Friction Angle of Soil," *Mathematical Problems in Engineering*, 2021.
- [11] W. Samek et al., "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247-278, 2021.