

OPTIMASI KLASIFIKASI JENIS INDUSTRI KECIL MENENGAH (IKM) MENGUNAKAN DEEP NEURAL NETWORK BERBASIS SHAP ANALYSIS

M. Fikri Haikal Ayatullah¹⁾, Desi Anggreani²⁾, Rizki Yusliana Bakti³⁾, Muhammad Faisal⁴⁾, Muhammad Syafaat⁵⁾, M. Agusalm⁶⁾

1. Informatika, Universitas Muhammadiyah Makassar
email: 105841105522@student.unismuh.ac.id
2. Informatika, Universitas Muhammadiyah Makassar
email: desianggreani@unismuh.ac.id
3. Informatika, Universitas Muhammadiyah Makassar
email: rizkiyusliana@unismuh.ac.id
4. Informatika, Universitas Muhammadiyah Makassar
email: muhfaisal@unismuh.ac.id
5. Teknik Sipil, Universitas Muhammadiyah Makassar
email: syafaat_skuba@unismuh.ac.id
6. Teknik Sipil, Universitas Muhammadiyah Makassar
email: m.agusalim@unismuh.ac.id

Abstract

Small and Medium Industries (SMEs) in Makassar City face a significant gap between high labor absorption (66.25%) and low GDP contribution (20%), often due to conventional and experience-based determination of industry types. This study implements a Deep Neural Network (DNN) model to classify four categories of SMEs, Bread and Cake, Processed Food, Vehicle Repair, and Textiles and Clothing to facilitate data-driven decisions. Using a supervised learning approach on 31,824 data samples for the 2022-2024 period, this model was developed through feedforward and backpropagation mechanisms. The results showed superior performance with overall accuracy of (93.99%) and balanced accuracy (96.70%), which signified an increase of (15.88%) compared to the Naïve Bayes baseline model. All F1-scores above (90%) indicate strong performance stability in each class. Furthermore, SHAP's analysis revealed that textual features (87.1%) were the dominant factors, followed by the type of business entity and investment value. This study confirms that DNN is effective in modeling complex non-linear interactions, providing objective tools for classification and strategic economic planning in Makassar City.

Kata Kunci: Deep Neural Network, IKM Classification, Deep Learning, SHAP Analysis, Makassar City.

A. PENDAHULUAN

Industri Kecil Menengah (IKM) memegang peranan strategis dalam pertumbuhan ekonomi di Kota Makassar, khususnya dalam penyerapan tenaga kerja dan peningkatan daya saing dalam industri lokal [1]. Berdasarkan data badan pusat statistik pada tahun 2022, sektor IKM menyerap 66,25 persen tenaga kerja pada sektor industri. Namun demikian, kontribusi sektor ini terhadap Produk Domestik Bruto (PDB) masih berada pada kisaran 20 persen [2]. Kondisi ini menunjukkan adanya ketidakseimbangan antara Tingkat penyerapan tenaga kerja dan kontribusi ekonomi yang dihasilkan. Berbagai faktor dapat mempengaruhi kondisi tersebut, salah satunya adalah karakteristik jenis industri yang dijalankan oleh pelaku usaha [3]. Pemilihan jenis industri yang kurang selaras dengan potensi sumber daya, lokasi serta kapasitas tenaga kerja berpotensi mempengaruhi efisiensi dan keberlanjutan usaha [4]. Dalam praktiknya, penentuan jenis industri oleh pelaku IKM masih banyak dilakukan secara konvensional dan berbasis pengalaman, sehingga berisiko menghasilkan keputusan yang kurang optimal [5].


Dampak dari ketidaksesuaian tersebut dapat berupa meningkatnya resiko kegagalan usaha serta kurang optimalnya pertumbuhan sektor industri di beberapa wilayah [6]. Penelitian sebelumnya [1] menunjukkan bahwa persebaran IKM belum merata, dimana sektor tertentu cenderung berfokus pada wilayah padat penduduk, sementara wilayah lain yang memiliki karakteristik dan sumber daya yang berbeda belum berkembang secara optimal. Temuan ini menunjukkan perlunya pendekatan analisis yang mampu mengklasifikasikan pola kesesuaian antara karakteristik usaha dan kategori industri secara lebih sistematis dan berbasis data [7].

Seiring dengan perkembangan teknologi kecerdasan buatan, pendekatan berbasis *machine learning* dan *deep learning* dapat dimanfaatkan untuk melakukan klasifikasi dan analisis pola secara objektif [8]. Beberapa penelitian sebelumnya telah menerapkan metode *machine learning* yakni *Naive Bayes* untuk klasifikasi pada lingkup IKM [9]. Oleh karena itu, penelitian ini secara spesifik berfokus pada penerapan metode *Deep Neural Network* yang memiliki *hidden layers* (arsitektur berlapis) serta kemampuan dalam memodelkan hubungan non-linear antar variabel [10].

Penelitian ini bertujuan menerapkan metode *Deep Neural Network* untuk mengklasifikasikan jenis industri di Kota Makassar dalam empat kategori, yaitu Roti dan kue, Makanan Olahan, Reparasi Kendaraan, serta Tekstil Pakaian). Selain itu, penelitian ini juga mengevaluasi kinerja model berdasarkan metrik evaluasi, presisi, *recall*, dan *F1-score* guna mengukur performa klasifikasi secara komprehensif [11].

B. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain *supervised learning* untuk membangun model klasifikasi berbasis *Deep Neural Network*. Objek penelitian berupa data industri kecil menengah Kota Makassar tahun 2022-2024 yang diperoleh dari dinas perindustrian dan perdagangan provinsi Sulawesi Selatan. Keseluruhan alur kerja penelitian ini, mulai dari pemuatan data hingga evaluasi model melalui diagram alur pada gambar 1.



Gambar 1. Flowchart Perancangan sistem

1. Pengumpulan dan Pemuatan Data

Tahap awal dimulai dengan pengumpulan data Industri Kecil Menengah Kota Makassar yang diperoleh dari dinas perindustrian dan perdagangan provinsi Sulawesi Selatan (format .xlsx).

Pada komputasi, dilakukan verifikasi dengan kelengkapan atribut dan konsistensi data untuk meminimalisir anomali yang dapat mempengaruhi hasil analisis. Berikut tahapan *preprocessing* data di paparkan pada tabel 1 sebagai berikut.

Tabel 1. Tahap *Preprocessing* data

Tahapan	Jumlah Data	Missing Value	Duplikasi
Data Awal	31.825	Ada (pada 5 kolom utama)	1 (header) + 1 baris

Setelah Hapus Missing	31.825	0	1
Setelah Hapus Duplikasi	31.824	0	0
Dataset Final	31.824	0	0

Dataset awal terdiri dari 31.825 baris dengan *missing value* yang tersebar di 5 kolom utama serta dua baris duplikasi. Pada tahap penanganan *missing value*, dilakukan imputasi menggunakan fitur numerik dan label untuk fitur kategorikal sehingga jumlah data tetap 31.825 baris. setelah itu, dilakukan penghapusan satu baris header duplikat sehingga jumlah data akhir menjadi 31.824 baris. *Dataset* akhir telah bersih dari *missing value* dan duplikasi, sehingga siap digunakan untuk proses selanjutnya.

2. Normalisasi Data

Data yang telah dimuat kemudian melalui proses normalisasi untuk menyelaraskan rentang nilai antar fitur numerik. Dalam konteks jaringan saraf tiruan, perbedaan skala antar variabel dapat menyebabkan dominasi fitur tertentu dan memperlambat proses konvergensi. Tahap ini bukan sekedar informasi matematis, melainkan upaya untuk menciptakan kondisi pembelajaran yang stabil sehingga model mampu menangkap pola secara lebih representatif dan tidak mengalami bias terhadap variabel dengan nilai numerik yang lebih kecil.

3. Pembagian Data

Setelah data berada dalam kondisi terstandarisasi, dataset dibagi menjadi data latih dan data uji dengan rasio 80:20. Pembagian dilakukan untuk mensimulasikan kondisi nyata dimana

model dihadapkan pada data baru yang belum pernah dipelajari sebelumnya. Data latih digunakan sebagai media pembelajaran bagi model untuk mengenali pola hubungan antar fitur dan kategori industri, sedangkan data uji berfungsi sebagai instrumen validasi untuk menilai sejauh mana pola tersebut dipahami oleh model.

4. Pelatihan dan Pembentukan Model

Tahap inti penelitian terletak pada proses pelatihan model *Deep Neural Network*. Pada fase ini, data pelatihan dialirkan ke dalam arsitektur jaringan yang terdiri atas lapisan *input*, lapisan tersembunyi yang terdiri dari 4 *hidden layer* (128-64-32-26 neuron), dan lapisan *output* yang menghasilkan probabilitas klasifikasi [12]. Melalui *feedforward*, dan *Backpropagation*, jaringan secara iteratif menyesuaikan bobot untuk meminimalkan kesalahan model.

5. Evaluasi Model

Model yang dilatih dievaluasi menggunakan data pengujian untuk mengukur kemampuan generalisasinya terhadap data yang tidak terlihat sebelumnya. Evaluasi utama dilakukan melalui Confusion Matrix untuk guna mengidentifikasi distribusi kesalahan klasifikasi pada setiap kelas, yang selanjutnya digunakan untuk menghitung metrik akurasi, *precision*, *recall*, dan *F1-score* sebagai indikator kinerja model [13]. Pendekatan ini memungkinkan penilaian tidak hanya berfokus pada tingkat ketepatan prediksi, tetapi juga pada konsistensi dan keseimbangan performa antar kelas. Selain metrik terkait, penelitian ini juga menggunakan *balanced accuracy* untuk mengevaluasi performa model tiap kelas secara adil. Rumus untuk menemukan *balanced accuracy* dipaparkan sebagai berikut.

$$\text{Balanced accuracy} = \frac{1}{k} \sum_{i=1}^k \frac{TP_i}{TP_i + FN_i} \quad [1]$$


Selain dari pemaparan evaluasi model terkait, Untuk meningkatkan transparansi model, penelitian ini juga menggunakan *Shapley Additive exPlanations (SHAP)* guna menganalisis kontribusi fitur terhadap keputusan klasifikasi. Selain itu, *Mean Squared Error (MSE)* digunakan sebagai evaluasi tambahan untuk mengukur rata-rata kesalahan secara numerik sekaligus mempertegas hasil daripada evaluasi model utama.

C. HASIL DAN PEMBAHASAN

Bagian ini mengimplementasikan alur analitis dalam mengklasifikasikan jenis Industri Kecil dan Menengah (IKM) Kota Makassar menggunakan *Deep Neural Network*, mulai dari pelatihan model hingga evaluasi dan interpretasi hasil. Kinerja model dianalisis melalui akurasi *training* dan *validation*, *confusion matrix*, metrik per kelas, *balanced accuracy*, serta *Mean Squared Error (MSE)*, dan diperkuat dengan *SHAP* untuk mengidentifikasi kontribusi fitur. Hasil yang disajikan menunjukkan bahwa model tidak hanya akurat, tetapi juga stabil dan seimbang antar kelas.

1. Hasil penelitian dan konvergensi

Tahap awal evaluasi dilakukan pada analisis dinamika proses pelatihan guna memastikan bahwa model mencapai kondisi konvergensi yang stabil tanpa ada indikasi *overfitting*. Model *Deep Neural Network (DNN)* dilatih selama 150 *epoch* dengan pemantauan akurasi *training* dan *validation* pada setiap fase pembelajaran. Perbandingan akurasi *training* dan *validation* selama proses pelatihan disajikan pada gambar 2.



Gambar 2. Perbandingan akurasi *training* dan *validation*

Gambar 2 secara visual menghasilkan peningkatan akurasi *training* dari (91,21%) pada *epoch* 50 menjadi (92%) pada *epoch* 100 dan pada *epoch* 150 akurasi *training* sempat turun menjadi (91,94%). Akurasi *validation* meningkat dari (93,86%) menjadi (94,11%) dan tetap konsisten hingga epoch 150.

Ringkasan perkembangan akurasi pada beberapa titik *epoch* utama (50, 100, dan 150) di ditampilkan pada tabel 2 berikut.

Tabel 2. Perbandingan akurasi *validation* *epoch* 50, 100, dan 150

Epoch	Training Accuracy	Validation Accuracy
50	91,21%	93,86%
100	92%	94,11%
150	91,94%	94,11%

Selisih kecil antara *training* dan *validation* mengindikasikan tidak terjadinya *overfitting* pada proses pelatihan model. Akurasi akhir data uji yang mencapai akurasi sebesar (93,99%) menegaskan kemampuan generalisasi model terhadap data yang tidak digunakan dalam proses pelatihan. Ringkasan akurasi pada model ditampilkan pada tabel 3 berikut.

Tabel 3. Detail akurasi *Deep Neural Network*

Metric	Value
Total Samples	4774
Total Correct	4487
Total Incorrect	287
Overall Accuracy	0.9399

Berdasarkan 4.774 sampel data uji, model berhasil mengklasifikasikan dengan benar sebanyak 4.487 data dan melakukan kesalahan pada 287 data. Hal ini menghasilkan nilai *overall accuracy* sebesar 0,9399 atau sebesar (93,99%). Secara kuantitatif, angka tersebut menunjukkan bahwa hampir 94 dari setiap 100 data berhasil di prediksi dengan tepat oleh model. Proporsi kesalahan sebesar (6,01%) yaitu 287 dari 4.774 data tergolong rendah dalam konteks klasifikasi, yang mengindikasikan kemampuan generalisasi model yang baik terhadap data yang tidak digunakan selama proses pelatihan.

2. Evaluasi model klasifikasi

Untuk memastikan performa model tidak hanya tinggi secara global tetapi juga merata pada setiap kategori, dilakukan evaluasi menggunakan confusion matrix serta metrik *precision*, *recall*, dan *F1-score* per kelas. Distribusi metrik evaluasi pada masing masing kelas dipaparkan pada tabel 4.


Tabel 4. Metrik evaluasi per kelas

Kelas	Precision	Recall	F1-Score	Accuracy
Makanan Olahan	99,72 %	90,65 %	94,97 %	94,45 %
Reparasi	85,35 %	99,50 %	91,88 %	97,78 %

Kendaraan				
Roti & Kue	91,95 %	1.00%	95,8 1%	98,8 3%
Tekstil & Pakai an				
l & Pakai an	86,03 %	96,63%	91,0 2%	96,9 2%

Berdasarkan metrik evaluasi per kelas, model menunjukkan performa yang konsisten dengan seluruh *F1-score* berada diatas (90%). Pada kelas makanan olahan, *precision* tinggi (99,72%) menandakan kesalahan prediksi positif sangat rendah, meskipun *recall* (90,65%) menunjukkan masih terdapat sebagian kecil data yang tidak terdeteksi. Pada kelas reparasi kendaraan, *recall* yang tinggi (99,50%) mengindikasikan sensitifitas model yang sangat baik, meskipun *precision* lebih rendah (85,35%) menandakan adanya sejumlah *false positive*

Kelas roti dan kue menunjukkan *recall* sempurna (100%) yang berarti tidak terdapat *false negative*, dengan *F1-score* (95,81%) dan akurasi (98,83%) sebagai salah satu performa terbaik. Sementara itu, tekstil dan pakaian memiliki keseimbangan yang baik antara *precision* (86,03%) dan *recall* (96,63%) dengan *F1-score* (91,02%).




Gambar 3. Confusion Matrix

Visualisasi Confusion Matrix menunjukkan distribusi prediksi model terhadap 4.774 data uji dengan *balance accuracy* sebesar (96,70%). Nilai dominan pada diagonal utama (2.502 untuk makanan olahan, 600 untuk reparasi kendaraan, 640 untuk roti dan kue, dan 745 untuk tekstil dan pakaian) menandakan mayoritas data berhasil diklasifikasikan dengan benar.

3. Evaluasi propabilistik tambahan (*Mean Squared Error*)

Selain metrik klasifikasi diskrit, evaluasi tambahan menggunakan *Mean Squared Error (MSE)* terhadap propabilitas keluaran *softmax*. Pendekatan ini memberikan gambaran mengenai kedekatan distribusi propabilitas prediksi terhadap label sebenarnya serta stabilitas proses pembelajaran.



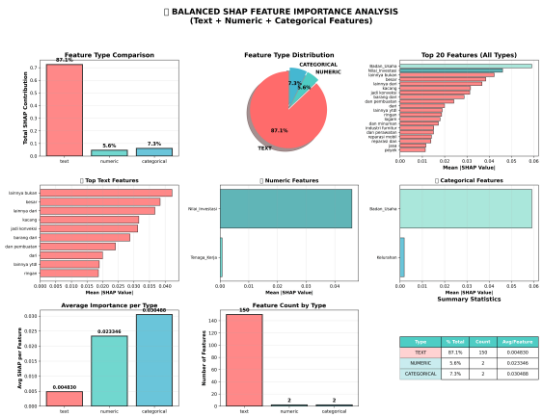
Gambar 4. Grafik Mean Squared Error (MSE)

Visualisasi *Mean Squared Error (MSE)* dimana kurva training dan validation menunjukkan penurunan tajam di awal *epoch*, yang menandakan proses pembelajaran berjalan efektif dan menyesuaikan bobot model. Setelah *epoch* ke 50, kurva cenderung melandai dan stabil hingga akhir pelatihan. Nilai akhir training *Mean Squared Error (MSE)* sebesar (0,0610) dan validation *Mean Squared Error (MSE)* sebesar (0,0360) yang rendah dan konsisten

mengindikasikan propabilitas prediksi model mendekati label aktual.

4. Interpretasi model menggunakan SHAP

untuk mengurangi sifat *black-box* pada arsitektur *deep learning*. Dilakukan analisis interpretabilitas menggunakan *SHAP* (*Shapley Additive exPlanations*). Pendekatan ini memungkinkan klasifikasi mengidentifikasi kontribusi setiap fitur terhadap keputusan klasifikasi serta memberikan transparansi terhadap mekanisme internal model.



Gambar 5. Hasil analisis SHAP

Visualisasi diatas menunjukkan analisis *SHAP Feature Importance* yang menggabungkan fitur teks, numerik, dan kategorikal dalam model, terlihat bahwa fitur teks dominan dengan kontribusi total (87,1%) jauh lebih besar dibandingkan fitur kategorikal (7,3%) dan numerik (5,6%). Meskipun jumlah fitur teks paling banyak 150 fitur, rata-rata kontribusi perfiturnya justru paling kecil, sedangkan fitur kategorikal memiliki rata-rata pengaruh per fitur paling tinggi. Detail hasil visualisasi terbut dipaparkan pada tabel 5.

Tabel 5. Fitur hasil analisis SHAP

Feature Name	Feature Group	Feature Type	SHAP Importance
Badan Usaha	Badan Usaha (Entity)	categorical	0.059079885
Nilai Investasi	Investasi (Investment)	numerical	0.045964359
lainnya bukan	TF-IDF (Text)	text	0.042232421
besar	TF-IDF (Text)	text	0.038446421
lainnya dari	TF-IDF (Text)	text	0.036761362

Berdasarkan nilai *SHAP Importance*, fitur *Badan_usaha* memiliki kontribusi tertinggi dalam model untuk kontribusi pengaruh per fitur diikuti oleh nilai investasi, yang menunjukkan bahwa karakteristik entitas dan skala modal menjadi faktor penting dalam klasifikasi.

5. Perbandingan Model dengan Baseline


Sebagai pembanding pengujian efektivitas arsitektur *Deep Neural Network* (*DNN*), penelitian ini menggunakan metode *Naïve Bayes* sebagai model *baseline*. Perbandingan kinerja *Deep Neural Network* dan *Naïve Bayes* disajikan pada tabel 6 berikut.

Tabel 6. Perbandingan kinerja Model


Model	Accuracy	Balanced Accuracy
Deep Neural Network	78,11%	86,16%
Naïve Bayes	93,99%	96,70%

Selisih	+15,88%	+10,54%
---------	---------	---------

Berdasarkan hasil tersebut, *Deep Neural Network (DNN)* menunjukkan peningkatan akurasi sebesar (15,88%) dibandingkan dengan metode *baseline (Naïve Bayes)*. Pada *balanced accuracy*, peningkatan diperoleh sebesar (10,54%) yang menunjukkan peningkatan performa tidak hanya terjadi secara global, tetapi juga konsisten pada distribusi sensitivitas antar kelas.



Gambar 6. Perbandingan akurasi dan balanced accuracy model



Gambar 7. Peningkatan performa model

Berdasarkan visualisasi tersebut, terlihat bahwa *Deep Neural Network* secara konsisten berada diatas *Naïve Bayes*. *Naïve Bayes* memperoleh akurasi sebesar (78,11%) dan *balanced accuracy* sebesar (86,16%), sedangkan *Deep Neural Network* mencapai akurasi sebesar (93,99%) dan *balanced accuracy* sebesar (96,70%). Peningkatan sebesar (+15,88%) dan (+10,54) pada *balanced accuracy*.

D. KESIMPULAN DAN SARAN

Penelitian ini berhasil menerapkan *Deep Neural Network (DNN)* untuk mengklasifikasikan jenis IKM Kota Makassar dengan akurasi (93,99%) dan *balanced accuracy* (96,70%), serta seluruh *F1-score* berada diatas (90%). Hasil ini menunjukkan model mampu menggeneralisasi data dengan baik dan menjaga keseimbangan performa antar kelas. Analisis *SHAP* mengungkapkan bahwa fitur teks menjadi faktor dominan dalam proses klasifikasi disusul fitur kategorikal dan numerik seperti badan usaha dan nilai investasi. Dibandingkan dengan metode *Naïve Bayes*, *Deep Neural Network* memberikan peningkatan akurasi sebesar (+15,88%) membuktikan kemampuan model menangkap hubungan non-linear antar fitur.

E. REFERENSI

- [1] N. M. Esta, D. S. J. Samudra, and M. Yasin, "Analisis Pola Spasial Industri Kecil Menengah (Ikm) Dan Industri Rumah Tangga (Irt) Di Kabupaten Dan Kota," J. Ilm. Ekon. Dan Manaj., vol. 3, no. 4, pp. 55–66, 2025, doi: 10.61722/jiem.v3i4.4380.
- [2] T. Darmawati and Y. Arafat, "Model Produktivitas Tenaga Kerja dan Daya Saing Industri Mikro Kecil Serta Implementasinya Dalam Mendukung Pertumbuhan Ekonomi di Indonesia," Jurnal Ekonomi, pp. 384–395, 2022.
- [3] K. N. Reihanah, D. A. I. Maruddani, and T. Widiharhi, "CLUSTERING KARAKTERISTIK INDUSTRI KECIL DAN MENENGAH DI KOTA KENDARI MENGGUNAKAN ALGORITMA k-PROTOTYPES," J. Gaussian, vol. 12, no. 3, pp. 340–351, 2024, doi:

- 10.14710/j.gauss.12.3.340-351.
- [4] N. Alfarisi and F. D. Sitania, "Sinkronisasi Data Terhadap Industri Kecil Menengah (IKM) Pada Dinas Perindustrian, Perdagangan, Koperasi, Dan IKM Provinsi Kalimantan Timur," *J. Tek. Ind.*, vol. 2, no. 1, pp. 63–70, 2024, doi: 10.30872/jatri.v2i1.1234.
- [5] M. Kiron, M. Islam, and E. Chowdhury, "Green Technologies and Sustainability Enhancing small and medium-sized enterprises ' sustainability in global value chains : The impact of multinational corporations on Bangladesh ' s garment industry," *Green Technol. Sustain.*, vol. 4, no. 1, p. 100265, 2026, doi: 10.1016/j.grets.2025.100265.
- [6] D. Baez *et al.*, "ScienceDirect ScienceDirect Enterprises : Case of the Bakery Industry in Colombia Analysis of Strategic Marketing in Small and Medium-sized of the Bakery Industry in Colombia Harold Enterprises : Analysis of Strategic Marketing in Small and Medium-sized," *Procedia Comput. Sci.*, vol. 231, pp. 601–606, 2024, doi: 10.1016/j.procs.2023.12.178.
- [7] Yusniati, W. Aya Rumbia, and L. Pipi, "Pengaruh Karakteristik Industri Kecil Menengah Terhadap Keuntungan Usaha di Kabupaten Konawe," *J. Prog. Ekon. Pembang.*, vol. 9, no. 2, pp. 128–138, 2024, doi: 10.33772/jpep.v9i2.790.
- [8] M. Naved, M. Asim, and T. Ahmad, "Prediction of concrete compressive strength using deep neural networks based on hyperparameter optimization," *Cogent Eng.*, vol. 11, no. 1, p., 2024, doi: 10.1080/23311916.2023.2297491.
- [9] M. Chintya Adelina and Z. Situmorang, "Machine Learning for Classification of Ikm Programs At the Department of Industry and Trade of Langkat Regency," vol. 02, no. 01, pp. 1649–1656, 2024.
- [10] G. Gunawan, A. Aimar Akbar, and W. Andriani, "Application of deep neural network with stacked denoising autoencoder for ECG signal classification," *J. Intell. Decis. Support Syst.*, vol. 7, no. 2, pp. 173–187, 2024, doi: 10.35335/idss.v7i2.247.
- [11] L. Zancato and A. Chiuso, "A novel deep neural network architecture for non-linear system identification," *IFAC-PapersOnLine*, vol. 54, no. 7, pp. 186–191, 2021, doi: 10.1016/j.ifacol.2021.08.356.
- [12] D. Arya Pamungkas, I. Lucia Kharisma, D. Sartika Simatupang, and kamdan, "Implementasi Deep Neural Network pada Perancangan Aplikasi Deteksi Token Scam Blockchain Ethereum," *Sist. J. Sist. Inf.*, vol. 12, no. 3, pp. 927–937, 2023, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [13] Z. C. Dwinnie, L. Khairani, M. A. M. Putri, J. Adhiva, and M. I. F. Tsamarah, "Application of the Supervised Learning Algorithm for Classification of Pregnancy Risk Levels," *Public Res. J. Eng. Data Technol. Comput. Sci.*, vol. 1, no. 1, pp. 26–33, 2023, doi: 10.57152/predatecs.v1i1.806.