

PREDIKSI TINGKAT OBESITAS MENGGUNAKAN NEURAL NETWORK: PENDEKATAN KLASIFIKASI BINER

Prediction of Obesity Levels Using Neural Network: Binary Classification Approach

Desy Nur Fitriani¹, Saiful Bahri²

¹Program Studi Matematika, FST UIN Sunan Ampel Surabaya

²Program Studi Biologi, FST UIN Sunan Ampel Surabaya

*e-mail: *desynf34@mail.com*

Abstrak

Penelitian ini bertujuan untuk mengembangkan model prediktif menggunakan jaringan saraf tiruan (*neural network*) dalam memprediksi tingkat obesitas pada individu berdasarkan atribut terkait kebiasaan makan dan kondisi fisik dari individu negara-negara Meksiko, Peru, dan Kolombia. Pendekatan klasifikasi biner digunakan untuk membedakan antara individu yang termasuk dalam kategori obesitas dan tidak obesitas. Metode pelatihan jaringan saraf tiruan dilakukan dengan menggunakan dataset yang telah diklasifikasikan sebelumnya. Pemodelan dilakukan dengan membagi dataset menjadi data pelatihan dan data uji yaitu 70:30. Selanjutnya, jaringan saraf tiruan diadaptasi dan disesuaikan dengan fitur-fitur yang relevan dalam menentukan tingkat obesitas. Kinerja model dievaluasi menggunakan metrik evaluasi standar seperti akurasi, presisi, recall, dan F1-score. Dan mendapatkan hasil *Accuracy*: 0.9684, *Loss*: 0.1061, *Presisi*: 0.9669, *Recall*: 0.9915, dan *F1-Score*: 0.9791.

Kata Kunci: Klasifikasi Biner, Neural Network, Obesitas, Prediksi.

Abstract

This research aims to develop a predictive model using neural network technology to forecast the obesity levels in individuals based on attributes related to eating habits and physical conditions of individuals from Mexico, Peru, and Colombia. A binary classification approach is employed to distinguish individuals falling into the categories of obesity and non-obesity. The training of the neural network model is executed using a pre-classified dataset. The dataset is partitioned into training and testing data in a ratio of 70:30. Subsequently, the neural network is adapted and tailored to pertinent features in determining obesity levels. The model's performance is assessed using standard evaluation metrics such as accuracy, precision, recall, and F1-score. The outcomes reveal Accuracy: 0.9684, Loss: 0.1061, Precision: 0.9669, Recall: 0.9915, and F1-Score: 0.9791.

Keywords: Binary Classification, Neural Network, Obesity, Prediction.



This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

1. PENDAHULUAN

Obesitas adalah kondisi medis yang terjadi ketika tubuh mengalami penumpukan lemak secara berlebihan sehingga dapat berdampak negatif pada kesehatan seseorang. Ini umumnya diukur menggunakan indeks massa tubuh (BMI), yang mempertimbangkan berat dan tinggi seseorang. Obesitas terjadi ketika seseorang memiliki BMI 30 atau lebih. Penyebab utama obesitas melibatkan ketidakseimbangan antara asupan kalori yang dikonsumsi dan energi yang dibakar tubuh. Faktor-faktor seperti pola makan yang tidak sehat, kurangnya aktivitas fisik, genetika, lingkungan, serta faktor psikologis dapat berperan dalam perkembangan obesitas[1]. Masalah obesitas telah menjadi perhatian global karena dampaknya yang signifikan pada kesehatan masyarakat. Menurut Organisasi Kesehatan Dunia (WHO), tingkat obesitas telah meningkat secara dramatis dalam beberapa dekade terakhir di seluruh dunia. Obesitas terkait erat dengan berbagai penyakit serius seperti diabetes tipe 2, penyakit jantung, dan masalah kesehatan lainnya[2]. Oleh karena itu, memahami dan memprediksi tingkat obesitas menjadi krusial dalam upaya pencegahan dan penanganan masalah kesehatan ini. Data mengenai kebiasaan makan, aktivitas fisik, dan faktor-faktor lainnya yang terkait dengan tingkat obesitas pada populasi tertentu dapat menjadi landasan penting untuk pengembangan solusi yang efektif[3]. Dalam upaya untuk memahami dan mengidentifikasi faktor-faktor yang memengaruhi tingkat obesitas, penelitian ini menggunakan pendekatan jaringan saraf tiruan untuk melakukan prediksi klasifikasi biner terhadap tingkat obesitas pada individu. Klasifikasi biner adalah teknik dalam pembelajaran mesin yang digunakan untuk memprediksi atau mengkategorikan data menjadi dua kelas atau kategori yang berbeda[4]. Dalam klasifikasi biner, tujuannya adalah untuk mengklasifikasikan *instance* (data point) ke dalam salah satu dari dua kelas yang telah ditentukan sebelumnya. Metode ini diimplementasikan dengan menggunakan teknik pembelajaran mendalam untuk mengkategorikan tingkat obesitas menjadi dua kelas utama: "Tidak Obesitas" dan "Obesitas".

Beberapa peneliti sebelumnya telah melakukan prediksi tingkat obesitas menggunakan beberapa metode diantaranya, oleh Yoris dkk. dengan judul "Application of Adaptive Synthetic Nominal and Extreme Gradient Boosting Methods in Determining Factors Affecting Obesity: A Case Study of Indonesian Basic Health Research Survey 2013" pada tahun 2022[5], juga oleh Taufik dan Lestari "Klasifikasi Tipe Berat Tubuh Menggunakan Metode Support Vector Machine" pada tahun 2023[6], di tahun yang sama dilakukan oleh Uswatun dan Ade dengan judul "Prediksi Persentase Body Fat Menggunakan Algoritma CART dan M5"[7] dan juga dilakukan oleh Riski dkk. "Survey Obesitas Anak Usia Dini Menggunakan Machine Learning Selama Pandemi COVID 19 di Kota Medan"[8]. Berdasarkan hal tersebut dapat diketahui penggunaan ilmu komputer dapat mempermudah dalam menganalisis data obesitas dengan baik.

Neural Network (Jaringan saraf tiruan) adalah model matematis yang terinspirasi dari struktur dan fungsi jaringan saraf biologis manusia. Ini adalah jenis dari sistem pembelajaran mesin yang terdiri dari jaringan simpul (*neuron*) buatan yang saling terhubung. Jaringan saraf tiruan terdiri dari lapisan-lapisan neuron yang berkomunikasi satu sama lain. Informasi masukan diterima oleh neuron di lapisan masukan (*input layer*), kemudian diteruskan melalui lapisan-lapisan tersembunyi (*hidden layers*), diolah melalui serangkaian kalkulasi matematis, dan akhirnya memberikan keluaran di lapisan keluaran (*output layer*). Setiap neuron dalam jaringan saraf memiliki bobot yang

menentukan seberapa pentingnya masukan tersebut dalam pengambilan keputusan. Selama proses pelatihan (*training*), jaringan saraf akan memperbarui dan menyesuaikan bobot-bobot ini berdasarkan data yang disediakan sehingga menghasilkan keluaran yang diinginkan atau mendekati solusi yang benar[9]. Jaringan saraf tiruan memiliki kemampuan untuk mempelajari pola-pola kompleks dalam data, sehingga digunakan dalam berbagai aplikasi seperti pengenalan pola, klasifikasi, prediksi, pengenalan gambar, pemrosesan bahasa alami, dan banyak lagi. Keunggulan utama dari jaringan saraf tiruan adalah kemampuannya untuk menangani masalah-masalah yang sulit didefinisikan dengan baik atau memiliki struktur yang kompleks[4]. Penggunaan *Neural Network* telah banyak dilakukan dalam menganalisis data seperti analisis geospasial kasus Stunting[10], prediksi Jantung Koroner[11], klasifikasi paket jaringan[12], prediksi kasus balita Gizi buruk[13], prediksi dan analisa penyakit Diabetes Metitus[14], dari beberapa penelitian tersebut terlihat bahwa penggunaan Neural Network memiliki hasil yang baik.

Dengan adanya penelitian ini diharapkan masalah obesitas dapat diminimalisir dengan mengurangi kebiasaan yang dapat mengakibatkan terjadinya obesitas di usia dini. Dimana pada penelitian ini akan dijelaskan faktor apa saja yang dapat mempengaruhi terjadinya obesitas. Dan bagaimana hasil prediksi menggunakan model jaringan saraf tiruan pada penelitian dapat menghasilkan hasil yang baik dalam menganalisis tingkat obesitas.

2. METODE PENELITIAN

2.1. Tipe Penelitian

Penelitian yang di gunakan adalah tipe penelitian studi kasus, yaitu dengan mendalami penggunaan model *neural network* untuk mengidentifikasi pola-pola terkait obesitas pada kasus-kasus tertentu. Sehingga dapat melibatkan analisis mendalam terhadap individu atau kelompok yang memiliki masalah obesitas dan menggunakan model untuk memahami variabel-variabel yang memengaruhi kondisi tersebut. Pada studi kasus ini digunakan analisis klasifikasi biner dalam mengkategorikan variabel target. Sehingga dari 7 kelas kategori yang telah ditentukan, akan diolah menjadi 2 kategori saja. Sehingga akan didapat kategori 0 (Tidak Obesitas) dan 1 (Obesitas).

2.2. Data dan Variabel Penelitian

Data yang digunakan adalah dataset tingkat obesitas yang dapat diakses melalui website <https://archive.ics.uci.edu/> dan dapat di unduh melalui url [Tingkat Obesitas](#). Pada dataset yang digunakan berisi data untuk estimasi tingkat obesitas pada individu dari negara-negara Meksiko, Peru, dan Kolombia, berdasarkan kebiasaan makan dan kondisi fisik mereka. Data tersebut terdiri dari 17 atribut dan 2111 catatan, yang dilabeli dengan variabel kelas *NObesity* (Tingkat Obesitas), yang memungkinkan klasifikasi data menggunakan nilai *Insufficient Weight*, *Normal Weight*, *Overweight Level I*, *Overweight Level II*, *Obesity Type I*, *Obesity Type II*, dan *Obesity Type III*. Sebanyak 77% dari data dihasilkan secara sintesis menggunakan alat Weka dan filter SMOTE, sementara 23% dari data tersebut dikumpulkan langsung dari pengguna melalui platform web. Adapun faktor-faktor yang mempengaruhi tingkat obesitas akan dijadikan sebagai variabel input dapat dilihat pada **Tabel 1**. berikut ini.

Tabel 1. Variabel yang Mempengaruhi Obesitas

Faktor yang dinilai	Tipe data	Faktor yang dinilai	Tipe data
Frequent consumption of high caloric food (FAVC)	Kategorik	Physical activity frequency (FAF)	Numerik
Frequency of consumption of vegetables (FCVC)	Numerik	Time using technology devices (TUE)	Numerik
Number of main meals (NCP)	Numerik	Transportation used (MTRANS)	Kategorik
Consumption of food between meals (CAEC)	Kategorik	Family History With Overweight	Kategorik
Consumption of water daily (CH20)	Kategorik	Age	Numerik
Consumption of alcohol (CALC)	Kategorik	Height	Numerik
Calories consumption monitoring (SCC)	Kategorik	Weight	Numerik
Smoke	Kategorik	Gender	Kategorik

Dapat terlihat bahwa pada dataset tingkat obesitas memiliki beberapa variabel bersifat kategorik, sehingga diperlukan proses untuk mengubah data yang bersifat kategorik menjadi matriks dengan tipe data biner.

2.3. Analisis Model

Pada *Neural Network* (jaringan saraf tiruan) melibatkan konsep-konsep dari berbagai bidang seperti matematika, statistik, dan neurosains. Di bawah ini adalah beberapa landasan teori yang relevan untuk pemahaman tentang jaringan saraf tiruan:[9].

- 2.3.1. **Teori Matematika dan Aljabar Linear:** Jaringan saraf tiruan bergantung pada operasi matematika seperti perkalian matriks, penjumlahan vektor, fungsi aktivasi, dan optimisasi. Konsep-konsep ini membentuk dasar operasi jaringan saraf dan memungkinkan pengembangan algoritma pembelajaran yang efektif.
- 2.3.2. **Fungsi Aktivasi:** Dalam setiap neuron, terdapat fungsi aktivasi yang mengubah masukan (*input*) menjadi keluaran (*output*). Fungsi ini bisa berupa fungsi sigmoid, ReLU (*Rectified Linear Unit*), tangen hiperbolik, atau fungsi lainnya. Pemilihan fungsi aktivasi ini memiliki dampak pada perilaku dan kinerja jaringan.
- 2.3.3. **Algoritma Pembelajaran:** Landasan teori termasuk algoritma pembelajaran seperti backpropagation, yang digunakan untuk mengatur bobot-bobot (*weights*) dalam jaringan agar jaringan mampu belajar dari data yang diberikan. Ini adalah dasar dari proses pelatihan (*training*) jaringan saraf.
- 2.3.4. **Optimisasi dan Pengaturan Hyperparameter:** Pengoptimalan bobot dan hyperparameter (seperti learning rate, jumlah neuron dalam lapisan tersembunyi, dll.) adalah bagian penting dari landasan teori. Ini melibatkan strategi untuk menemukan konfigurasi yang optimal agar jaringan dapat

belajar dengan cepat dan memberikan hasil yang baik.

2.3.5. **Teori Graf dan Struktur Jaringan:** Struktur jaringan saraf tiruan, termasuk jumlah lapisan, jumlah neuron dalam setiap lapisan, dan bagaimana neuronnya terhubung, seringkali didasarkan pada prinsip-prinsip dari teori graf. Struktur jaringan yang tepat dapat sangat mempengaruhi kemampuan jaringan dalam memodelkan pola-pola data yang rumit.

2.3.6. **Teori Pembelajaran Mesin (*Machine Learning*):** Landasan teori dalam machine learning, termasuk konsep seperti *overfitting*, *underfitting*, *generalisasi*, dan *validasi model*, penting untuk memahami bagaimana jaringan saraf tiruan diterapkan dalam konteks pembelajaran mesin.

Memahami landasan teori ini penting untuk mengembangkan, melatih, dan menganalisis jaringan saraf tiruan dengan tepat serta menginterpretasikan hasil yang dihasilkan oleh model tersebut.

3. HASIL DAN PEMBAHASAN

Variabel target dikategorikan dari 7 kelas menjadi 2 kelas kategori dengan tipe interger 0 dan 1. Kemudian semua data dibagi menjadi data train dan data test dengan perbandingan 70:30. Setelah didapatkan data train dan data test, lakukan juga pembagian data train dan test untuk tiap variabel target dan variabel input. Dimana data train digunakan dalam pembuatan model dan data test digunakan untuk mengevaluasi model. Data yang telah diproses akan uji menggunakan model *Neural Network* dengan bantuan *software* R-Studio.


Dari data yang telah dibagi dilakukan pemodelan klasifikasi biner dengan dua hidden layer dimana terdapat dua lapisan dense tersembunyi yang diikuti oleh lapisan output dengan fungsi aktivasi sigmoid. Dropout diterapkan untuk mengurangi *overfitting*, dan ReLU dipilih sebagai fungsi aktivasi pada lapisan tersembunyi karena kinerjanya yang baik dalam banyak kasus. Fungsi sigmoid dan ReLU memiliki formula matematis sebagai berikut:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (1)$$

$$f(x) = \max(0, x) \quad (2)$$

Pada **Persamaan (1)**, $\sigma(x)$ adalah nilai keluaran (*output*) dari fungsi sigmoid untuk masukan x . Fungsi ini mengubah setiap nilai masukan menjadi rentang antara 0 dan 1, sehingga berguna untuk masalah klasifikasi biner di mana output diinginkan berada pada rentang probabilitas antara dua kelas. Sedangkan pada **Persamaan (2)**, $f(x)$ adalah nilai keluaran (*output*) dari fungsi ReLU untuk masukan x . Fungsi ReLU mengembalikan nilai masukan jika nilai tersebut positif, dan mengembalikan 0 jika nilai masukan negatif. Hal ini memberikan kelebihan dalam mengatasi masalah gradien yang menghilang (*vanishing gradient problem*) dan meningkatkan kecepatan pelatihan dalam beberapa arsitektur jaringan saraf. Kedua fungsi aktivasi ini sangat penting dalam jaringan saraf, karena mereka menentukan apakah neuron-neuron dalam jaringan harus diaktifkan atau tidak, dan berkontribusi pada kemampuan jaringan untuk mempelajari representasi yang kompleks dari data[4].

Dari hasil pelatihan model yang telah dilakukan didapat hasil plotting epochs sebanyak 200 unit seperti pada **Gambar 1**. Dimana akan terlihat pergerakan dari data training dan data validation.



Gambar 1. Plot Accuracy dan Loss pada Data Training dan Validation

Berdasarkan hasil dari model pelatihan yang telah dilakukan didapatkan hasil prediksi yang baik dengan nilai akurasi hingga 1.0000 dan nilai loss 0.0016 pada epoch ke-200. Setelah melakukan pelatihan model perlu dilakukan evaluasi model tersebut dengan menggunakan data test. Hasil evaluasi data test didapatkan nilai akurasi sebesar 0.9684044 dan nilai loss 0.1061748, nilai ini tergolong nilai yang baik.

Prediksi model yang telah dilakukan dengan memanfaatkan fungsi *predict*. Kemudian bandingkan hasil dari nilai prediksi dengan nilai kategori sesungguhnya menggunakan fungsi *confusionMatrix*, dimana akan didapatkan tabel kebingungan dan hasil overall statistika untuk mengetahui seberapa baik model prediksi yang dilakukan. Pada hasil keluaran didapat nilai akurasi terhadap prediksi model sebesar 0.9684 dimana hasil ini dilai sangat baik pada keseluruhan prediksi. Didapatkan juga nilai kappa sekitar 0.9146, menunjukkan ada kesesuaian yang baik antara hasil prediksi dan nilai sebenarnya. Berikut ditampilkan pada **Tabel 2.** hasil matrix yang didapat.

Tabel 2. Confusion Matrix

	Prediksi 0	Prediksi 1
Kelas 0	TN = 145	FP = 16
Kelas 1	FN = 4	TP = 468

Dari hasil **Tabel 2.** didapatkan nilai TN, FP, FN, dan TP dimana melalui nilai tersebut dapat dilakukan uji evaluasi metrik lainnya seperti presisi, recall, dan f1-score untuk mengevaluasi kinerja model klasifikasi terhadap dataset yang digunakan.

$$\text{Presisi} = \frac{TP}{TP+FP} = \frac{468}{468+16} = 0,9669 \tag{3}$$

$$\text{Recall} = \frac{TP}{TP+FN} = \frac{468}{468+4} = 0,9915 \tag{4}$$

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} = 2 \times \frac{0,9669 \times 0,9915}{0,9669 + 0,9915} = 0,979 \tag{5}$$

Berdasarkan **Persamaan (3)**, hasil presisi menunjukkan bahwa ketika model memprediksi positif, prediksi tersebut cenderung benar. Pada **Persamaan (4)**, hasil recall

menunjukkan bahwa model cenderung menemukan sebagian besar kasus yang sebenarnya positif. Dan **Persamaan (5)**, hasil f1-score menunjukkan bahwa model memiliki presisi dan recall yang baik secara bersamaan[15]. Hal ini membuktikan bahwa model yang kita lakukan dapat memberikan hasil prediksi yang sangat bagus.

4. KESIMPULAN

Model klasifikasi yang dikembangkan untuk memprediksi tingkat obesitas telah dievaluasi menggunakan sejumlah metrik evaluasi yang penting. Berikut adalah hasil evaluasi:

- **Akurasi:** Model menunjukkan tingkat akurasi sebesar 96.84%. Ini menunjukkan seberapa baik model dapat memprediksi secara keseluruhan.
- **Presisi:** Presisi model untuk kelas positif (obesitas) adalah 90.06%. Ini menunjukkan seberapa akurat model dalam mengidentifikasi kasus obesitas dari total prediksi obesitas yang dilakukan oleh model.
- **Recall:** Recall atau sensitivitas model adalah 97.32%. Ini menunjukkan seberapa baik model dapat menemukan semua kasus yang sebenarnya obesitas dari keseluruhan kasus obesitas yang ada.
- **F1-Score:** F1-score model adalah sekitar 93.58%. Ini adalah rata-rata harmonik dari presisi dan recall, yang memberikan ukuran seimbang dari kinerja keseluruhan model.

Dari hasil evaluasi tersebut, dapat disimpulkan bahwa model memiliki kinerja yang baik dalam mengidentifikasi kasus obesitas. Meskipun akurasi secara keseluruhan cukup tinggi, penting untuk memperhatikan presisi dan recall, terutama dalam konteks medis di mana mengidentifikasi kasus obesitas dengan benar sangat penting. Nilai presisi yang tinggi menunjukkan bahwa sebagian besar prediksi yang diberikan model untuk kasus obesitas benar, sementara nilai recall yang tinggi menunjukkan bahwa sebagian besar kasus obesitas yang sebenarnya berhasil diidentifikasi oleh model.

Model ini mungkin dapat diandalkan dalam mendukung upaya pencegahan dan manajemen obesitas, tetapi tetap perlu dilakukan evaluasi lebih lanjut terutama dalam mengurangi risiko kesalahan diagnosis yang dapat berdampak pada pengambilan keputusan medis.

UCAPAN TERIMA KASIH

Terima kasih atas perhatian yang diberikan terhadap hasil evaluasi model ini. Semoga hasil evaluasi ini dapat memberikan wawasan yang berguna bagi pengembangan lebih lanjut. Segala kontribusi dan upaya dalam analisis ini sangat dihargai. Terima kasih sekali lagi atas kerjasama yang baik dalam proses ini.

DAFTAR PUSTAKA

- [1] "Obesity and overweight." Diakses: 16 Desember 2023. [Daring]. Tersedia pada: <https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight>
- [2] "World Obesity Day 2022 – Accelerating action to stop obesity." Diakses: 16 Desember 2023. [Daring]. Tersedia pada: <https://www.who.int/news/item/04-03-2022-world-obesity-day-2022-accelerating-action-to-stop-obesity>
- [3] F. M. Palechor dan A. de la H. Manotas, "Dataset for estimation of obesity levels based on eating habits and physical condition in individuals from Colombia, Peru and Mexico," *Data Brief*, vol. 25, hlm. 104344, Agu 2019, doi: 10.1016/j.dib.2019.104344.

- [4] M. Hodnett, J. F. Wiley, Y. (Hayden) Liu, dan P. Maldonado, *Deep Learning with R for Beginners: Design neural network models in R 3.5 using TensorFlow, Keras, and MXNet*. Packt Publishing Ltd, 2019.
- [5] Y. Rombe, S. A. Thamrin, dan A. Lawi, "Application of Adaptive Synthetic Nominal and Extreme Gradient Boosting Methods in Determining Factors Affecting Obesity: A Case Study of Indonesian Basic Health Research Survey 2013," *Indones. J. Stat. Its Appl.*, vol. 6, no. 2, hlm. 309–317, 2022, doi: 10.29244/ijsa.v6i2p309-317.
- [6] T. Hidayatulloh dan L. Yusuf, "Klasifikasi Tipe Berat Tubuh Menggunakan Metode Support Vector Machine," *INTI Nusa Mandiri*, vol. 18, no. 1, Art. no. 1, Agu 2023, doi: 10.33480/inti.v18i1.4254.
- [7] U. Hasanah dan A. Nurhopipah, "Prediksi Persentase Body Fat Menggunakan Algoritma CART dan M5'," *JTIM J. Teknol. Inf. Dan Multimed.*, vol. 4, no. 4, hlm. 351–363, Feb 2023, doi: <https://doi.org/10.35746/jtim.v4i4.316>.
- [8] R. Ramadhani, G. N. Eza, dan S. Srinahyanti, "Survey Obesitas Anak Usia Dini Menggunakan Machine Learning Selama Pandemi COVID 19 di Kota Medan," *J. Usia Dini*, vol. 9, no. 1, hlm. 67, Jun 2023, doi: 10.24114/jud.v9i1.47819.
- [9] H. Osipyan, B. I. Edwards, dan A. D. Cheok, *Deep Neural Network Applications*. CRC Press, 2022.
- [10] M. F. Ghazali, A. Aqzela, C. Gracia, R. S. Febriningtyas, dan D. Wijayanti, "Analisis Geospasial Kasus Stunting menggunakan Artificial Neural Network (ANN) di Kecamatan Gadingrejo, Pringsewu-Lampung," *Maj. Geogr. Indones.*, vol. 37, no. 1, hlm. 1, 2022, doi: 10.22146/mgi.70474.
- [11] P. Butarbutar, D. M. Midyanti, dan T. Rismawan, "Implementasi Jaringan Syaraf Tiruan Menggunakan Metode Elman Recurrent Neural Network Untuk Prediksi Penyakit Jantung Koroner," *Coding J. Komput. Dan Apl.*, vol. 10, no. 01, hlm. 103–113, Mei 2022, doi: 10.26418/coding.v10i01.52723.
- [12] I. Gunawan, "Optimasi Model Artificial Neural Network untuk Klasifikasi Paket Jaringan," *SIMETRIS*, vol. 14, no. 2, Art. no. 2, Des 2020, doi: 10.51901/simetris.v14i2.135.
- [13] I. Kurniati, C. S. Dewi, dan R. Juniantika, "Penerapan Data Mining dengan Algoritma Neural Network pada Sistem Informasi Prediksi Kasus Balita Gizi Buruk di Provinsi Nusa Tenggara Barat," *J. Rekayasa Inf. Swadharma*, vol. 1, no. 1, hlm. 20–27, 2021.
- [14] D. L. Rahakbauw, F. Tahya, dan M. Sopaheluwakan, "Penerapan Backpropagation Untuk Prediksi Dan Analisa Penyakit Diabetes Melitus Di Kota Ambon," *Pros. Semin. Nas. Pendidik. Mat. Univ. Pattimura*, vol. 1, hlm. 51–55, 2019.
- [15] L. Setiyani, A. N. Indahsari, dan R. Roestam, "Analisis Prediksi Level Obesitas Menggunakan Perbandingan Algoritma Machine Learning dan Deep Learning," *JTERA J. Teknol. Rekayasa*, vol. 8, no. 1, Art. no. 1, 2023, doi: 10.31544/jtera.v8.i1.2022.139-146.