

OPTIMASI ALGORITMA RANDOM FOREST UNTUK MENINGKATKAN AKURASI PREDIKSI INDEKS MASSA TUBUH (BMI)

Eva Juliani^{1(*)}, Apriade Voutama²

¹ Universitas Singaperbangsa Karawang, Karawang

² Universitas Singaperbangsa Karawang, Karawang

Abstract

Accurate Body Mass Index (BMI) prediction is essential for detecting obesity risks and related diseases. This study optimizes the Random Forest algorithm to enhance BMI prediction accuracy through hyperparameter tuning and feature selection. The dataset used is Obesity: Raw and Synthetic Data, which includes demographic and lifestyle variables. After undergoing subsetting, label encoding, and data imbalance handling using SMOTE, the model was trained using Random Forest and evaluated with accuracy, precision, recall, and F1-score metrics. The results indicate that the optimized model achieved 90% accuracy, with precision and recall of 0.89. Additionally, the feature importance analysis identified weight, height, and dietary habits as the most influential factors in BMI prediction. These findings confirm that optimizing the algorithm enhances model reliability in BMI classification and can be applied in data-driven health monitoring systems. This research is expected to contribute to the development of digital health applications and more accurate early obesity detection systems.

Kata Kunci: *Body Mass Index, Random Forest, Machine Learning*

Informasi Artikel:

Dikirim : 18 Maret 2025

Ditelaah : 09 Mei 2025

Diterima : 25 Mei 2025

Publikasi : 25 Juni 2025

Januari – Juni 2025, Vol 6 (1): hlm 11-20

©2025 Institut Teknologi dan Bisnis Ahmad Dahlan.

All rights reserved.

(*) Korespondensi: evajuliani1504@gmail.com (Eva Juliani)

PENDAHULUAN

Kesehatan merupakan salah satu aspek penting dalam kehidupan manusia, dan salah satu indikator kesehatan yang sering digunakan adalah Indeks Massa Tubuh (IMT) atau *Body Mass Index* (BMI). BMI digunakan untuk menentukan kategori berat badan seseorang, mulai dari kurang berat badan, normal, hingga obesitas. Obesitas sendiri telah menjadi masalah kesehatan global yang berkontribusi terhadap berbagai penyakit kronis seperti diabetes, hipertensi, dan penyakit jantung (WHO, 2022). Oleh karena itu, diperlukan metode prediksi BMI yang lebih akurat agar dapat membantu deteksi dini dan pengambilan keputusan dalam bidang kesehatan.

Indeks Massa Tubuh (BMI) umum digunakan untuk menilai status gizi berdasarkan rasio berat dan tinggi badan. BMI membantu mengklasifikasikan individu ke dalam kategori seperti kurus, normal, overweight, atau obesitas, serta mengidentifikasi potensi risiko kesehatan. Namun, metode ini memiliki keterbatasan karena mengabaikan faktor seperti usia, gender, pola makan, dan aktivitas fisik, yang dapat menyebabkan bias (Aptana et al., 2025).

Random Forest merupakan algoritma machine learning yang banyak digunakan untuk klasifikasi dan regresi karena tahan terhadap overfitting dan menghasilkan akurasi tinggi. Dalam prediksi status gizi, studi terdahulu menunjukkan bahwa kombinasi Random Forest dan algoritma genetika mampu mencapai akurasi 89,58% dalam mengklasifikasikan status gizi balita (Candra et al., 2022). Hasil tersebut menegaskan potensi Random Forest dalam meningkatkan akurasi prediksi status gizi. Algoritma ini mampu menangani banyak variabel input tanpa perlu seleksi fitur, serta dapat mengelola data pelatihan yang mengandung nilai hilang secara efektif (Fabian Azmi et al., 2024)

Selain itu, penelitian lain mengimplementasikan Random Forest untuk mengklasifikasikan risiko obesitas berdasarkan pola makan. Dengan melakukan optimasi hyperparameter menggunakan *Grid Search*, model tersebut berhasil mencapai akurasi sebesar 85,4% (Rosidah & Prathivi, 2025) Variabel penting yang mempengaruhi prediksi meliputi frekuensi konsumsi makanan cepat saji, jumlah makanan utama per hari, kebiasaan ngemil, dan konsumsi sayur. Temuan ini menekankan pentingnya optimasi algoritma untuk meningkatkan kinerja model prediksi.

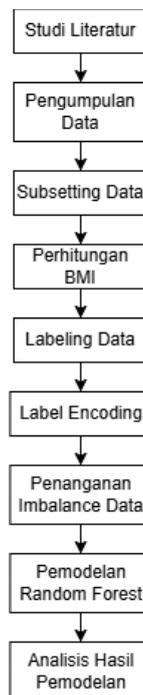
Lebih lanjut, optimasi algoritma Random Forest menggunakan *Particle Swarm Optimization* (PSO) telah diterapkan dalam klasifikasi penyakit diabetes. Hasilnya menunjukkan peningkatan akurasi dari 97,25% menjadi 98,35% setelah optimasi (Fauzi et al., n.d.). Peningkatan ini menggarisbawahi efektivitas teknik optimasi dalam meningkatkan performa algoritma klasifikasi.

Perkembangan teknologi *machine learning* telah mendorong inovasi dalam prediksi status gizi dan Indeks Massa Tubuh (BMI). Salah satu studi signifikan dilakukan oleh Liu dkk, yang memanfaatkan berbagai algoritma seperti *Decision Tree*, *Random Forest*, dan *XGBoost* untuk memprediksi status berat badan remaja di Hong Kong. Model XGBoost menunjukkan kinerja terbaik dengan akurasi hingga 74% dan AUC 0,86, menandakan efektivitas algoritma

ensemble dalam memproses data kesehatan populasi muda (Liu et al., 2024). Sejalan dengan itu, Ji-Hoon Jeong dkk mengembangkan sistem prediksi obesitas remaja berbasis deep learning bernama DeepHealthNet, yang mencapai akurasi 88,4% menggunakan data kesehatan dari 321 remaja (Jeong et al., 2024). Selain itu, pendekatan baru menggunakan citra wajah juga mulai dieksplorasi, seperti oleh Nadeem Yousaf dkk, yang mengembangkan model estimasi BMI berbasis segmentasi semantik dan *pooling region-aware* untuk meningkatkan akurasi prediksi dari data visual (Yousaf et al., 2021).

Temuan ini menyoroti pentingnya optimalisasi algoritma, penggunaan data multidimensi, dan teknologi canggih untuk membangun model prediksi BMI yang akurat dan adaptif. Model tersebut diharapkan dapat menjadi alat bantu yang efektif dalam menilai status gizi individu.

METODE



Gambar 1. Metode Penelitian

1. Studi Literatur

Tahap awal dalam penelitian ini adalah melakukan studi literatur guna memahami konsep dasar serta perkembangan metode yang telah digunakan dalam prediksi Indeks Massa Tubuh (BMI). Sumber referensi yang digunakan meliputi jurnal ilmiah serta penelitian terdahulu terkait algoritma Random Forest dan teknik optimasi model *machine learning*. Studi ini bertujuan untuk mengidentifikasi kelebihan dan kekurangan metode yang ada serta menemukan peluang pengembangan dalam penelitian ini. Dalam beberapa studi, optimasi algoritma Random Forest dengan tuning hyperparameter telah terbukti meningkatkan akurasi dalam klasifikasi data kesehatan, khususnya dalam prediksi obesitas (Rosidah & Prathivi, 2025).

2. Pengumpulan Data

Dataset Obesity: Raw and Synthetic Data, yang diambil dari Kaggle, digunakan untuk tahap pengumpulan data. Dataset ini terdiri dari 2111 entri dan memiliki 17 item. Kolom yang mencakup berbagai informasi yang terkait dengan obesitas, seperti demografis (seperti jenis kelamin, usia, tinggi badan, dan berat badan), kebiasaan hidup (seperti makan cepat, aktivitas fisik, merokok, dan konsumsi air), status kesehatan, dan pilihan transportasi.

3. Subsetting Data

Setelah data terkumpul, dilakukan proses pemilihan *subset* data yang relevan. Data yang memiliki nilai tidak lengkap, tidak valid, atau mengandung *outlier* yang ekstrem akan dibersihkan untuk memastikan kualitas dataset. Langkah ini penting untuk meningkatkan keakuratan model prediksi yang akan dibangun.

4. Perhitungan BMI

Pada langkah berikutnya, nilai *Body Mass Index* (BMI) didapat dengan membagi berat badan dalam kilogram dengan kuadrat tinggi badan dalam meter. Ini dilakukan dengan menggunakan rumus standar. Dalam dataset, kolom baru ditambahkan untuk menampilkan hasil perhitungan BMI, yang dihitung dengan cara berikut:

$$BMI = \frac{Weight}{Height^2}$$

Perhitungan ini dilakukan untuk setiap baris data. Ini menghasilkan kolom BMI yang menunjukkan status berat badan setiap orang.

5. Labeling Data

Setelah perhitungan BMI selesai, setiap individu dikategorikan ke dalam kelompok tertentu berdasarkan standar yang telah ditetapkan, seperti Kurus, Normal, Kelebihan Berat Badan, dan Obesitas (Wulandari et al., 2023). Klasifikasi ini digunakan untuk memberikan target yang jelas dalam proses pembelajaran mesin, sehingga model dapat mengenali pola dalam data dan meningkatkan akurasi prediksi. Pada tahap labeling data, setiap anggota kumpulan data diberi label berdasarkan klasifikasi mereka pada indeks massa tubuh (BMI) yang telah dihitung sebelumnya. Label ini diberikan dengan menggunakan klasifikasi BMI yang telah ditetapkan oleh undang-undang, yang terdiri dari bawah berat badan (BMI di bawah 18.5), berat badan normal (BMI di antara 18.5 dan 24.9), berat badan berlebihan (BMI di antara 25 dan 29.9), kelas obesitas I (BMI antara 30 dan 34.9), kelas obesitas II (BMI antara 35 dan 39.9), dan kelas obesitas III (BMI di atas 40).

6. Label Encoding

Algoritma Random Forest hanya dapat bekerja dengan data numerik, label kategori BMI yang berupa teks dikonversi menjadi bentuk angka menggunakan teknik

Label Encoding (Herdian et al., 2024). Dimulai dari 0 untuk kategori pertama, 1 untuk kategori kedua, dan seterusnya.

7. Penanganan *Imbalance Data*

Jika dataset menunjukkan distribusi kelas yang tidak merata (misalnya, jumlah individu dengan BMI normal jauh lebih banyak dibandingkan kategori lainnya), digunakan teknik seperti SMOTE (*Synthetic Minority Over-sampling Technique*) atau metode *undersampling*. Hal ini dilakukan untuk mencegah model menjadi bias terhadap kelas yang memiliki jumlah sampel lebih banyak. Teknik SMOTE bekerja dengan memperbanyak data minoritas sehingga menyebabkan keseimbangan kelas dalam dataset (Siboro et al., 2024).

8. Pemodelan Random Forest

Setelah data diproses dengan baik, tahap selanjutnya adalah membangun model Random Forest. Random forest bagian dari algoritma klasifikasi dengan pengklasifikasian data yang berjumlah besar (Utami et al., 2024). Algoritma Random Forest terdiri dari beberapa pohon keputusan yang bekerja secara kolektif untuk membuat prediksi. Setiap pohon keputusan dalam ensemble ini memberikan prediksi, dan hasil akhirnya ditentukan berdasarkan mayoritas prediksi tersebut, yang membantu meningkatkan akurasi dan mencegah *overfitting* (Sulehu et al., 2025). Model ini kemudian dilatih menggunakan dataset yang telah diproses, dengan penyesuaian *hyperparameter* seperti jumlah pohon (*n_estimators*), kedalaman maksimum pohon (*max_depth*), dan jumlah fitur yang digunakan (*max_features*) guna meningkatkan performa model.

9. Analisis Hasil Pemodelan

Setelah model dilatih, tahap selanjutnya adalah mengevaluasi kinerjanya menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*. Metrik-metrik ini memberikan gambaran tentang kemampuan model dalam mengklasifikasikan data dengan benar. Sebagai contoh, penelitian menunjukkan bahwa model Random Forest dapat mencapai akurasi sebesar 93,6%, presisi 91,4%, *recall* 96,1%, dan *F1-score* 93,7% dalam prediksi *stroke* (Alifah et al., n.d.).

Dengan demikian, evaluasi menyeluruh menggunakan metrik kinerja dan analisis *feature importance* sangat penting dalam memastikan bahwa model prediksi BMI yang dibangun memiliki akurasi dan interpretabilitas yang tinggi. Langkah-langkah ini memungkinkan identifikasi area yang memerlukan perbaikan dan memastikan bahwa model dapat diandalkan dalam aplikasi praktis, sebagaimana telah dibuktikan dalam penelitian sebelumnya terkait penerapan Random Forest pada klasifikasi data kesehatan (Suryanegara et al., 2021).

HASIL DAN PEMBAHASAN

1. *Subsetting Data*

Data awal terdiri dari 17 kolom, namun hanya kolom terkait gender, usia, tinggi, dan berat badan yang digunakan. Kolom lain seperti pola makan dan merokok dihapus

karena tidak relevan. Subsetting data dilakukan untuk efisiensi pengelolaan, seperti pada penelitian dengan metode Subset Query dalam sistem POSBINDU (Anggara et al., 2023).

Data yang sudah diseleksi, seperti yang ditunjukkan dalam Tabel 1, akan diaplikasikan untuk menghitung indeks massa tubuh dan mengategorikan status berat badan individu.

Tabel 1. *Subsetting Data*

	Gender	Age	Height	Weight
1	Female	21	1.62	64
2	Female	21	1.52	56
3	Male	23	1.80	77
...
2109	Female	22	1.75	133
2110	Female	24	1.73	133
2111	Female	23	1.73	133

2. Perhitungan BMI

Berdasarkan pada pola perumusan WHO, perhitungan BMI dilakukan dengan membagi berat badan (dalam satuan kilogram) dan tinggi badan (dalam satuan meter).

Tabel 2. Perhitungan BMI

	Gender	Age	Height	Weight	BMI
0	Male	24	1.78	67	21.1

3. Labeling Data

Tahap berikutnya adalah mengklasifikasikan setiap individu ke dalam kategori BMI yang telah ditetapkan. Proses ini dilakukan dengan mengacu pada standar rentang nilai BMI yang direkomendasikan oleh Organisasi Kesehatan Dunia (WHO). Klasifikasi BMI terdiri dari beberapa kelompok, yaitu:

- a. *Underweight*: BMI di bawah 18.5 kg/m²
- b. *Normal weight*: BMI dalam rentang 18.5 hingga 24.9 kg/m²
- c. *Overweight*: BMI dalam rentang 25 hingga 29.9 kg/m²
- d. *Obesity Class I*: BMI dalam rentang 30 hingga 34.9 kg/m²
- e. *Obesity Class II*: BMI dalam rentang 35 hingga 39.9 kg/m²
- f. *Obesity Class III*: BMI 40 kg/m² atau lebih

Setelah perhitungan BMI dilakukan, setiap individu dalam dataset diberikan label yang sesuai dengan kategori yang telah ditentukan. Data yang telah diberi label ini selanjutnya dapat disajikan dalam bentuk tabel untuk memudahkan analisis lebih lanjut.

Tabel 3. Labeling Data

Gender	Age	Height	Weight	BMI	Label
---------------	------------	---------------	---------------	------------	--------------

1	Female	21	1.62	64	24.39	Normal Weight
2	Female	21	1.52	56	24.24	Normal Weight
3	Male	23	1.80	77	23.77	Normal Weight
...
2109	Female	22	1.75	133	43.54	Obesity Class III
2110	Female	24	1.73	133	44.07	Obesity Class III
2111	Female	23	1.73	133	44.14	Obesity Class III

4. Label Encoding

Selanjutnya data numerik akan diubah menjadi data kategorikal agar dapat diproses. Perubahan ini dilakukan pada kolom *Gender* dengan data kategorikal yakni *Female* dan *Male*. Nilai *Female* diubah menjadi 1 dan nilai *Male* diubah menjadi 1.

Hasil perubahan dataset ini ditampilkan dalam Tabel 4, yang menunjukkan bahwa kolom *Gender* kini berisi nilai numerik dan dapat dimanfaatkan dalam tahap berikutnya untuk analisis maupun pengembangan model prediktif.

Tabel 4. Label Encoding

	Gender	Age	Height	Weight	BMI	Label
1	0	21	1.62	64	24.39	Normal Weight
2	0	21	1.52	56	24.24	Normal Weight
3	1	23	1.80	77	23.77	Normal Weight
...
2109	0	22	1.75	133	43.54	Obesity Class III
2110	0	24	1.73	133	44.07	Obesity Class III
2111	0	23	1.73	133	44.14	Obesity Class III

5. Penanganan *Imbalance Data*

Pembelajaran mesin sangat dipengaruhi oleh ketidakseimbangan data, terutama saat distribusi kelas target tidak merata. Dalam dataset ini, beberapa label seperti *Overweight* dan *Obesity Class I* memiliki jumlah data lebih besar dibanding label lain. Metode SMOTE-ENN digunakan untuk menangani hal ini dengan menambah data sintetis pada kelas minoritas dan menghapus sampel yang tidak konsisten dari tetangga terdekat.

Tabel 5. Data Sebelum Diseimbangkan

Label	Jumlah
Underweight	239
Normal weight	296
Overweight	562
Obesity class I	366
Obesity class II	335
Obesity class III	313

Tabel 6. Data Setelah Diseimbangkan

Label	Jumlah
Underweight	377
Normal weight	238
Overweight	262
Obesity class I	344
Obesity class II	373
Obesity class III	384

Pada Tabel 6 penyebaran kelas target lebih seimbang dibanding sebelumnya.

6. Pemodelan Random Forest

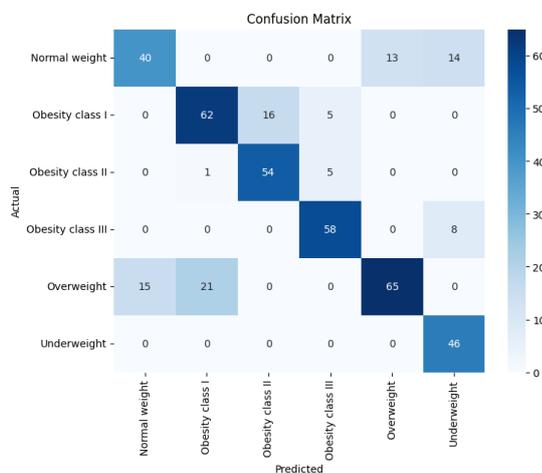
Pada tahap pemodelan Random Forest, dilakukan penyesuaian hyperparameter seperti jumlah pohon, kedalaman, dan fitur yang digunakan. Model dilatih pada data latih dan dievaluasi menggunakan data uji berdasarkan akurasi, precision, recall, dan F1-score. Analisis feature importance juga dilakukan untuk mengetahui variabel yang paling memengaruhi BMI.

7. Analisis Hasil Pemodelan

Model Random Forest mencapai akurasi 90%, menandakan kinerja klasifikasi yang solid. Precision dan recall masing-masing berada di angka 0.89, sedikit lebih rendah namun tetap stabil. Secara keseluruhan, model efektif dalam mengenali sebagian besar kelas dengan hasil yang cukup konsisten.

Tabel 7. Analisis Hasil Pemodelan

Algoritma	Metrik	Hasil
Random Forest	Accuracy	0.90
	Precision	0.89
	Recall	0.90
	F-1 Score	0.89



Gambar 2. Confusion Matrix Random Forest

KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma Random Forest mampu mencapai akurasi 90% dalam memprediksi Indeks Massa Tubuh (BMI), dengan *precision* dan *recall* yang sedikit lebih rendah tetapi tetap menunjukkan performa yang andal. Hasil ini mengindikasikan bahwa model dapat digunakan dalam sistem deteksi dini obesitas dan pemantauan kesehatan berbasis data. Implikasi dari penelitian ini adalah potensi penerapan model dalam aplikasi kesehatan *digital* atau *platform* kesehatan masyarakat untuk membantu individu dan tenaga medis dalam mengidentifikasi risiko obesitas serta merancang strategi pencegahan yang lebih efektif. Untuk penelitian selanjutnya, optimasi model dapat dilakukan melalui teknik ensemble learning atau integrasi dengan data real-time guna meningkatkan akurasi dan kegunaan dalam skenario dunia nyata.

DAFTAR PUSTAKA

- Alifah, R. N., Najib, M. K., Nurdiati, S., Sari, A. P., Herlambang, K., Putri, T., Ginting, B., & Sya'adah, S. N. (n.d.). Indonesian Journal of Mathematics and Natural Sciences **Perbandingan Metode Tree Based Classification untuk Masalah Klasifikasi Data Body Mass Index**. In *Indones. J. Math. Nat. Sci* (Vol. 47, Issue 1). <https://journal.unnes.ac.id/journals/JM/index>
- Anggara, B., Fauziah, F., & Ningsih, S. (2023). **Metode Fast dan Subset Query untuk Optimalisasi Pengolahan Data Medis pada Posbindu Berbasis Web**. *Infomatek*, 25(1), 33–40. <https://doi.org/10.23969/infomatek.v25i1.7270>
- Candra, E. N., Cholissodin, I., & Wihandika, R. C. (2022). **Klasifikasi Status Gizi Balita menggunakan Metode Optimasi Random Forest dengan Algoritme Genetika (Studi Kasus: Puskesmas Cakru)** (Vol. 6, Issue 5). <http://j-ptiik.ub.ac.id>
- Fabian Azmi, A., Voutama, A., Karawang Jl HSRonggo Waluyo, S., & Timur, T. (2024). **PREDIKSI CHURN NASABAH BANK MENGGUNAKAN KLASIFIKASI RANDOM FOREST DAN DECISION TREE DENGAN EVALUASI CONFUSION MATRIX**. 13(1).
- Fauzi, A., Heri, A., & #2, Y. (n.d.). *JEPIN (Jurnal Edukasi dan Penelitian Informatika)* **Optimasi Algoritma Klasifikasi Naive Bayes, Decision Tree, K-Nearest Neighbor, dan Random Forest menggunakan Algoritma Particle Swarm Optimization pada Diabetes Dataset**.
- Gde Agung Brahmana Suryanegara, Adiwijaya, & Mahendra Dwifebri Purbolaksono. (2021). **Peningkatan Hasil Klasifikasi pada Algoritma Random Forest untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi**. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 114–122. <https://doi.org/10.29207/resti.v5i1.2880>
- Herdian, C., Kamila, A., & Agung Musa Budidarma, I. G. (2024). Studi Kasus Feature Engineering Jeong, J. H., Lee, I. G., Kim, S. K., Kam, T. E., Lee, S. W., & Lee, E.

- (2024). **DeepHealthNet: Adolescent Obesity Prediction System Based on a Deep Learning Framework.** *IEEE Journal of Biomedical and Health Informatics*, 28(4), 2282–2293. <https://doi.org/10.1109/JBHI.2024.3356580>
- Liu, H., Wu, Y. C., Chau, P. H., Chung, T. W. H., & Fong, D. Y. T. (2024). **Prediction of adolescent weight status by machine learning: a population-based study.** *BMC Public Health*, 24(1), 1–13. <https://doi.org/10.1186/s12889-024-18830-1>
- Yousaf, N., Hussein, S., & Sultani, W. (2021). **Estimation of BMI from facial images using semantic segmentation based region-aware pooling.** *Computers in Biology and Medicine*, 133. <https://doi.org/10.1016/j.compbiomed.2021.104392>
- Untuk Data Teks: **Perbandingan Label Encoding dan One-Hot Encoding Pada Metode Linear Regresi.** *Technologia: Jurnal Ilmiah*, 15(1), 93. <https://doi.org/10.31602/tji.v15i1.13457>
- Rosidah, N., & Prathivi, R. (2025). **OPTIMASI METODE RANDOM FOREST UNTUK KLASIFIKASI RISIKO OBESITAS BERDASARKAN POLA MAKAN.** *Jurnal Informatika Teknologi Dan Sains*, 7(1), 56–62.
- Siboro, O., Pricilia Banjarnahor, Y., Gultom, A., Antonius Siagian, N., & Silitonga, P. D. (2024). **Penanganan Data Ketidakseimbangan dalam Pendekatan SMOTE Guna Meningkatkan akurasi Algoritma K-NN 1** (Vol. 1, Issue Mei).
- Sulehu, M., Wisda, W., Wanita, F., & Markani, M. (2025). **Optimasi Prediksi Kelulusan Mahasiswa Menggunakan Random Forest untuk Meningkatkan Tingkat Retensi.** *Jurnal Minfo Polgan*, 13(2), 2364–2374. <https://doi.org/10.33395/jmp.v13i2.14472>
- Utami, N., Ahmad Baihaqi, K., Elvira Awal, E., & Wahiddin, D. (2024). **Analisis Kinerja Algoritma Decision Tree Dan Random Forest Dalam Klasifikasi Penyakit Kardiovaskular.** *Technology and Science (BITS)*, 6(2). <https://doi.org/10.47065/bits.v6i2.5722>
- Yogi Aptana, N., Nur Ikhsan, A., Maulana Baihaqi, W., & Raras Ajeng Widiawati, C. (2025). **Perbandingan Random Forest dan K-Nearest Neighbors untuk Klasifikasi Body Mass Index Menggunakan SMOTE-ENN untuk Mengatasi Ketidakseimbangan Data pada Analisis Kesehatan.** 16(01). <https://doi.org/10.35970/infotekmesin.v16i1.2553>
- Zahra Wulandari, M., Fuad Hamdi, A., Zahra Nurhalisa, F., Fawwaz, D., Hutabarat, P., Septiani, G. C., Nurazizah, D. A., & Puspawati, S. (2023). **Penggunaan Perhitungan Indeks Massa Tubuh sebagai Penanda Status Gizi pada Mahasiswa Prodi Kesehatan Masyarakat Rombel 2D.** In *Jurnal Analis* (Vol. 2, Issue 2). <http://jurnalilmiah.org/journal/index.php/Analis>