



SUBMIT

(Jurnal Ilmiah Teknologi Informasi dan Sains)

Vol.6 No.1(2026) 9 - 14

ISSN Media Elektronik: 2798-6861

PENGUNAAN *SINGLE MACHINE LEARNING* DAN *ENSEMBLE MACHINE LEARNING* UNTUK DETEKSI PENYAKIT JANTUNG

Faisal Dharma Adhinata^{*1}, Gita Fadila Fitriana², Nia Annisa Ferani Tanjung³

^{1,2,3}Program Studi Rekayasa Perangkat Lunak, Telkom University, Purwokerto, Indonesia

Email: ¹faisaldharma@telkomuniversity.ac.id, ²gitafadila@telkomuniversity.ac.id,

³niaannisa@telkomuniversity.ac.id

(Naskah masuk: 16 Mei 2026, diterima untuk diterbitkan: 24 Mei 2026)

Abstrak

Penyakit jantung merupakan penyakit yang berbahaya bahkan penyebab kematian tertinggi di dunia. Deteksi dini penyakit jantung diperlukan sebagai upaya antisipasi untuk menjaga kesehatan sejak dini. Terdapat beberapa karakteristik gejala penyakit jantung yang cukup kompleks. Adanya banyak karakteristik ini mengharuskan penegakan diagnosis oleh tenaga medis. Sementara itu, pada beberapa daerah terpencil belum banyak tenaga medis. Oleh karena itu, pada penelitian ini mengembangkan sistem deteksi dini penyakit jantung menggunakan AI. Proses deteksi dini ini juga masih memerlukan tenaga medis sebagai penegakan diagnosis utama. Penelitian ini dilakukan dengan membandingkan metode *single machine learning* dengan *ensemble machine learning*. Pemilihan metode machine learning daripada deep learning karena dataset yang digunakan jumlahnya tidak terlalu banyak. Metode *single machine learning* menggunakan Support Vector Machine (SVM), sedangkan metode *ensemble machine learning* menggunakan CatBoost. Perbandingan ini untuk mengetahui metode mana yang cocok untuk klasifikasi data kompleks. Hasil eksperimen menunjukkan penggunaan CatBoost lebih efektif dibanding *single machine learning*. Nilai akurasi dan F1 menggunakan metode CatBoost adalah 0,99. Metode CatBoost menggunakan banyak *decision tree* untuk pengambilan keputusan prediksi. Proses ini yang membuat *ensemble learning* lebih baik dibanding *single machine learning*. Melalui hasil ini, penggunaan *ensemble learning* terbukti dapat mengolah data yang kompleks untuk penentuan prediksi penyakit jantung.

Kata kunci: *penyakit jantung, single machine learning, ensemble machine learning, SVM, CatBoost*

USE OF SINGLE MACHINE LEARNING AND ENSEMBLE MACHINE LEARNING FOR HEART DISEASE DETECTION

Abstract

Heart disease is a dangerous disease and the leading cause of death worldwide. Early detection of heart disease is essential as a preventative measure to maintain health early. Several characteristics of heart disease symptoms are quite complex. The presence of many of these characteristics requires a diagnosis by medical personnel. Meanwhile, in some remote areas, medical personnel are scarce. Therefore, this study developed an early detection system for heart disease using AI. This early detection process also still requires medical personnel as the primary diagnostic tool. This research was conducted by comparing single machine learning methods with ensemble machine learning. The single machine learning method used SVM, while the ensemble machine learning method used CatBoost. This comparison was carried out to determine which method is suitable for classifying complex data. Experimental results showed that using CatBoost was more effective than single machine learning. The accuracy and F1 score using the CatBoost method were 0.99. The CatBoost method uses multiple decision trees for predictive decision making. This process makes ensemble learning superior to single machine learning.

Through these results, the use of ensemble learning has been proven to process complex data for determining heart disease predictions.

Keywords: *heart disease, single machine learning, ensemble machine learning, SVM, CatBoost*

1. PENDAHULUAN

Penyakit jantung merupakan salah satu penyebab kematian terbanyak di dunia, bahkan memiliki tingkat mortalitas yang tinggi. Penyakit jantung ini termasuk penyakit kardiovaskular (Fraç et al., 2022). Gejala masalah penyakit jantung adalah nyeri dada, sesak napas, detak jantung tidak teratur, pusing, dan kelelahan (Khan et al., 2024). Organisasi WHO telah menyatakan bahwa penyakit jantung merupakan penyebab kematian tertinggi. Sekitar 19,8 juta orang meninggal diakibatkan oleh penyakit kardiovaskular pada tahun 2022 atau sekitar 32% dari seluruh kematian global. Bahkan, lebih dari tiga perempat penyakit ini mengjangkit di negara berpenghasilan rendah dan menengah (WHO, 2025). Oleh karena itu, upaya pencegahan dini terhadap penyakit jantung diperlukan untuk mengurangi resiko komplikasi yang ditimbulkan. Pemanfaatan teknologi berbasis data dapat menjadi pendekatan untuk pengolahan data prediksi resiko penyakit jantung.

Pada pengolahan data penyakit jantung, tenaga medis pada umumnya menggunakan berbagai gejala klinis yang muncul. Indikator yang sering digunakan adalah usia, jenis kelamin, nyeri dada, tekanan darah, kolesterol, kadar gula, hasil elektrokardiografi, detak jantung maksimum, serta kondisi pembuluh darah (Lapp, 2019). Hubungan pada karakteristik data-data tersebut terlalu kompleks, sehingga pendekatan konvensional tanpa tenaga medis belum dapat dilakukan. Pada daerah terpencil yang minim tenaga medis diperlukan sebuah metode otomatisasi untuk deteksi penyakit jantung. Salah satu pendekatan yang dapat dimanfaatkan untuk proses prediksi adalah menggunakan pendekatan Artificial Intelligence (AI), khususnya *machine learning* (Febrian et al., 2022). Penggunaan *machine learning* juga tergantung pada metode *machine learning* yang digunakan. Oleh karena itu, pada penelitian ini akan membandingkan penggunaan *single machine learning* dan *ensemble learning*.

Salah satu metode *single machine learning* adalah Support Vector Machine (SVM) (Hall et al., 2025). SVM telah banyak digunakan sebagai metode klasifikasi. Peneliti Syahputra & Wibowo (2023) menggunakan metode SVM untuk deteksi konten negatif. Hasil eksperimen menunjukkan penggunaan metode SVM menghasilkan akurasi yang lebih baik daripada metode Random Forest. Penggunaan metode SVM juga lebih baik dibanding Random Forest untuk deteksi *cyberbullying* (Amalina et al., 2025). Akurasi yang dihasilkan masih sedikit lebih baik menggunakan SVM. Adanya perbandingan komparasi antara *single machine learning* dan

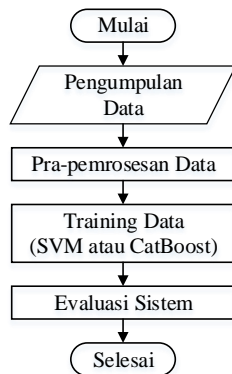
ensemble learning menunjukkan SVM masih cukup baik untuk tugas klasifikasi.

Performa *ensemble learning* juga perlu diuji untuk mengetahui performa klasifikasi yang dihasilkan. Pada penelitian ini mengusulkan penggunaan metode CatBoost. Penggunaan metode klasifikasi CatBoost menghasilkan performa paling unggul dibanding metode klasifikasi lainnya (Ibrahim et al., 2020). Peneliti P & Salamah (2025) membandingkan metode *ensemble learning* XGBoost, CatBoost, dan GBM untuk prediksi penyakit kardiovaskular. Hasil eksperimen menunjukkan penggunaan CatBoost lebih baik akurasinya dibanding metode *ensemble learning* lainnya. Peneliti Badr & Abdul-Hassan (2021) juga menggunakan metode CatBoost untuk pengenalan usia dan jenis kelamin. Hasil eksperimen juga menunjukkan kinerja metode CatBoost cukup baik.

Pada penelitian ini akan melakukan evaluasi terhadap metode *single machine learning* yaitu SVM dan *ensemble machine learning* yaitu CatBoost untuk deteksi penyakit jantung. Tujuannya adalah memperoleh akurasi yang paling optimal. Kontribusi penelitian adalah melakukan komparasi penggunaan *single machine learning* dengan *ensemble machine learning*. Hasil penelitian ini diharapkan dapat memberikan kontribusi didunia medis terkait penggunaan metode AI untuk prediksi penyakit jantung. Sistem ini dapat digunakan untuk membantu diagnosis deteksi dini, sehingga membantu pihak medis dalam penegakan diagnosis.

2. METODE PENELITIAN

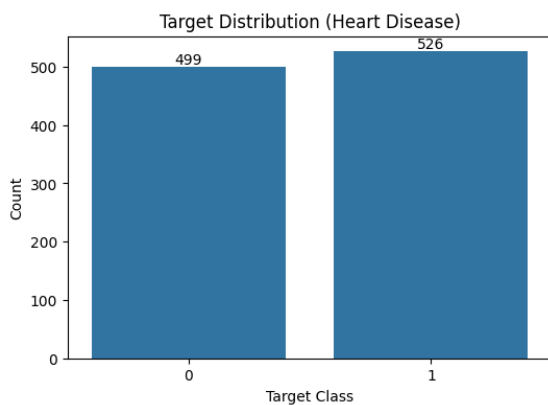
Sistem deteksi penyakit jantung dimulai dengan akuisisi dataset. Pada penelitian ini, dataset yang digunakan adalah dataset sekunder. Data dilakukan proses pembagian data menjadi data *training* dan data *testing*. Tahap selanjutnya adalah dilakukan proses pra-pemrosesan terhadap skala data. Kemudian, proses dilanjutkan dengan tahapan *training* data. Hasil *training* akan dievaluasi berdasarkan nilai akurasi dan F1 yang dihasilkan. Gambar 1 menunjukkan alur penelitian yang diusulkan. Bahasa pemrograman yang digunakan pada penelitian ini adalah bahasa pemrograman Python.



Gambar 1. Alur sistem deteksi penyakit jantung

2.1 Pengumpulan data

Dataset yang digunakan pada penelitian ini bersumber dari Kaggle (Lapp, 2019). Jumlah dataset yang digunakan adalah 1025 baris data. Terdapat 13 fitur dan 1 target pada data ini, dimana data disimpan dalam format csv. Pembagian jumlah kelas ditunjukkan pada Gambar 2. Kelas 0 merupakan kelas tanpa penyakit, sedangkan kelas 1 adalah penyakit.



Gambar 2. Jumlah data pada masing-masing kelas

2.2 Pra-pemrosesan data

Tahap pra-pemrosesan merupakan tahap menyiapkan data sebelum dilanjutkan ke tahap *training*. Pada penelitian ini, tahap pra-pemrosesan diawali dengan split data *training* dan *testing*. Konfigurasi split yang digunakan adalah 80% sebagai data *training* dan 20% sebagai data *testing*. Penggunaan ukuran 80:20 ini karena pada penelitian Adhinata et al. (2024) melakukan eksperimen berbagai kombinasi data *training* dan *testing*. Hasil eksperimen menunjukkan penggunaan kombinasi 80:20 yang paling optimal akurasi. Dataset juga dilakukan *scaling* menggunakan `standardScaler` dari Python. Normalisasi ini dilakukan pada kedua data *training* dan *testing*. Penggunaan `standardScaler` untuk mengurangi bias, sehingga semua *attribute* memiliki skala yang sama (Ishak et al., 2024).

2.3 Training data menggunakan SVM

Pada penelitian ini menggunakan SVM karena SVM merupakan contoh metode *single supervised learning*. SVM bekerja untuk memaksimalkan

hyperplane yang memisahkan kedua kelas data. Margin yang diperoleh juga dimaksimalkan (Taamneh et al., 2023). Dataset yang letaknya paling dekat dengan hyperplane disebut sebagai support vector. Data ini yang digunakan sebagai penentuan posisi batas keputusan model.

2.4 Training data menggunakan CatBoost

Pada penelitian ini menggunakan CatBoost sebagai pembanding metode SVM. CatBoost termasuk metode *ensemble learning* (Badr & Abdul-Hassan, 2021). CatBoost menggunakan banyak decision tree sebagai model dasar. Model ini dapat membangun pohon Keputusan bertahap. Setiap pohon baru dibuat untuk memperbaiki keputusan prediksi dari pohon sebelumnya.

2.5 Evaluasi sistem

Evaluasi sistem deteksi penyakit jantung pada penelitian ini menggunakan `classification report` pada Python. Pemrograman menggunakan Kaggle dengan Python versi 3.12.12. Jumlah CPU yang digunakan adalah 4 dengan Intel(R) Xeon(R) CPU @ 2.20GHz. Metrik evaluasi yang pertama adalah akurasi, dimana menyatakan banyak prediksi model yang benar dibandingkan dengan seluruh data testing. Akurasi akan menunjukkan seberapa besar hasil klasifikasi pasien benar, baik pasien yang terjangkit penyakit maupun tidak. Metrik evaluasi yang kedua adalah F1-Score, dimana metrik ini diperoleh dari gabungan nilai precision dan recall. F1-Score digunakan untuk melihat performa keseimbangan model.

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, perangkat lunak yang digunakan adalah menggunakan bahasa pemrograman Python. Proses *training* data dilakukan menggunakan Kaggle. Library yang digunakan untuk tahap *training* adalah `sklearn` untuk SVM dan `catboost` untuk *training* menggunakan metode CatBoost.

3.1 Hasil training menggunakan SVM

Proses *training* menggunakan SVM dilakukan dengan *tuning hyperparameter*. Salah satu hyperparameter yang paling berpengaruh adalah kernel. Pada penelitian ini akan dilakukan evaluasi terhadap tiga kernel, yaitu linear, RBF, dan polynomial. Tabel 1 menunjukkan hasil *training* menggunakan SVM.

Kernel	Akurasi	F1
Linear	0,81	0,81
RBF	0,89	0,89
polynomial	0,91	0,91

Pada penggunaan kernel linear, metode SVM terbukti cukup baik dalam mengklasifikasikan data deteksi penyakit jantung. Namun, hasil yang diperoleh masih belum dapat menangkap pola data

yang kompleks, sehingga akurasi dan F1 yang dihasilkan belum optimal. Penyebab belum optimalnya menggunakan kernel linear karena data dipisahkan secara linear atau garis lurus. Hasil yang rendah menunjukkan data tidak sepenuhnya dapat dipisahkan secara linear.

Penggunaan kernel non-linear seperti RBF dan polynomial menghasilkan nilai akurasi dan F1 yang lebih baik dibanding kernel linear. Nilai akurasi dan F1 yang sama menunjukkan model tidak hanya baik dalam memprediksi data, namun memiliki keseimbangan juga terhadap nilai recall dan precision. Kernel polynomial menghasilkan nilai akurasi dan F1 yang paling tinggi pada penggunaan SVM. Hasil ini menunjukkan kernel polynomial dapat membentuk keputusan yang efektif dibanding kernel linear dan RBF.

3.2 Hasil *training* menggunakan CatBoost

Pada proses *training* menggunakan CatBoost, tuning hyperparameter yang digunakan adalah *iteration*. Nilai *iteration* yang akan dievaluasi mulai dari 50 hingga 250 dengan interval 50. Tabel 2 menunjukkan hasil *training* menggunakan CatBoost.

Tabel 2. Hasil *training* menggunakan CatBoost

Iteration	Akurasi	F1
50	0,85	0,85
100	0,88	0,88
150	0,89	0,89
200	0,99	0,99
250	0,99	0,99

Tabel 2 menunjukkan adanya peningkatan *iteration* yang digunakan maka performa klasifikasi juga ikut meningkat. Penambahan nilai *iteration* menunjukkan model dapat mempelajari pola data yang lebih baik. Pada penggunaan *iteration* 200, nilai akurasi dan F1 mencapai 0,99. Hasil ini menunjukkan model tidak hanya mencapai akurasi tinggi, namun juga efektif dalam menjaga keseimbangan nilai recall dan precision.

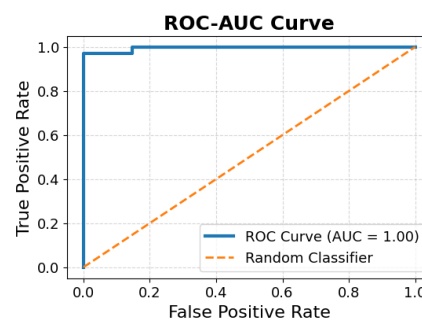
Pada penggunaan nilai *iteration* 250, nilai akurasi dan F1 tidak mengalami perubahan dibanding penggunaan *iteration* 200. Hasil ini menunjukkan bahwa model telah mencapai titik stabil pada penggunaan *iteration* 200. Penambahan *iteration* setelah 200 cenderung tidak meningkatkan hasil prediksi. Melalui hasil ini, jumlah *iteration* sangat berpengaruh terhadap performa model yang dihasilkan.

3.3 Diskusi

Penggunaan *single machine learning* dan *ensemble machine learning* cukup berbeda pada performa hasil klasifikasinya. Pada penggunaan SVM, hasil terbaik diperoleh menggunakan kernel polynomial dengan nilai akurasi dan F1 0,91. Sedangkan pada penggunaan CatBoost, performa terbaik diperoleh menggunakan *iteration* 200. Nilai

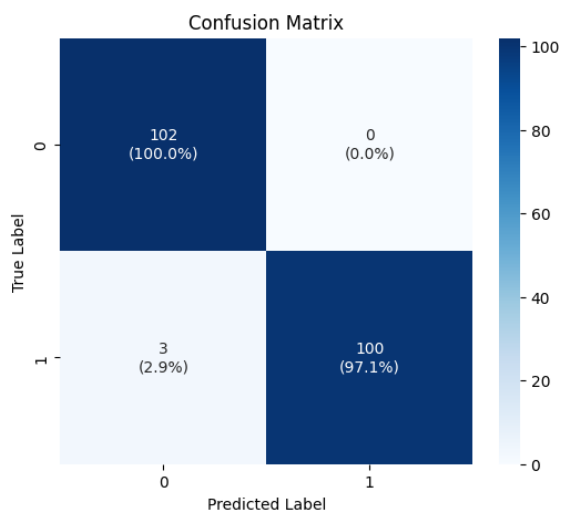
akurasi dan F1 yang dihasilkan mencapai 0,99. Melalui hasil ini, penggunaan CatBoost lebih baik dibanding menggunakan metode SVM.

Perbedaan hasil ini terjadi karena karakteristik metode yang berbeda. SVM sebagai tradisional machine learning bekerja berdasarkan optimalisasi hyperplane. Kemudian, pada CatBoost yang merupakan ensemble machine learning membangun banyak pohon decision tree. Setiap *tree* dibangun untuk mengatasi kesalahan pada hasil *tree* sebelumnya, sehingga proses *training* dilakukan lebih mendalam. Oleh karena itu, penggunaan metode CatBoost dapat menjadi rekomendasi *supervised learning* yang cukup baik untuk proses klasifikasi data.



Gambar 3. Hasil kurva ROC-AUC

Gambar 3 menunjukkan hasil kurva ROC-AUC. Nilai AUC adalah 1,00 bermakna model memiliki kemampuan sempurna dalam membedakan kelas 0 dan 1. Garis berwarna biru menunjukkan model memiliki *true positive rate* tinggi dan *false positive rate* rendah. Model dapat mengenali data positif dengan sangat baik. Gambar 4 menunjukkan hasil confusion matrix pada penggunaan metode CatBoost.



Gambar 4. Hasil confusion matrix menggunakan CatBoost

Dari 205 data testing, terdapat 202 data berhasil diklasifikasikan dengan benar. Bahkan pada kelas 0 atau kelas tanpa penyakit, hasil klasifikasi benar semua. Pada kelas terjangkit penyakit jantung, hanya

terdapat 3 kesalahan klasifikasi. Hasil ini menunjukkan penggunaan CatBoost sangat kecil mengalami kesalahan klasifikasi. Berdasarkan *confusion matrix*, kesalahan klasifikasi dapat dianalisis, khususnya pada kasus *false negative*. Adanya *false negative* sangat berbahaya karena pasien yang terindikasi penyakit jantung dinyatakan sehat. Terdapat 3 data yang *false negative*, dimana penggunaan AI masih terdapat kesalahan prediksi. Penggunaan AI sebagai prediksi penyakit jantung merupakan hanya sebagai alat bantu, sehingga bukan pengganti diagnosis oleh pihak medis.

4. KESIMPULAN

Penggunaan metode *machine learning* yang tepat menjadi pertimbangan untuk menghasilkan akurasi yang optimal. Hasil penelitian ini menunjukkan bahwa penggunaan *ensemble learning* seperti CatBoost lebih efektif daripada *tradisional machine learning* seperti SVM. Hasil terbaik diperoleh dengan nilai akurasi dan F1 0,99. Penggunaan CatBoost dapat menangkap pola non-linear pada dataset. Disamping itu, *ensemble learning* merupakan gabungan dari *tree tree* yang terus memperbaiki setiap keputusan, sehingga hasil klasifikasi semakin akurat. Adanya penggabungan banyak *decision tree* membuat model lebih fleksibel dalam pembelajaran pada fitur kompleks.

Pada penelitian ini juga masih mengeksplorasi *hyperparameter* yang masih umum dan paling berpengaruh. Penelitian kedepan dapat mengeksplorasi dengan kombinasi *hyperparameter* lainnya untuk memperoleh hasil akurasi yang optimal. Selain menggunakan *tuning hyperparameter*, peneliti juga dapat eksplorasi teknik atau metode *supervised learning* lainnya.

DAFTAR PUSTAKA

- Adhinata, F. D., Wahyono, & Sumiharto, R. (2024). Classification of Weed and Corn Seedling Using Hybrid MobileNetV2 and Support Vector Machine. *2024 IEEE 33rd International Symposium on Industrial Electronics (ISIE)*, 1–6. <https://doi.org/10.1109/ISIE54533.2024.10595690>
- Amalina, I. N., Norhikmah, N., & Ashari, W. M. (2025). Analysis of the Performance Comparison between Random Forest and SVM RBF in Detecting Cyberbullying on Imbalanced Data with the SMOTE Approach. *Sistemasi*, *14*(6), 2768. <https://doi.org/10.32520/stmsi.v14i6.5574>
- Badr, A. A., & Abdul-Hassan, A. K. (2021). CatBoost Machine Learning Based Feature Selection for Age and Gender Recognition in Short Speech Utterances. *International Journal of Intelligent Engineering and Systems*, *14*(3), 150–159. <https://doi.org/10.22266/ijies2021.0630.14>
- Febrian, M. E., Ferdinan, F. X., Sendani, G. P., Suryanigrum, K. M., & Yunanda, R. (2022). Diabetes prediction using supervised machine learning. *Procedia Computer Science*, *216*(2022), 21–30. <https://doi.org/10.1016/j.procs.2022.12.107>
- Frąk, W., Wojtasińska, A., Lisińska, W., Młynarska, E., Franczyk, B., & Rysz, J. (2022). Pathophysiology of Cardiovascular Diseases: New Insights into Molecular Mechanisms of Atherosclerosis, Arterial Hypertension, and Coronary Artery Disease. *Biomedicine*, *10*(8). <https://doi.org/10.3390/biomedicine10081938>
- Hall, J., Tang, J., & Cao, T. (2025). Machine Learning Classification of AI and Real Images. *2025 Intermountain Engineering, Technology and Computing, IETC 2025*, 1–6. <https://doi.org/10.1109/IETC64455.2025.11039474>
- Ibrahim, A. A., Ridwan, R. L., Muhammed, M. M., Abdulaziz, R. O., & Saheed, G. A. (2020). Comparison of the CatBoost Classifier with other Machine Learning Methods. *International Journal of Advanced Computer Science and Applications*, *11*(11), 738–748. <https://doi.org/10.14569/IJACSA.2020.0111190>
- Ishak, R., Nurmawanti, & Amiruddin. (2024). Optimasi K-Means pada Clustering Penyakit Ibu Hamil Menggunakan Random Forest. *Jambura Journal of Electrical and Electronics Engineering*, *7*(1), 41.
- Khan, M. R., Haider, Z. M., Hussain, J., Malik, F. H., Talib, I., & Abdullah, S. (2024). Comprehensive Analysis of Cardiovascular Diseases: Symptoms, Diagnosis, and AI Innovations. *Bioengineering*, *11*(12). <https://doi.org/10.3390/bioengineering11121239>
- Lapp, D. (2019). *Heart Disease Dataset*. Kaggle.Com. <https://www.kaggle.com/datasets/johnsmith88/heart-disease-dataset>
- P, P. S., & Salamah, U. (2025). Comparison of the Performance of XGBoost, CatBoost, and GBM Algorithms in Cardiovascular Disease Prediction. *JSAI (Journal Scientific and Applied Informatics)*, *8*(1), 268–273. <https://doi.org/10.36085/jsai.v8i1.7552>
- Syahputra, H., & Wibowo, A. (2023). Comparison of Support Vector Machine (SVM) and Random Forest Algorithm for Detection of Negative Content on Websites. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika*, *9*(1), 165–173. <https://doi.org/10.26555/jiteki.v9i1.25861>
- Taamneh, M. M., Taamneh, S., Alomari, A. H., & Abuaddous, M. (2023). Analyzing the Effectiveness of Imbalanced Data Handling Techniques in Predicting Driver Phone Use. *Sustainability (Switzerland)*, *15*(13).

<https://doi.org/10.3390/su151310668>

WHO. (2025). *Cardiovascular diseases (CVDs)*.

WHO. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))