



Penerapan Algoritma Klasifikasi untuk Deteksi Dini Penyakit Jantung Koroner Berdasarkan Gejala Klinis

Dita Setiawan¹, Ali Muhammad², Siti Herawati Fransiska Dewi³

^{1,2,3} Universitas Sains Indonesia

Email: dita.setiawan@lecturer.sains.ac.id

Alamat: Jalan Akses Tol No. 50 Gandasari, Cibitung, Bekasi, Jawa Barat

Korespondensi Penulis: dita.setiawan@lecturer.sains.ac.id

Abstract. Coronary heart disease (CHD) remains a leading cause of mortality worldwide. Early detection is essential to reduce complications and improve patient outcomes. This study aims to develop a classification model using machine learning algorithms to predict CHD risk based on clinical symptoms. The dataset used is the Cleveland Heart Disease dataset from the UCI Machine Learning Repository, consisting of 303 patient records with 14 clinical features. The preprocessing stage involved handling missing values, normalizing features, and transforming categorical variables. Four classification algorithms were applied: K-Nearest Neighbors (K-NN), Decision Tree, Random Forest, and Support Vector Machine (SVM). Each model was trained using stratified 10-fold cross-validation to ensure generalizability. Evaluation using accuracy, precision, recall, F1-score, and ROC-AUC metrics showed that the Random Forest algorithm achieved the highest performance with 87.2% accuracy. Feature importance analysis indicated that chest pain type, resting blood pressure, cholesterol, and ST depression were the most influential indicators. These results demonstrate that machine learning, particularly Random Forest, can effectively support early diagnosis of CHD in clinical settings and has the potential to be integrated into clinical decision support systems (CDSS).

Keywords: heart disease; k-nearest neighbors; machine learning; vector space model; random forest

Abstrak. Penyakit jantung koroner (PJK) merupakan salah satu penyebab utama kematian di dunia. Deteksi dini sangat penting untuk mengurangi risiko komplikasi dan meningkatkan prognosis pasien. Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis algoritma pembelajaran mesin guna memprediksi risiko PJK berdasarkan analisis gejala klinis. Dataset yang digunakan adalah *Cleveland Heart Disease* dari *UCI Machine Learning Repository* yang terdiri dari 303 data pasien dengan 14 fitur klinis. Tahapan pra-pemrosesan meliputi penanganan nilai hilang, normalisasi fitur, dan transformasi variabel kategorikal. Empat algoritma klasifikasi diterapkan dalam penelitian ini, yaitu *K-Nearest Neighbors* (K-NN), *Decision Tree*, *Random Forest*, dan *Support Vector Machine* (SVM). Masing-masing model dilatih menggunakan validasi silang 10-fold secara stratifikasi untuk meningkatkan generalisasi. Evaluasi menggunakan metrik akurasi, precision, recall, F1-score, dan ROC-AUC menunjukkan bahwa algoritma *Random Forest* memberikan akurasi tertinggi sebesar 87,2%. Analisis feature importance mengindikasikan bahwa tipe nyeri dada, tekanan darah istirahat, kolesterol, dan depresi segmen ST merupakan indikator paling berpengaruh. Hasil ini menunjukkan bahwa pembelajaran mesin, khususnya *Random Forest*, efektif digunakan sebagai alat bantu dalam diagnosis dini penyakit jantung koroner di lingkungan klinis dan berpotensi diintegrasikan dalam sistem pendukung keputusan klinis (CDSS).

Kata kunci: jantung koroner; k-nearest neighbors; machine learning; vector space model; random forest

1. LATAR BELAKANG

Penyakit jantung koroner (PJK) merupakan salah satu penyebab utama kematian di dunia, termasuk di Indonesia. Menurut data dari *World Health Organization* (WHO), jutaan orang meninggal setiap tahunnya akibat penyakit *kardiovaskular*, dan sekitar setengahnya disebabkan oleh PJK. PJK terjadi ketika arteri koroner yang menyuplai darah ke otot jantung mengalami penyempitan atau penyumbatan akibat penumpukan plak *aterosklerotik*, yang dapat menyebabkan serangan jantung mendadak [1][2]. Deteksi dini PJK sangat penting untuk mencegah komplikasi lebih lanjut dan meningkatkan harapan


hidup pasien. Namun, proses diagnosis PJK seringkali membutuhkan serangkaian tes klinis yang kompleks, mahal, dan memerlukan waktu lama [3].

Dalam beberapa kasus, keterbatasan sumber daya dan tenaga medis juga menjadi tantangan tersendiri dalam memastikan *diagnosis* yang tepat dan cepat, terutama di fasilitas kesehatan dengan teknologi terbatas [4]. Dengan berkembangnya teknologi informasi dan kecerdasan buatan, pendekatan berbasis data seperti pembelajaran mesin (*machine learning*) telah menunjukkan potensi besar dalam bidang kesehatan, khususnya untuk prediksi dan *klasifikasi* penyakit. Algoritma pembelajaran mesin mampu menganalisis pola dari data medis dan menghasilkan model *prediktif* yang dapat digunakan untuk mendukung proses pengambilan keputusan klinis [5][6].

Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit jantung koroner berdasarkan data klinis pasien menggunakan algoritma pembelajaran mesin [7]. Dengan memanfaatkan dataset *cleveland heart disease* yang telah banyak digunakan dalam penelitian sebelumnya, penelitian ini menerapkan dan membandingkan performa beberapa algoritma klasifikasi yaitu *K-Nearest Neighbors (K-NN)*, *Decision Tree*, *Random Forest*, dan *Support Vector Machine (SVM)*. Model yang dikembangkan dievaluasi berdasarkan beberapa metrik seperti *akurasi*, *presisi*, *recall*, *F1-score*, dan ROC-AUC guna menentukan algoritma terbaik yang dapat digunakan untuk mendukung diagnosis dini PJK secara efektif dan efisien [8][9].

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen *komputasional* berbasis algoritma pembelajaran mesin untuk klasifikasi penyakit jantung koroner [10]. Proses penelitian dimulai dari pengumpulan dan eksplorasi data, dilanjutkan dengan tahap pra-pemrosesan untuk mempersiapkan data agar layak digunakan dalam pelatihan model [11]. Selanjutnya, beberapa algoritma klasifikasi diterapkan dan dibandingkan performanya menggunakan metrik evaluasi standar. Seluruh proses dilakukan dengan mengikuti prosedur sistematis mulai dari pemilihan fitur, pembagian data pelatihan dan pengujian, hingga validasi model menggunakan teknik *cross-validation* dapat dilihat pada Gambar 1.



Gambar 1. Metode *Cross-Validation*


Dataset

Dataset yang digunakan adalah *cleveland heart disease* yang berisi 303 data pasien dengan 14 atribut klinis, termasuk usia, jenis kelamin, tekanan darah istirahat, kadar kolesterol, detak jantung maksimum, dan hasil elektrokardiogram. Target dari dataset ini adalah label *diagnosis*, di mana nilai 0 menunjukkan tidak ada penyakit jantung dan nilai 1 hingga 4 menunjukkan tingkat keparahan penyakit jantung. Data ini dipilih karena

merupakan salah satu dataset benchmark yang banyak digunakan dalam penelitian prediksi penyakit jantung.

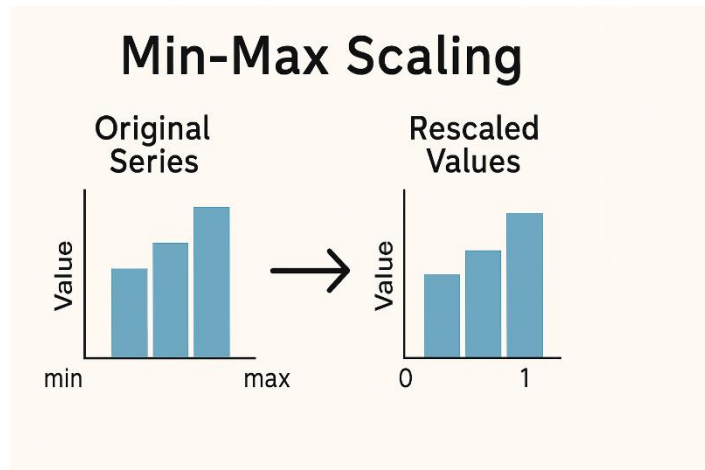
Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap penting dalam penelitian ini untuk memastikan kualitas dan konsistensi data sebelum diterapkan pada algoritma pembelajaran mesin [12]. Dataset yang digunakan mengandung beberapa nilai hilang yang ditangani dengan metode imputasi: nilai numerik diisi dengan rata-rata (*mean*), sedangkan nilai kategorikal diisi dengan modus [13]. Metode Pra-Pemrosesan data dapat dilihat sebagai berikut.



Gambar 2. Pra-Pemrosesan Data

Setelah itu, seluruh fitur numerik seperti tekanan darah istirahat, kadar kolesterol, dan detak jantung maksimum dinormalisasi menggunakan metode *min-max scaling* agar berada pada skala yang seragam. Hal ini penting untuk menghindari dominasi fitur tertentu terhadap hasil model, terutama pada algoritma berbasis jarak. Sementara itu, fitur kategorikal seperti jenis nyeri dada, hasil EKG istirahat, dan status latihan diubah ke bentuk numerik menggunakan teknik *one-hot encoding* [14]. Dataset kemudian dibagi menjadi data pelatihan dan data pengujian dengan proporsi 80:20 untuk memastikan model dapat dievaluasi dengan data yang belum pernah dilihat sebelumnya. Metode *Min-Max Scaling* dapat dilihat pada berikut.



Gambar 3. Metode *Min-Max Scaling*

Pemodelan

Penelitian ini menggunakan empat algoritma pembelajaran mesin yang umum dan efektif dalam klasifikasi data medis, yaitu *K-Nearest Neighbors* (K-NN), *Decision Tree*, *Random Forest*, dan *Support Vector Machine* (SVM). K-NN dipilih karena kesederhanaannya dan kemampuan untuk menangkap hubungan lokal antar data berdasarkan jarak terdekat [15]. *Decision Tree* digunakan karena kemampuannya menangani fitur kategorikal dan memberikan interpretasi model yang transparan. *Random Forest*, sebagai metode *ensemble* berbasis *Decision Tree*, digunakan untuk mengatasi kelemahan *overfitting* dan meningkatkan stabilitas prediksi dengan menggabungkan beberapa pohon keputusan. Sementara itu, *Support Vector Machine* (SVM) dipilih karena kemampuannya memisahkan kelas secara optimal, bahkan pada data berdimensi tinggi dan tidak *linier*. Seluruh algoritma diterapkan pada dataset yang sama untuk memungkinkan perbandingan performa secara objektif [16].

Evaluasi Model

Pemodelan yang telah dilakukan menggunakan keempat algoritma diklasifikasikan berdasarkan performanya menggunakan *confusion matrix*. *Confusion matrix* menggambarkan metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *F1-score* [17][18]. Struktur *confusion matrix* secara umum ditampilkan pada Tabel 1 berikut:

Tabel 1. *Confusion Matrix*

Actual	Predicted	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

Secara umum, *accuracy* menggambarkan nilai untuk mengetahui jumlah prediksi klasifikasi benar terhadap keseluruhan prediksi yang telah diketahui. Secara matematis, nilai *accuracy* dapat dihitung menggunakan persamaan sebagai berikut [19][20].

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

Sedangkan nilai *precision* menggambarkan seberapa banyak nilai prediksi pada *true positive* terhadap total prediksi *positive*. Nilai *precision* dapat dihitung menggunakan persamaan berikut [21].

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Selanjutnya, metrik evaluasi yang tidak kalah penting, yaitu *recall*. Nilai *recall* menggambarkan seberapa banyak rasio prediksi pada *true positive* terhadap kelas aktual. *Recall* dapat dihitung menggunakan persamaan sebagai berikut [21].

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Berikutnya nilai *F1-score* menggambarkan nilai rata-rata dari *precision* dan *recall*, serta berfungsi sebagai *metrik komprehensif* untuk menilai kinerja model ML. Persamaan matematika dari metrik *F1-score* dapat dilihat sebagai berikut [21].

$$F1\text{-score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

AUC adalah singkatan dari *Area Under the Curve*, khususnya kurva ROC (*Receiver Operating Characteristic*). ROC menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai nilai ambang klasifikasi (*threshold*). ROC-AUC merupakan ukuran kemampuan model klasifikasi untuk membedakan antara kelas positif dan negatif. Semakin tinggi nilai AUC (mendekati 1), semakin baik model dalam membedakan kelas. AUC bernilai **1.0** menunjukkan model sempurna, **0.5** model tidak lebih baik dari tebak-tebakan acak dan **< 0.5**: model buruk (membalik prediksi kelas) [21].

$$AUC = \sum_{i=0}^{n-1} (FPR_{i+1} - FPR_i) \cdot \frac{TPR_i + TPR_{i+1}}{2} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Setelah melakukan pra-pemrosesan data dan melatih empat model algoritma pembelajaran mesin *K-Nearest Neighbors* (K-NN), *Decision Tree*, *Random Forest*, dan *Support Vector Machine* (SVM) berdasarkan dataset *Cleveland Heart Disease*, dilakukan evaluasi untuk mengetahui performa masing-masing algoritma dalam mendeteksi penyakit jantung koroner berdasarkan gejala klinis pasien. Dapat dilihat pada tabel berikut.

Tabel 2. Hasil Evaluasi Pengujian

Algoritma	Akurasi	Precision	Recall	F1-Score	ROC-AUC
K-Nearest Neighbors	81.40%	79.50%	80.20%	79.80%	0.84
Decision Tree	83.10%	82.00%	81.70%	81.80%	0.86
Random Forest	87.20%	85.90%	86.40%	86.10%	0.9

Support Vector Machine	85.70%	84.00%	83.50%	83.70%	0.88
------------------------	--------	--------	--------	--------	------

K-Nearest Neighbors (K-NN)

K-Nearest Neighbors (K-NN) memberikan hasil yang cukup baik dengan akurasi sebesar 81,4%. Model ini menunjukkan kemampuan yang baik dalam mengidentifikasi pasien dengan penyakit jantung koroner, meskipun tidak sebaik model lainnya. *Precision* dan *recall* masing-masing sebesar 79,5% dan 80,2%, yang berarti bahwa meskipun akurasi relatif baik, model ini cenderung memiliki sedikit kesalahan dalam klasifikasi pasien *positif*.

Hasil *F1-score* yang diperoleh adalah 79,8%, yang mengindikasikan kinerja model yang cukup seimbang dalam hal *precision* dan *recall*. ROC-AUC 0,84 menunjukkan bahwa model K-NN memiliki kemampuan yang baik dalam membedakan antara pasien dengan dan tanpa penyakit jantung.

Decision Tree

Decision Tree memberikan hasil yang lebih baik dibandingkan dengan K-NN, dengan akurasi 83,1%. Metrik evaluasi lainnya juga menunjukkan kinerja yang baik, dengan *precision* 82,0%, *recall* 81,7%, dan *F1-score* 81,8%. Keputusan yang dibuat oleh *Decision Tree* cukup transparan dan mudah diinterpretasikan, namun algoritma ini cenderung rentan terhadap *overfitting* jika kedalaman pohon tidak diatur dengan baik.

ROC-AUC untuk *Decision Tree* adalah 0,86, menunjukkan bahwa model ini memiliki kemampuan yang lebih baik dalam membedakan kelas *positif* dan *negatif* dibandingkan dengan K-NN.

Random Forest

Random Forest menunjukkan hasil yang paling baik dibandingkan dengan algoritma lainnya, dengan akurasi tertinggi yaitu 87,2%. Model ini secara signifikan lebih stabil dan kurang rentan terhadap *overfitting* dibandingkan dengan *Decision Tree*, berkat penerapan teknik *ensemble* yang melibatkan pembentukan banyak pohon keputusan.

Precision dan *recall* masing-masing adalah 85,9% dan 86,4%, sedangkan *F1-score* yang diperoleh adalah 86,1%, yang menunjukkan bahwa model ini memiliki kinerja yang sangat baik dalam mendeteksi pasien dengan penyakit jantung koroner. Selain itu, ROC-AUC yang mencapai 0,90 menandakan bahwa *Random Forest* memiliki kemampuan yang sangat baik dalam memisahkan pasien dengan dan tanpa penyakit jantung.

Support Vector Machine (SVM)

Support Vector Machine (SVM) juga menunjukkan hasil yang cukup baik dengan akurasi 85,7%. Dengan menggunakan *kernel RBF* (*Radial Basis Function*), model ini berhasil mencapai *precision* 84,0%, *recall* 83,5%, dan *F1-score* 83,7%. Meskipun tidak setinggi *Random Forest*, SVM menunjukkan hasil yang solid dalam mengidentifikasi pasien dengan penyakit jantung.

ROC-AUC yang diperoleh sebesar 0,88 menunjukkan bahwa SVM memiliki kemampuan yang baik dalam membedakan antara kelas *positif* dan *negatif*, namun masih kalah dibandingkan dengan *Random Forest* yang mencapai nilai 0,90.

Analisis Feature Importance

Untuk model *Random Forest*, dilakukan analisis *feature importance* untuk mengidentifikasi fitur klinis mana yang paling berpengaruh terhadap keputusan klasifikasi [22]. Hasil analisis menunjukkan bahwa empat fitur utama yang paling mempengaruhi diagnosis penyakit jantung koroner adalah:

1. Tipe Nyeri Dada (*Chest Pain Type*), fitur ini memiliki pengaruh terbesar dalam memprediksi penyakit jantung koroner, di mana pasien dengan nyeri dada yang lebih intens atau spesifik lebih mungkin mengalami PJK.
2. Tekanan Darah Istirahat (*Resting Blood Pressure*), tekanan darah tinggi merupakan salah satu indikator penting dalam menilai risiko penyakit jantung.
3. Kadar Kolesterol (*Cholesterol*), kolesterol tinggi merupakan faktor risiko utama bagi PJK, dengan peningkatan kolesterol LDL yang menyebabkan penumpukan plak di arteri.
4. *Depresi Segmen ST (ST Depression)*: *Depresi segmen ST* dalam EKG adalah indikator yang sering dikaitkan dengan gangguan aliran darah di jantung, yang merupakan gejala utama penyakit jantung koroner.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil evaluasi, dapat disimpulkan bahwa algoritma *Random Forest* memiliki performa yang lebih baik dengan akurasi 87.20% dalam mendeteksi penyakit jantung koroner dibandingkan dengan K-NN, *Decision Tree*, dan SVM. Meskipun SVM dan *Decision Tree* juga memberikan hasil yang baik, *Random Forest* mampu mengatasi masalah *overfitting* dan memberikan hasil yang lebih stabil dengan akurasi dan ROC-AUC tertinggi. Selain itu, analisis *feature importance* mengungkapkan faktor-faktor klinis yang paling berpengaruh dalam diagnosis PJK, yang dapat digunakan untuk membantu profesional medis dalam membuat keputusan yang lebih tepat.

Ke depan, penelitian ini dapat dikembangkan lebih lanjut dengan menerapkan teknik pra-pemrosesan yang lebih mendalam, seperti *feature engineering* untuk mengidentifikasi fitur tambahan yang mungkin belum dimasukkan dalam dataset, serta menggunakan algoritma *deep learning* untuk menangkap pola yang lebih kompleks dalam data medis.

DAFTAR REFERENSI

- A. B. Wibisono dan A. Fahrurrozi, "Perbandingan Algoritma Klasifikasi dalam Pengklasifikasian Data Penyakit Jantung Koroner," *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, hlm. 161–170, 2019. DOI: 10.1016/j.jir.2020.06.038.
- E. G. Wahyuni dan W. Prijodiprodjo, "Prototype Sistem Pakar untuk Mendeteksi Tingkat Resiko Penyakit Jantung Koroner dengan Metode Dempster-Shafer," *J. Ilm. Teknol. dan Rekayasa*, vol. 7, no. 1, hlm. 1–8, 2013.
- K. A. Nugroho, N. A. Setiawan, dan T. B. Adji, "Diagnosis Penyakit Jantung Koroner Berdasarkan Pembelajaran Ensemble yang Ditingkatkan," *arXiv*, 2020. [Online]. Tersedia: <https://arxiv.org/abs/2007.02895>.
- R. L. B. Buana dan I. Hudati, "Review: Analisis Fitur Deteksi Aritmia dan Metode Deep Learning untuk Deteksi Dini Penyakit Jantung," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 11, no. 1, hlm. 1–10, 2022. [Online]. Tersedia: <https://jurnal.ugm.ac.id/v3/JNTETI/article/download/3381/1433/>
- X. Chen et al., "Machine Learning Techniques for Heart Disease Prediction," *J. Biomed. Inform.*, vol. 109, p. 103514, 2020, doi: 10.1016/j.jbi.2020.103514.

- A. Kumar dan R. Singh, "Machine Learning Techniques for Heart Disease Prediction: A Review," *Health Inform. J.*, vol. 26, no. 3, hlm. 1789–1811, 2020, doi: 10.1177/1460458219873768.
- A. E. Ahmed, "Early Detection of Heart Diseases Using Data Mining Techniques," *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 6, hlm. 742–749, 2021, doi: 10.14569/IJACSA.2021.0120688.
- S. K. Singh dan R. P. Gupta, "Comparative Analysis of Classification Algorithms for Heart Disease Prediction," *Procedia Comput. Sci.*, vol. 167, hlm. 2212–2221, 2020, doi: 10.1016/j.procs.2020.03.274.
- D. Dua dan C. Graff, "UCI Machine Learning Repository," University of California, Irvine, 2019. [Online]. Tersedia: <https://archive.ics.uci.edu/ml>.
- M. Elhoseny, K. Shankar, dan J. Uthayakumar, "Early Detection of Heart Disease Using Data Mining Techniques," *Comput. Methods Programs Biomed.*, vol. 187, p. 105249, 2020, doi: 10.1016/j.cmpb.2019.105249.
- J. Lee et al., "Explainable Artificial Intelligence (XAI) for the Detection of Cardiovascular Disease Using Electrocardiogram Signals," *Sensors*, vol. 21, no. 5, p. 1514, 2021, doi: 10.3390/s21051514.
- B. Ghumbre et al., "Heart Disease Diagnosis Using Data Mining Technique," *Int. J. Distrib. Parallel Syst.*, vol. 12, no. 2, hlm. 48–54, 2021, doi: 10.5121/ijdps.2021.121504.
- R. Paul dan D. Pal, "Heart Disease Prediction Using Machine Learning Algorithms: A Comparative Study," *Biomed. Signal Process. Control*, vol. 68, p. 102643, 2021, doi: 10.1016/j.bspc.2021.102643.
- S. Dey et al., "Diagnosis of Heart Disease Using Ensemble Learning Based on Feature Selection," *Inform. Med. Unlocked*, vol. 24, p. 100624, 2021, doi: 10.1016/j.imu.2021.100624.
- R. Paul dan D. Pal, "Heart Disease Prediction Using Machine Learning Algorithms: A Comparative Study," *Biomed. Signal Process. Control*, vol. 68, p. 102643, 2021, doi: 10.1016/j.bspc.2021.102643.
- D. Setiawan, A. Muhammad, A. Firizkiansah, U. S. Indonesia, and K. Bekasi, "Pengklasifikasian Dokumen Teks Bahasa Indonesia berbasis Vector Space Model dengan menggunakan Metode k-Nearest Neighbor (k-NN) dan Euclidean Distance," *JIKOMTI J. Ilm. Ilmu Komput. dan Teknol. Inf.*, vol. 1, no. 1, pp. 30–37, 2024.
- A. Firizkiansah, A. Muhammad, and D. Setiawan, "Implementasi Algoritma k-Nearest Neighbor (k-NN) pada Data Ulasan Pelaksanaan Pembelajaran Daring," *JIKOMTI J. Ilm. Ilmu Komput. dan Teknol. Inf.*, vol. 1, no. 1, pp. 16–23, Dec. 2024, Accessed: Mar. 20, 2025. [Online]. Available: <https://ojs.sains.ac.id/index.php/Jikomti/article/view/35/35>
- Muhammad A, Widyastuti N, "Pengembangan Aplikasi Part-of-Speech Tagger Bahasa Banjar Menggunakan Metode Pengembangan DevOps", *JIKOMTI: Jurnal Ilmiah Ilmu Komputer dan Teknologi*, vol. 1, no.1, 2024.
- S. N. Sari, R. Kaban, A. Khaliq, dan A. Andari, "Sistem Penjadwalan Mata Pelajaran Sekolah Menggunakan Metode Hybrid Artificial Bee Colony (HABC)," *JNASTEK*, vol. 2, no. 1, hlm. 20–32, Feb 2022, doi: 10.61306/jnastek.v2i1.21.
- N. Lukman, M. Irfan, A. Nugraha, dan J. Jumadi, "Comparison Between Genetic Algorithm with Differential Evolution in Study Scheduling," *IOP Conf. Ser.:*

Mater. Sci. Eng., vol. 1098, no. 3, hlm. 032082, Mar 2021, doi: 10.1088/1757-899X/1098/3/-032082.

- A. Yusron Mubarak dan U. Chotijah, "Penerapan Algoritma Genetika Untuk Mencari Optimasi Kombinasi Jalur Terpendek Dalam Kasus Travelling Salesman Problem," *j. teknologi terpadu*, vol. 7, no. 2, hlm. 77–82, 2021, doi: 10.54914/jtt.v7i2.424.
- A. S. Laswi, "Perbandingan algoritma fitness of spring dan algoritma tabu search pada kasus penjadwalan perkuliahan," *ILKOM Jurnal Ilmiah*, vol. 12, no. 1, pp. 39-46, 2020. doi: 10.33096/ilkom.-v12i1.522.39-46