

Evaluasi Teknik Seleksi Fitur terhadap Performa Model Machine Learning pada Dataset Penyakit Sirosis

Agus Wantoro^{1*}, Ferly Ardhy², Dwi Yana Ayu Andini³, Aviv Fitria Yulia⁴, Dwi Feriyanto⁵

^{1*}Ilmu Komputer; Universitas Aisyah Pringsewu; Jl. A Yani Tambah Rejo – Pringsewu

²Teknik Informatika; Universitas Aisyah Pringsewu; Jl. A Yani Tambah Rejo – Pringsewu

^{3,4,5}Rekayasa Perangkat Lunak; Universitas Aisyah Pringsewu; Jl. A Yani Tambah Rejo – Pringsewu

Received: 09-02-2026

Accepted: 21-08-2026

Keywords:

Sirosis;
Machine Learning;
Seleksi fitur;
Klasifikasi;

Correspondent Email:

aguswantoro@aisyahuniversity.ac.id

Abstrak. Penyakit sirosis merupakan salah satu penyakit kronis pada hati dengan tingkat morbiditas dan mortalitas yang tinggi, sehingga diperlukan upaya deteksi dini yang akurat dan efisien. Pemanfaatan Machine Learning (ML) dalam bidang kesehatan menjadi salah satu solusi untuk membantu proses klasifikasi dan diagnosis penyakit berdasarkan data klinis pasien. Namun, penggunaan seluruh fitur dalam dataset tanpa seleksi dapat menyebabkan penurunan performa model akibat adanya fitur yang tidak relevan atau redundant. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi pengaruh teknik seleksi fitur terhadap performa model ML seperti SVM, Tree, kNN dan Random Forest pada dataset penyakit sirosis. Tahapan yang digunakan dalam penelitian ini meliputi penerapan beberapa model ML sebagai model klasifikasi, serta penerapan berbagai teknik seleksi fitur seperti Information Gain (IG), Gain Rasio (GR), dan Gini Decrease (GD) dan evaluasi kinerja. Evaluasi model dilakukan dengan membandingkan hasil klasifikasi sebelum dan sesudah seleksi fitur menggunakan metrik akurasi, presisi, dan recall. Hasil penelitian menunjukkan bahwa penerapan seleksi fitur mampu meningkatkan performa model klasifikasi penyakit sirosis secara signifikan, sekaligus mengurangi kompleksitas model. Selain itu, efektivitas teknik seleksi fitur bervariasi tergantung pada model ML yang digunakan, sehingga tidak terdapat satu metode seleksi fitur yang selalu unggul untuk seluruh model. Penelitian ini membuktikan bahwa seleksi fitur merupakan tahap penting dalam pengolahan data medis berbasis ML dan dapat meningkatkan akurasi serta efisiensi diagnosis penyakit sirosis.

Abstract. Cirrhosis is a chronic disease of the liver with high levels of morbidity and mortality, so accurate and efficient early detection efforts are needed. The use of Machine Learning (ML) in the health sector is one solution to help the process of classifying and diagnosing diseases based on patient clinical data. However, using all the features in a dataset without selection can cause a decrease in model performance due to the presence of irrelevant or redundant features. Therefore, this study aims to evaluate the effect of feature selection techniques on the performance of ML models such as SVM, Tree, kNN and Random Forest on the cirrhosis dataset. The stages used in this research include the application of several ML models as classification models, as well as the application of various feature selection techniques such as Information Gain (IG), Gain Ratio (GR), and Gini Decrease (GD) and performance evaluation. Model evaluation is carried out by comparing classification results before and after feature selection using accuracy, precision and recall metrics. The research results show that the application of feature selection can significantly improve the performance of the cirrhosis classification model, while reducing the complexity of the model. In addition,

the effectiveness of feature selection techniques varies depending on the ML algorithm used, so there is no one feature selection method that is always superior for all models. This research proves that feature selection is an important stage in ML-based medical data processing and can increase the accuracy and efficiency of cirrhosis diagnosis

1 PENDAHULUAN

Penyakit sirosis merupakan salah satu penyakit kronis pada hati yang ditandai dengan kerusakan jaringan hati secara progresif dan bersifat irreversible [1]. Penyakit ini menjadi masalah kesehatan global karena tingkat morbiditas dan mortalitas yang cukup tinggi, terutama ketika diagnosis dilakukan pada tahap lanjut [2]. Oleh karena itu, deteksi dini penyakit sirosis sangat penting untuk meningkatkan peluang penanganan dan memperlambat perkembangan penyakit.

Seiring berkembangnya teknologi, penerapan Machine Learning (ML) dalam bidang kesehatan semakin banyak digunakan, termasuk dalam membantu proses diagnosis penyakit berdasarkan data klinis pasien [3]. Dataset penyakit sirosis umumnya terdiri dari berbagai fitur klinis dan laboratorium, seperti usia, kadar enzim hati, bilirubin, albumin, serta parameter medis lainnya [4]. Namun, tidak semua fitur tersebut memiliki kontribusi yang signifikan terhadap proses klasifikasi. Penggunaan seluruh fitur tanpa seleksi dapat menyebabkan masalah seperti redundansi data, overfitting, peningkatan kompleksitas model, dan penurunan performa klasifikasi [5].

Untuk mengatasi permasalahan tersebut, teknik seleksi fitur digunakan untuk memilih fitur-fitur yang paling relevan dan informatif. Berbagai teknik seleksi fitur telah dikembangkan, antara lain metode berbasis statistik, metode berbasis pembelajaran mesin, serta pendekatan hybrid [5]. Setiap teknik seleksi fitur memiliki karakteristik dan keunggulan masing-masing, serta dapat memberikan pengaruh yang berbeda terhadap performa model ML yang digunakan [6].

Penelitian-penelitian sebelumnya menunjukkan bahwa penerapan seleksi fitur dapat meningkatkan akurasi, efisiensi, dan stabilitas model klasifikasi pada berbagai kasus penyakit, seperti penyakit jantung, diabetes, dan kanker [7], [8], [9]. Namun, masih terbatas penelitian yang secara khusus mengevaluasi dan membandingkan pengaruh berbagai teknik

seleksi fitur terhadap performa model ML pada dataset penyakit sirosis. Selain itu, perbedaan model ML yang digunakan juga dapat menghasilkan performa yang bervariasi meskipun menggunakan teknik seleksi fitur yang sama.

Berdasarkan permasalahan tersebut, diperlukan suatu penelitian yang melakukan evaluasi komprehensif terhadap berbagai teknik seleksi fitur dan pengaruhnya terhadap performa model ML dalam klasifikasi penyakit sirosis. Evaluasi ini diharapkan dapat memberikan gambaran mengenai teknik seleksi fitur yang paling efektif dalam meningkatkan performa model, baik dari sisi akurasi, presisi, recall, maupun efisiensi komputasi.

Adapun tujuan dari penelitian ini adalah menganalisis performa beberapa model ML seperti Support Vector Machines (SVM), Tree, kNN, dan Random Forest dalam mengklasifikasikan penyakit sirosis. Mengevaluasi pengaruh penerapan berbagai teknik seleksi fitur seperti Information Gain (IG), Gain Rasio (GR), dan Gini Decrease (GD) terhadap performa model ML. Selain itu, membandingkan hasil performa model sebelum dan sesudah penerapan seleksi fitur serta menentukan teknik seleksi fitur yang paling optimal untuk digunakan pada dataset penyakit sirosis.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pendukung keputusan medis, khususnya dalam membantu diagnosis penyakit sirosis secara lebih akurat dan efisien

2 TINJAUAN PUSTAKA

2.1 Penyakit Sirosis

Sirosis merupakan kondisi medis kronis yang ditandai dengan terbentuknya jaringan parut (fibrosis) pada hati akibat kerusakan hati jangka panjang [10]. Kerusakan ini menyebabkan penurunan fungsi hati secara bertahap dan dapat berkembang menjadi komplikasi serius seperti gagal hati dan kanker

hati. Faktor penyebab sirosis antara lain konsumsi alkohol berlebihan, hepatitis kronis, serta gangguan metabolik [2]. Dalam penelitian berbasis data, penyakit sirosis umumnya dianalisis menggunakan data klinis dan laboratorium pasien untuk membantu proses diagnosis dan prediksi kondisi penyakit.

2.2 Machine Learning dalam Bidang Kesehatan

ML merupakan cabang dari kecerdasan buatan yang memungkinkan sistem untuk belajar dari data dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit [11]. Dalam bidang kesehatan, ML banyak digunakan untuk klasifikasi penyakit, prediksi risiko, serta analisis data medis dalam jumlah besar [12]. Model ML mampu mengenali pola tersembunyi dalam data klinis yang kompleks sehingga dapat membantu tenaga medis dalam pengambilan Keputusan [13]

2.3 Model Machine Learning Klasifikasi

Model klasifikasi bertujuan untuk mengelompokkan data ke dalam kelas tertentu berdasarkan karakteristik fitur yang dimiliki [14]. Beberapa model yang umum digunakan dalam penelitian medis antara lain:

- a. **K-Nearest Neighbor (KNN)**
KNN merupakan model berbasis instance yang mengklasifikasikan data berdasarkan kedekatan jarak dengan data lain di sekitarnya. Model ini sederhana namun sensitif terhadap jumlah fitur dan skala data [15].
- b. **Support Vector Machine (SVM).**
Model SVM bekerja dengan mencari hyperplane terbaik yang memisahkan data antar kelas. Model ini efektif pada data berdimensi tinggi dan sering digunakan pada klasifikasi data medis [16]
- c. **Decision Tree.** Model Decision Tree mengklasifikasikan data dengan membentuk struktur pohon keputusan berdasarkan aturan tertentu. Model ini mudah diinterpretasikan dan cocok untuk analisis medis [17]
- d. **Random Forest.** Model Random Forest merupakan pengembangan dari Decision Tree yang menggunakan banyak pohon keputusan untuk meningkatkan akurasi dan mengurangi overfitting [18]

Model-model tersebut memiliki karakteristik yang berbeda dan dapat memberikan performa yang bervariasi tergantung pada kualitas dan jumlah fitur yang digunakan

2.4 Seleksi Fitur

Seleksi fitur merupakan proses pemilihan subset fitur yang paling relevan dari dataset untuk digunakan dalam proses pemodelan [19]. Tujuan utama seleksi fitur adalah mengurangi dimensi data, meningkatkan performa model, serta mengurangi kompleksitas komputasi [20]. Seleksi fitur sangat penting dalam dataset medis yang umumnya memiliki banyak fitur namun tidak semuanya berkontribusi secara signifikan [21]

2.3.1. Information Gain (IG)

Teknik IG mengukur pengurangan entropi (ketidakpastian) dalam kumpulan data setelah pemisahan (splitting) berdasarkan atribut tertentu. Semakin tinggi IG, semakin baik atribut tersebut dalam mengklasifikasikan data [22]. Induksi pohon keputusan merupakan fondasi metode ini. Perolehan informasi digunakan sebagai kriteria pemilihan atribut. Metode perolehan informasi memiliki waktu yang lebih cepat dalam proses pemilihan fitur dibandingkan metode lainnya. Fitur dengan informasi terbanyak akan diberi peringkat tinggi dalam metode ini; jika tidak, fitur dengan informasi terbanyak akan diberi peringkat tinggi [23]

2.3.2. Gain-Ratio (GR)


GR adalah modifikasi dari IG yang dirancang untuk mengatasi bias tersebut. GR menormalkan IG dengan membagi nilai pada atribut yang bersangkutan [24]. Split Information mengukur seberapa merata atau tidak meratanya atribut membagi data [5]. Saat memilih fitur, GR mempertimbangkan jumlah dan ukuran dataset [25]. GR memodifikasi perolehan informasi yang mampu mengurangi biasnya. GR memilih atribut berdasarkan jumlah dan ukuran cabang. Dengan adanya normalisasi ini, GR cenderung memilih atribut yang menghasilkan pemisahan yang lebih seimbang dan bermakna, bukan hanya yang memiliki banyak kategori unik [5]. Hal ini mengarah pada generalisasi model yang lebih baik (mengurangi overfitting)

2.3.3. Gini Decrease

Merupakan metode seleksi fitur yang menggunakan teknik rata-rata penurunan total sebuah variabel pada node impurity-nya, dibobot dengan proporsi sampel yang mencapai node tersebut di setiap individu decision tree pada Random forest-nya [26]. Ini secara efektif mengukur seberapa penting variabel untuk memperkirakan nilai dari variable target di semua pohon. Gini Mean Decrease yang lebih tinggi menunjukkan kepentingan variabel yang lebih tinggi

2.5 Cross-validation (k-fold)

Klasifikasi merupakan salah satu bentuk teknik penambangan data yang sedang populer saat ini [27]. Strategi ini menggunakan berbagai metode untuk menilai data yang tersedia guna menghasilkan prediksi diabetes [5]. Model klasifikasi akan divalidasi menggunakan *k-fold cross-validation*. Metode *cross-validation* umumnya digunakan untuk training set [28]. Gambar 2 menampilkan prosedur *cross-validation*.



Gambar 1. Prosedur k-fold Validation

2.6 Evaluasi Performa Model

Evaluasi performa model dilakukan untuk mengukur kemampuan model dalam melakukan klasifikasi secara akurat. Beberapa metrik evaluasi yang umum digunakan antara lain:

- **Akurasi**, untuk mengukur persentase prediksi yang benar.
- **Presisi**, untuk mengukur ketepatan prediksi kelas positif.
- **Recall**, untuk mengukur kemampuan model dalam mendeteksi kasus positif.

Penggunaan beberapa metrik evaluasi diperlukan untuk memperoleh gambaran performa model yang lebih komprehensif,


terutama pada kasus data medis yang sering mengalami ketidakseimbangan kelas.

2.7 Seleksi Fitur dan Performa Model

Penerapan seleksi fitur yang tepat dapat meningkatkan performa model ML dengan menghilangkan fitur yang tidak relevan atau redundant [26]. Hal ini berdampak pada peningkatan akurasi, stabilitas model, serta efisiensi komputasi. Oleh karena itu, evaluasi dan perbandingan teknik seleksi fitur menjadi aspek penting dalam penelitian ini untuk menentukan pendekatan yang paling optimal pada dataset penyakit sirosis

3 METODE PENELITIAN

Tahapan penelitian ini disusun untuk memastikan proses penelitian berjalan secara terstruktur, sistematis, dan dapat direplikasi. Adapun langkah-langkah penelitian yang dilakukan diilustrasikan pada Gambar 2.



Gambar 2. Tahapan penelitian

3.1 Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset prediksi kelangsungan hidup pasien Sirosis yang berisi 418 data klinis pasien. Dataset diperoleh dari UCI Machine Learning Repository sumber terbuka dan repository terpercaya. Data tersebut mencakup 18 atribut, yang berpotensi memengaruhi kondisi penyakit sirosis, dan satu atribut target yang ditampilkan dalam Tabel 1.

3.2 Pre-Processing

Proses pengolahan dan persiapan data agar terstruktur, dan siap digunakan untuk analisis lebih lanjut atau pembuatan model ML [29]. Tahapan ini sangat krusial karena kualitas data akan sangat memengaruhi keakuratan hasil analisis. Pada tahap ini dataset dilakukan pengisian data hilang (*missing-values*) menggunakan teknik *impute average*. Selain itu, karena data yang beragam, maka kami

melakukan normalisasi menggunakan interval [0-1].

Tabel 1. Atribut dataset

No	Atribut	Type	Role
1	N_Days	Int	Fitur
2	Status	Categorical	Target
3	Age	Int	Fitur
4	Sex	Categorical	Fitur
5	Ascites	Categorical	Fitur
6	Hepatomegaly	Categorical	Fitur
7	Spiders	Categorical	Fitur
8	Edema	Categorical	Fitur
9	Bilirubin	Continuous	Fitur
10	Cholesterol	Categorical	Fitur
11	Albumin	Continuous	Fitur
12	Copper	Categorical	Fitur
13	Alk_Phos	Continuous	Fitur
14	SGOT	Continuous	Fitur
15	Tryglicerides	Int	Fitur
16	Platelets	Int	Fitur
17	Prothrombin	Continuous	Fitur
18	Stage	Categorical	Fitur

3.3. Implementasi Teknik Seleksi Fitur (SF)

SF adalah proses memilih subset fitur yang paling relevan dari sekumpulan fitur yang ada dalam suatu dataset. Tujuan utama feature selection untuk mengukur kinerja model, mempercepat proses pelatihan, dan menghindari *overfitting* [6]. Dengan menghilangkan fitur yang tidak relevan atau berlebihan, model menjadi lebih sederhana, mudah dipahami, dan lebih efisien.

Kami melakukan seleksi fitur untuk menentukan fitur yang sangat berpengaruh terhadap prediksi kelangsungan hidup pasien Sirosis. Kami menggunakan teknik seleksi fitur Information Gain (IG), Gain Ratio (GR), dan Gini Decrease (GD). Ketiga metode tersebut mampu melakukan perangkian terhadap fitur yang memiliki bobot tertinggi hingga terendah [30]. Tabel 2 menampilkan delapan ranking fitur terbaik beserta bobot

Tabel 2. Fitur yang memiliki bobot tertinggi

Information Gain (IG)		Gain Ratio (GR)		Gini Decrease	
Fitur	Bobot	Fitur	Bobot	Fitur	Bobot
Bilirubin	0.217	Ascites	0.222	Bilirubin	0.122
N_Days	0.203	Bilirubin	0.108	N_Days	0.116
Copper	0.169	N_Days	0.101	Copper	0.097
Prothrombin	0.122	Edema	0.098	Prothrombin	0.070
SGOT	0.092	Copper	0.084	Stage	0.052
Stage	0.089	Hepatomegaly	0.084	SGOT	0.052
Ascites	0.087	Prothrombin	0.061	Hepatomegaly	0.052
Hepatomegaly	0.084	Stage	0.050	Ascites	0.047
Age	0.083	SGOT	0.046	Edema	0.042

3.4 Split Data

Proses membagi dataset menjadi dua bagian terpisah untuk kebutuhan yang berbeda. Bagian pertama untuk data latih dan bagian kedua untuk data uji. Kami menggunakan persentase dataset data latih 80%, dan data uji 20%. Hal ini dilakukan berdasarkan hasil pengujian yang menunjukkan bahwa persentase tersebut yang paling optimal pada kinerja model

3.5 Evaluasi Model


Pada tahap ini, model ML diterapkan pada dataset menggunakan k-fold=5 tanpa menggunakan dan menggunakan teknik seleksi fitur. Hasil dari tahap ini digunakan sebagai baseline untuk membandingkan performa model sebelum, dan sesudah seleksi fitur

diterapkan. Kinerja model menggunakan semua fitur ditampilkan dalam Tabel 3.

Tabel 3. Kinerja model menggunakan semua fitur

No	Model	Akurasi	Presisi	Recall
1	SVM	74.4	69.2	73.7
2	Tree	67.7	69.7	70.8
3	KNN	65.6	65.5	69.1
4	RF	74.2	71.3	73.7

Berdasarkan Tabel 3, setelah dilakukan perhitungan nilai rata-rata (Gambar 3), model SVM menunjukkan kinerja paling optimal menggunakan semua fitur, disusul Random Forest, Tree, dan kNN.




Gambar 3. Kinerja model menggunakan semua fitur

Selanjutnya kami melakukan evaluasi terhadap penggunaan teknik seleksi fitur untuk mendapatkan gambaran komprehensif dan temuan terhadap teknik yang digunakan. Evaluasi performa model dilakukan menggunakan metrik evaluasi berupa akurasi, presisi, dan recall. Hasil evaluasi (Tabel 4) dibandingkan untuk mengetahui pengaruh masing-masing teknik seleksi fitur terhadap performa model ML yang digunakan.

Tabel 2. Perbandingan kinerja model dan seleksi fitur

Model	Semua	IG	GR	GD
SVM	74.4	74.6	73.9	73.9
Tree	67.7	66.3	67.7	67.7
kNN	65.6	69.9	70.8	70.8
RF	74.2	72.5	73.7	74.4


Selanjutnya kami melakukan visualisasi untuk memudahkan melihat perbandingan kinerja model dan teknik seleksi fitur berdasarkan nilai rata-rata. Hasil perbandingan kinerja ditampilkan pada Gambar 4.



Gambar 4. Kinerja model dan seleksi fitur berdasarkan nilai rata-rata


Grafik (Gambar 4) menunjukkan bahwa model dan teknik seleksi fitur paling optimal

yaitu Random Forest (RF) dan Gini Decrease (GD). Random Forest menggunakan teknik ensemble learning yang menggabungkan banyak decision tree, sehingga mampu mengurangi overfitting. Selain itu, dengan seleksi fitur berbasis GD, dimana fitur yang paling berkontribusi terhadap pemisahan kelas yang dipertahankan. Kombinasi ini mengurangi noise dari fitur tidak relevan, sehingga akurasi dan generalisasi model meningkat. Selanjutnya kami melakukan perbandingan terhadap teknik seleksi fitur yang ditampilkan pada Gambar 5.



Gambar 5. Perbandingan kinerja teknik seleksi fitur

Berdasarkan grafik (Gambar 5) teknik GD memiliki kinerja terbaik, disusul GR, dan IG. Hal ini karena GD mampu mengukur seberapa besar suatu fitur menurunkan impurity. Hasilnya model menjadi lebih sederhana (Gambar 6)



Gambar 6. Peningkatan kinerja teknik seleksi fitur

Berdasarkan grafik (Gambar 6) secara umum penerapan teknik seleksi fitur meningkatkan kinerja model. Teknik seleksi

fitur IG meningkatkan kinerja 0.5%, GR 1.24%, dan GD 1.42%. Sehingga pada kasus ini, teknik GD menunjukkan kinerja optimal.

4 KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan teknik seleksi fitur memberikan pengaruh yang signifikan terhadap performa model ML dalam klasifikasi penyakit sirosis. Seleksi fitur mampu mengurangi jumlah fitur yang digunakan tanpa menurunkan, bahkan pada beberapa kasus meningkatkan, performa model klasifikasi.

Hasil evaluasi menunjukkan bahwa model yang menerapkan seleksi fitur memiliki akurasi, presisi, dan recall yang lebih baik dibandingkan dengan model tanpa seleksi fitur. Selain itu, penggunaan fitur yang lebih sedikit juga berdampak pada penurunan kompleksitas model dan peningkatan efisiensi komputasi.

Penelitian ini menunjukkan bahwa efektivitas teknik seleksi fitur bergantung pada model ML yang digunakan. Belum ditemukan teknik seleksi fitur yang secara konsisten memberikan performa terbaik pada seluruh model. Oleh karena itu, pemilihan kombinasi teknik seleksi fitur dan model ML yang tepat menjadi faktor penting dalam membangun model klasifikasi penyakit sirosis yang optimal.

Meskipun penelitian ini telah dilakukan secara sistematis, terdapat beberapa keterbatasan yang perlu diperhatikan, antara lain dataset yang digunakan berasal dari satu sumber sehingga belum sepenuhnya merepresentasikan variasi data pasien secara luas. Jumlah data yang digunakan relatif terbatas (418), sehingga berpotensi memengaruhi kemampuan generalisasi model.

Penelitian ini hanya menggunakan empat model ML (SVM, Tree, kNN, dan Random Forest) dan teknik seleksi fitur (IG, GR, dan GD), sehingga masih memungkinkan adanya metode lain yang dapat memberikan performa lebih baik. Evaluasi performa model belum mempertimbangkan aspek klinis secara mendalam, seperti interpretabilitas fitur dari sudut pandang medis.

Berdasarkan keterbatasan penelitian, beberapa saran yang dapat diberikan untuk penelitian selanjutnya yaitu menggunakan dataset yang lebih besar dan beragam, serta mengombinasikan data dari berbagai sumber untuk meningkatkan generalisasi model.

Menerapkan teknik seleksi fitur dan model ML yang lebih kompleks, seperti ensemble learning atau deep learning. Mengkaji aspek interpretabilitas model agar hasil penelitian dapat lebih mudah dipahami dan dimanfaatkan oleh tenaga medis. Mengintegrasikan model klasifikasi ke dalam sistem pendukung keputusan klinis sebagai langkah awal penerapan di dunia nyata.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam pelaksanaan penelitian ini, khususnya kepada para peneliti ML di fakultas Teknologi dan Informatika Universitas Aisyah Pringsewu. Ucapan terima kasih juga disampaikan kepada dokter dan dosen dari fakultas kesehatan yang telah membantu memverifikasi dataset. Semoga penelitian ini bermanfaat untuk semua pihak.

DAFTAR PUSTAKA

- [1] P. Ginès, A. Krag, J. G. Abraldes, E. Solà, N. Fabrellas, and P. S. Kamath, "Liver cirrhosis," *Lancet*, vol. 398, no. 10308, pp. 1359–1376, Oct. 2021, doi: 10.1016/S0140-6736(21)01374-X.
- [2] F. Ye *et al.*, "The burden of liver cirrhosis in mortality : Results from the global burden of disease study," *Front. Public Heal.*, vol. 10, no. 1, pp. 1–13, 2022, doi: 10.3389/fpubh.2022.909455.
- [3] V. P. Chavda, K. Patel, S. Patel, and V. Apostolopoulos, "Artificial Intelligence and Machine Learning in Healthcare Sector," in *Bioinformatics Tools for Pharmaceutical Drug Product Development*, 2023, pp. 285–314. doi: <https://doi.org/10.1002/9781119865728.ch13>.
- [4] J. Singh, S. Bagga, and R. Kaur, "Software-based Prediction of Liver Disease with Feature Selection and Classification Techniques," *Procedia Comput. Sci.*, vol. 167, pp. 1970–1980, 2020, doi: <https://doi.org/10.1016/j.procs.2020.03.226>.
- [5] H. Sulistiani, A. Syarif, K. Muludi, and Warsito, "Performance evaluation of feature selections on some ML approaches for diagnosing the narcissistic personality disorder," *Bull. Electr. Eng. Informatics*, vol. 13, no. 2, pp. 1383–1391, 2024, doi: 10.11591/eei.v13i2.6717.
- [6] F. Miao, Y. Wu, G. Yan, and X. Si, "Dynamic multi-swarm whale optimization algorithm

- based on elite tuning for high-dimensional feature selection classification problems,” *Appl. Soft Comput.*, vol. 169, p. 112634, 2025, doi: <https://doi.org/10.1016/j.asoc.2024.112634>.
- [7] M. Y. Shams, Z. Tarek, and A. M. Elshewey, “A novel RFE-GRU model for diabetes classification using PIMA Indian dataset,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–22, 2025, doi: 10.1038/s41598-024-82420-9.
- [8] S. Bashir, Z. S. Khan, F. H. Khan, A. Anjum, and K. Bashir, “Improving Heart Disease Prediction Using Feature Selection Approaches,” in *2019 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST)*, 2019, pp. 619–623. doi: 10.1109/IBCAST.2019.8667106.
- [9] C. Sharma and A. Singla, “Advanced PTSVM Based Breast Cancer Classification with Weighted Feature Selection,” *SN Comput. Sci.*, vol. 6, no. 1, p. 50, 2024, doi: 10.1007/s42979-024-03590-x.
- [10] M. J. Lee, “A review of liver fibrosis and cirrhosis regression,” *J. Pathol. Transl. Med.*, vol. 57, no. 2, pp. 189–195, 2023, doi: <https://doi.org/10.4132/jptm.2023.05.24>.
- [11] B. Mahesh, “Machine Learning Algorithms - A Review,” *Int. J. Sci. Res.*, vol. 9, no. 1, pp. 381–386, 2020, doi: 10.21275/art20203995.
- [12] A. B. R. Shatte, D. M. Hutchinson, and S. J. Teague, “Machine learning in mental health: a scoping review of methods and applications,” *Psychol. Med.*, vol. 49, no. 9, pp. 1426–1448, 2019, doi: DOI: 10.1017/S0033291719000151.
- [13] R. Iacob *et al.*, “Evaluating the Role of Breast Ultrasound in Early Detection of Breast Cancer in Low- and Middle-Income Countries: A Comprehensive Narrative Review,” 2024. doi: 10.3390/bioengineering11030262.
- [14] A. El Ghaly, “Hybrid ML Algorithm for Fault Classification in Transmission Lines Using Multi-Target Ensemble Classifier with Limited Data,” 2025. doi: 10.3390/eng6010004.
- [15] S. Huang, J. Yang, S. Fong, and Q. Zhao, “Artificial intelligence in the diagnosis of covid-19: Challenges and perspectives,” *Int. J. Biol. Sci.*, vol. 17, no. 6, pp. 1581–1587, 2021, doi: 10.7150/ijbs.58855.
- [16] R. Amilia and E. Prasetyo, “Klasifikasi Diagnosa Penyakit Demam Berdarah Dengue Pada Anak Menggunakan Metode K-Nearest Neighbor Studi Kasus Rumah Sakit Pku Muhammadiyah Ujung Pangkah Gresik,” *Indexia*, vol. 2, no. 2, pp. 1–10, 2021, doi: 10.30587/indexia.v2i2.2557.
- [17] F. Fadli and B. B. Butar, “Penerapan Decision Tree Menggunakan Algoritma C4.5 Untuk Deteksi Demam Berdarah Pada RS. IMC Bintaro,” *Indones. J. Softw. Eng.*, vol. 5, no. 1, pp. 75–86, 2019, doi: 10.31294/ijse.v5i1.5866.
- [18] A. Samosir, M. S. Hasibuan, W. E. Justino, and T. Hariyono, “Komparasi Algoritma Random Forest, Naïve Bayes dan K- Nearest Neighbor Dalam klasifikasi Data Penyakit Jantung,” *Pros. Semin. Nas. Darmajaya*, vol. 1, no. 0, pp. 214–222, 2021, [Online]. Available: <https://jurnal.darmajaya.ac.id/index.php/PSND/article/view/2955>
- [19] X. Song *et al.*, “Evolutionary computation for feature selection in classification: A comprehensive survey of solutions, applications and challenges,” *Swarm Evol. Comput.*, vol. 90, p. 101661, 2024, doi: <https://doi.org/10.1016/j.swevo.2024.101661>.
- [20] L. K. Singh, M. Khanna, and R. Singh, “Efficient feature selection for breast cancer classification using soft computing approach: A novel clinical decision support system,” *Multimed. Tools Appl.*, vol. 83, no. 14, pp. 43223–43276, 2024, doi: 10.1007/s11042-023-17044-8.
- [21] M. khanna, L. K. Singh, K. Shrivastava, and R. singh, “An enhanced and efficient approach for feature selection for chronic human disease prediction: A breast cancer study,” *Heliyon*, vol. 10, no. 5, Mar. 2024, doi: 10.1016/j.heliyon.2024.e26799.
- [22] J. Gao, Z. Wang, T. Jin, J. Cheng, Z. Lei, and S. Gao, “Information gain ratio-based subfeature grouping empowers particle swarm optimization for feature selection,” *Knowledge-Based Syst.*, vol. 286, p. 111380, 2024, doi: <https://doi.org/10.1016/j.knosys.2024.111380>.
- [23] P. Bhat and K. Dutta, “A multi-tiered feature selection model for android malware detection based on Feature discrimination and Information Gain,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 10, Part B, pp. 9464–9477, 2022, doi: <https://doi.org/10.1016/j.jksuci.2021.11.004>.
- [24] A. Tamilmani and M. Sughasiny, “Gain Ratio With Optimization Based Feature Selection Method,” *Webology*, vol. 18, no. 6, pp. 6545–6557, 2021.
- [25] M. Trabelsi, N. Meddouri, and M. Maddouri, “A New Feature Selection Method for Nominal Classifier based on Formal Concept Analysis,” *Procedia Comput. Sci.*, vol. 112,

- pp. 186–194, 2017, doi: 10.1016/j.procs.2017.08.227.
- [26] Y. Sang and X. Dang, “Grouped feature screening for ultrahigh-dimensional classification via Gini distance correlation,” *J. Multivar. Anal.*, vol. 204, pp. 1–25, 2024, doi: 10.1016/j.jmva.2024.105360.
- [27] F. Islam, R. Ferdousi, S. Rahman, and H. Y. Bushra, *Likelihood Prediction of Diabetes at Early Stage Using Data Mining Techniques*. London, 2019. doi: 10.1007/979-981-13-8798-2-12.
- [28] T. Yan, S.-L. Shen, A. Zhou, and X. Chen, “Prediction of geological characteristics from shield operational parameters by integrating grid search and K-fold cross validation into stacking classification algorithm,” *J. Rock Mech. Geotech. Eng.*, vol. 14, no. 4, pp. 1292–1303, 2022, doi: <https://doi.org/10.1016/j.jrmge.2022.03.002>.
- [29] Nurrahma, T. Muthia, and Y. E. Putra, “Perbandingan Akurasi Model Pembelajaran Mesin SVM , KNN , Decision Tree , dan Naive Bayes pada Klasifikasi Gangguan Kesehatan Mental,” *Electr. – J. Rekayasa dan Teknol. Elektro Perbandingan*, vol. 18, no. 3, pp. 363–368, 2024.
- [30] A. Wantoro, A. F. Yuliana, D. Yana, A. Andini, and I. Awaliyani, “Optimizing Type 2 Diabetes Classification with Feature Selection and Class Balancing in Machine Learning,” *J. Tek. Inform.*, vol. 6, no. 4, pp. 2625–2637, 2025.