

## **A SHAP-DRIVEN FEATURE SELECTION APPROACH FOR PREDICTIVE MODELING OF ACUTE ARTERIAL DISEASE**

<sup>1</sup>M. Afif Rizky A, <sup>2</sup>Muhammad Aldi Aulia Fathurohman, <sup>3</sup>Muhammad Fauzi Firdaus  
<sup>1,2,3</sup>Sistem Komputer, Universitas Pamulang, Serang

E-mail: <sup>1</sup>afifrizkyandika@unpam.ac.id, <sup>2</sup>03233@unpam.ac.id, <sup>3</sup>03039@unpam.ac.id

### **ABSTRAK**

Ketersediaan data telah lama menjadi tantangan dalam pengembangan model prediktif, khususnya pada domain medis. Tantangan ini terutama dipengaruhi oleh keterbatasan teknologi serta regulasi yang ketat, yang membatasi proses pengumpulan data dalam skala besar, padahal hal tersebut sangat penting untuk melatih model kecerdasan buatan yang andal. Akibatnya, model prediktif rentan mengalami overfitting dan sering kali gagal mencapai kinerja generalisasi yang optimal. Beberapa penelitian telah berupaya mengatasi permasalahan ini dengan menerapkan teknik reduksi dimensi seperti Principal Component Analysis (PCA); namun, pendekatan tersebut menjadi kurang efektif ketika ruang fitur relatif kecil dan interpretabilitas fitur tetap menjadi kebutuhan utama. Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan penggunaan Shapley Additive Explanations (SHAP) sebagai metode seleksi fitur pada tugas klasifikasi, dengan menggunakan dataset medis terkait penyakit arteri akut sebagai konteks penelitian. Seleksi fitur berbasis SHAP dinilai sangat sesuai pada kondisi data yang terbatas, karena mampu mengevaluasi kontribusi setiap fitur terhadap prediksi model secara independen, sehingga tetap menjaga interpretabilitas dan relevansi prediktif. Pada penelitian ini, proses seleksi fitur dilakukan dengan mempertahankan 11 fitur yang memiliki nilai SHAP di atas nilai baseline, kemudian dilanjutkan dengan proses klasifikasi menggunakan algoritma random forest. Hasil eksperimen menunjukkan bahwa model SHAP–Random Forest (SHAP-RF) mencapai kinerja yang lebih unggul pada dataset penyakit arteri koroner, dengan nilai ROC–AUC sebesar 0,96 dan AU–PRC sebesar 0,90. Kinerja tersebut melampaui metode seleksi fitur konvensional, termasuk PCA, seleksi fitur berbasis korelasi, serta seleksi fitur berbasis pengetahuan pakar. Secara keseluruhan, temuan penelitian ini menunjukkan bahwa seleksi fitur berbasis SHAP secara signifikan meningkatkan akurasi dan efisiensi model klasifikasi random forest, sehingga menjadi pendekatan yang kuat dan efektif untuk seleksi fitur dalam pemodelan prediktif medis, khususnya pada kasus penyakit arteri koroner.

**Kata kunci :** *Feature Selection, Klasifikasi, Acute Artery Disease, Shapley Additive Explanation, SHAP.*

### **ABSTRACT**

*Data availability has long been a challenge in the development of predictive models, particularly in the medical domain. This challenge is mainly driven by technological constraints and strict regulatory requirements that limit large-scale data acquisition, which is crucial for training robust artificial intelligence models. As a result, predictive models are prone to overfitting and may fail to achieve optimal generalization performance. Several studies have addressed this issue by applying dimensionality reduction techniques such as Principal Component Analysis (PCA); however, such approaches are less effective when the feature space is relatively small and feature interpretability remains essential. To address this problem, this study proposes the use of Shapley Additive Explanations (SHAP) as a feature selection method for classification tasks, using a medical dataset related to acute arterial disease as the study context. SHAP-based feature selection*

*is particularly suitable in constrained data scenarios, as it enables independent evaluation of each feature's contribution to model predictions, thereby preserving both interpretability and predictive relevance. In this research, feature selection was performed by retaining 11 features with SHAP values exceeding the baseline, followed by classification using a random forest algorithm. The experimental results demonstrate that the SHAP–Random Forest (SHAP-RF) model achieved superior performance on the coronary artery disease dataset, attaining a ROC–AUC of 0.96 and an AU–PRC of 0.90. These results outperform conventional feature selection approaches, including PCA, correlation-based feature selection, and domain expert–driven feature selection. Overall, the findings indicate that SHAP-based feature selection significantly enhances both the accuracy and efficiency of random forest classifiers, making it a robust and effective approach for feature selection in medical predictive modeling, particularly in the context of coronary artery disease.*

**Keyword :** *Feature selection, Classification, Acute Artery Disease, Shapley Additive Explanation, SHAP.*

## 1. PENDAHULUAN

Dalam pengembangan model prediktif, sering kali ditemukan bahwa data yang tersedia untuk proses pelatihan model berada dalam jumlah yang sangat terbatas, berlawanan dengan tren *big data* yang berkembang saat ini. Fenomena ini semakin umum terjadi pada domain yang mengutamakan privasi, seperti bidang kesehatan, keuangan, dan keamanan, di mana pengumpulan data dalam skala besar sering terhambat oleh berbagai kendala, termasuk regulasi privasi, keterbatasan teknologi, serta aksesibilitas data [1]. Salah satu solusi yang paling umum digunakan untuk mengatasi kondisi tersebut adalah dengan melakukan penambahan data secara sintetis, yang dikenal sebagai teknik *oversampling*, seperti *Synthetic Minority Over-sampling Technique (SMOTE)* [2]. Namun demikian, tantangan dalam proses validasi menjadi permasalahan yang signifikan, karena pada kondisi data yang terbatas, data sintetis sering kali tidak mampu merepresentasikan kondisi dunia nyata secara memadai. Kurangnya representativitas ini dapat menyebabkan *overfitting* pada distribusi sampel minoritas, mengingat data sintetis dihasilkan dengan mereplikasi atau menginterpolasi titik data yang

berdekatan dengan data asli. Selain itu, peningkatan volume data secara artifisial juga dapat menurunkan tingkat representativitas data terhadap permasalahan sebenarnya, yang pada akhirnya berdampak pada penurunan kinerja model prediktif [3].

Pengembangan model prediktif dari dataset berukuran kecil bukanlah permasalahan baru dan telah menjadi tantangan yang berkelanjutan dalam bidang machine learning. Dataset dengan jumlah sampel yang terbatas umumnya tidak memiliki keragaman dan kompleksitas yang cukup untuk memungkinkan model melakukan generalisasi secara efektif, sehingga menghasilkan kinerja yang kurang optimal ketika diterapkan pada data yang belum pernah dilihat sebelumnya [4]. Permasalahan ini menjadi semakin krusial pada domain berisiko tinggi seperti kesehatan dan keuangan, di mana keandalan dan akurasi model merupakan aspek yang sangat penting. Dalam kondisi tersebut, *overfitting* menjadi perhatian utama, karena model berpotensi mempelajari korelasi semu atau noise dari data yang terbatas, yang pada akhirnya menghasilkan prediksi yang bias atau tidak dapat diandalkan. Oleh karena itu, kemampuan untuk membangun model

prediktif yang akurat dan andal dari dataset berukuran kecil semakin menjadi tantangan utama di berbagai domain kritis [5], [6]. Dalam bidang kesehatan, misalnya, ketersediaan data sering kali terbatas akibat isu privasi, akses yang terbatas, serta rendahnya prevalensi beberapa kondisi medis tertentu. Meskipun demikian, kebutuhan akan model prediktif untuk mendukung pengambilan keputusan klinis terus meningkat. Pengembangan metode yang mampu mengekstraksi informasi bermakna dari dataset berukuran kecil tanpa mengorbankan akurasi model menjadi hal yang sangat penting untuk meningkatkan luaran pasien dan memastikan intervensi kesehatan berbasis data yang aman dan andal. Beberapa penelitian telah mencoba menggunakan metode yang kompleks, seperti large language model, dalam membangun model prediktif, namun belum menunjukkan peningkatan kinerja yang signifikan [7].

Secara umum, selain pendekatan berbasis model yang kompleks, terdapat dua teknik lain yang umum digunakan untuk mengoptimalkan kinerja model dan telah diterapkan pada dataset berukuran kecil guna mempelajari pengaruhnya terhadap model prediktif. Teknik pertama adalah reduksi dimensi, seperti Principal Component Analysis (PCA) [8]. Namun, PCA memiliki keterbatasan ketika diterapkan pada dataset berukuran kecil, karena sangat bergantung pada jumlah sampel dan sensitif terhadap noise. Sensitivitas ini dapat menyebabkan terbentuknya komponen utama yang menyesatkan, terutama ketika noise dan variansi yang tidak relevan memiliki pengaruh yang dominan, sehingga menurunkan efektivitas PCA dalam konteks tersebut. Selain itu, pada bidang krusial seperti kesehatan, interpretabilitas merupakan kebutuhan utama. PCA mentransformasikan fitur asli menjadi komponen abstrak, yang dapat

menyulitkan praktisi medis dalam memahami atau memvalidasi hasil model. Oleh karena itu, seleksi fitur menjadi teknik yang lebih relevan dalam kondisi data terbatas, karena melibatkan jumlah dimensi yang lebih sedikit serta memberikan manfaat yang lebih besar dibandingkan reduksi dimensi. Keunggulan utama seleksi fitur terletak pada kemampuannya untuk mempermudah pemahaman terhadap hasil prediksi, yang tidak ditawarkan oleh teknik reduksi dimensi [9]. Beberapa metode seleksi fitur tradisional, seperti koefisien korelasi yang termasuk dalam strategi filter, memiliki keterbatasan karena umumnya hanya mampu menangkap hubungan tertentu dan sering kali gagal merepresentasikan hubungan yang lebih kompleks dalam data [10], [11]. Metode lain adalah pendekatan wrapper, seperti Recursive Feature Elimination (RFE), namun metode ini berpotensi meningkatkan risiko overfitting karena sangat bergantung pada kinerja model tertentu selama proses seleksi fitur. Karena RFE mengevaluasi subset fitur berdasarkan kinerja model pada data pelatihan, metode ini dapat menangkap noise atau pola yang tidak relevan, terutama pada dataset berukuran kecil atau tidak seimbang [12].

Penelitian ini mengusulkan solusi alternatif untuk seleksi fitur yang bertujuan mengatasi tantangan pemodelan prediktif pada dataset berukuran kecil, dengan fokus pada tugas klasifikasi dan dapat diterapkan pada berbagai jenis data. Penelitian ini memanfaatkan Shapley Additive Explanations (SHAP) sebagai pendekatan seleksi fitur. Meskipun SHAP pada awalnya dikembangkan sebagai metode interpretabilitas model, pendekatan ini juga dapat dimanfaatkan secara efektif untuk seleksi fitur dengan mengidentifikasi fitur-fitur yang paling berkontribusi terhadap prediksi model, sehingga mampu meningkatkan kinerja dan interpretabilitas model secara

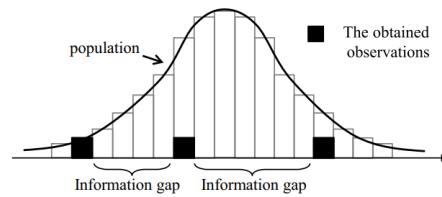
simultan [13], [14]. Kontribusi utama dari penelitian ini terletak pada analisis mendalam mengenai efektivitas SHAP sebagai metode seleksi fitur pada kondisi dataset berukuran kecil. Penelitian ini secara sistematis mengevaluasi kemampuan SHAP dalam meningkatkan akurasi dan ketahanan model pada lingkungan data yang terbatas, serta memberikan wawasan penting mengenai kesesuaianya dibandingkan dengan metode lain, seperti PCA [15].

## 2. LANDASAN TEORI

### 2.1 Karakteristik Keterbatasan Data

Data merupakan sekumpulan fakta mentah yang belum melalui proses pengolahan. Setelah diproses, data tersebut akan membentuk informasi yang memiliki makna dan dapat digunakan sebagai dasar pengambilan keputusan. Namun, dataset dengan ukuran sampel yang kecil dicirikan oleh keterbatasan jumlah observasi, yang secara signifikan dapat menghambat proses pengembangan model prediktif [16]. Dataset dengan karakteristik ini umumnya memiliki tingkat variabilitas yang rendah, sehingga membatasi kemampuan model dalam mempelajari distribusi data secara menyeluruh dan melakukan generalisasi yang baik terhadap data yang belum pernah diamati [17].

Secara metodologis, keterbatasan tersebut menimbulkan adanya celah informasi (information gaps) antar sampel, yang menyebabkan representasi ruang fitur menjadi tidak optimal. Kondisi ini menyulitkan algoritma pembelajaran untuk mengidentifikasi pola yang stabil dan bermakna, karena hubungan antar fitur tidak terobservasi secara memadai. Akibatnya, sebagian besar algoritma pembelajaran mesin cenderung menghasilkan model dengan tingkat ketidakpastian yang tinggi dan kinerja prediksi yang kurang akurat, khususnya ketika diterapkan pada data di luar data pelatihan [18].



**Gambar 1. Karakteristik Data Terbatas**

Selain itu, dataset dengan jumlah sampel yang kecil cenderung lebih sensitif terhadap keberadaan outlier dan noise, karena setiap titik data memiliki pengaruh yang relatif lebih besar terhadap perilaku model. Kondisi ini dapat menyebabkan model menghasilkan prediksi yang tidak akurat ketika diterapkan pada data baru. Lebih lanjut, dataset berukuran kecil sering kali memiliki representasi ruang permasalahan yang tidak lengkap atau tidak seimbang, sehingga menyulitkan model untuk menangkap keseluruhan variasi skenario atau kelas yang mungkin terjadi. Akibatnya, kinerja model menjadi menurun dan berpotensi menghasilkan prediksi yang bias [19].

### 2.2 Shapley Additive Explanation

Shapley Additive Explanations (SHAP) merupakan metode yang banyak digunakan untuk menjelaskan keluaran (output) dari model machine learning. Metode ini memberikan interpretasi yang sistematis dan mudah dipahami mengenai kontribusi masing-masing fitur terhadap prediksi model, dengan mendasarkan perhitungannya pada konsep nilai Shapley dari teori permainan. Nilai Shapley, yang diperkenalkan oleh Lloyd Shapley, digunakan untuk mendistribusikan kontribusi secara adil di antara setiap fitur sebagai "pemain" yang secara kolektif memengaruhi hasil prediksi model. Teori permainan yang dikemukakan dalam penelitian Lloyd Shapley berfokus pada analisis bagaimana sekelompok pemain dapat bekerja sama untuk mencapai keuntungan kolektif [20]. Teori ini mengkaji mekanisme pembagian keuntungan atau biaya di antara para pemain berdasarkan tingkat kontribusi masing-masing terhadap hasil akhir dari

kerja sama tersebut. Dalam kerangka ini, setiap pemain dinilai secara adil sesuai dengan perannya dalam menghasilkan hasil kolektif.

Berdasarkan konsep tersebut, SHAP mengadopsi ide untuk menghasilkan suatu nilai kuantitatif yang merepresentasikan kontribusi individu terhadap hasil kolektif dalam suatu skenario kerja sama. Dalam konteks model machine learning, nilai ini dikenal sebagai SHAP values, yang digunakan untuk mengukur kontribusi setiap fitur terhadap prediksi model secara bersifat aditif. Sifat aditif pada SHAP values menunjukkan bahwa kontribusi masing-masing fitur dapat dijumlahkan secara linear untuk membentuk total nilai prediksi model, sehingga memungkinkan interpretasi yang konsisten dan transparan terhadap perilaku model.

### 2.3 Feature Selection Process

Feature selection merupakan salah satu tahap penting dalam proses pemodelan machine learning yang bertujuan untuk memilih subset fitur yang paling relevan dan informatif dari keseluruhan fitur yang tersedia. Proses ini dilakukan untuk mengurangi kompleksitas model, meningkatkan kinerja prediksi, serta memperbaiki interpretabilitas model, khususnya ketika jumlah fitur relatif besar atau jumlah data terbatas. Dengan menghilangkan fitur yang tidak relevan, redundant, atau bersifat noise, feature selection membantu model dalam memfokuskan proses pembelajaran pada informasi yang paling berkontribusi terhadap target prediksi [21].

Secara konseptual, feature selection berbeda dengan reduksi dimensi. Feature selection mempertahankan fitur asli dengan memilih sebagian di antaranya, sedangkan reduksi dimensi, seperti Principal Component Analysis (PCA), mentransformasikan fitur ke dalam ruang fitur baru yang bersifat abstrak. Oleh karena itu, feature selection dinilai lebih sesuai untuk domain yang membutuhkan interpretabilitas tinggi, seperti bidang

kesehatan dan keuangan, karena hasil prediksi model tetap dapat ditelusuri kembali ke fitur-fitur asli yang memiliki makna nyata.

Tujuan utama dari feature selection meliputi beberapa aspek, yaitu meningkatkan akurasi, mengurangi overfitting, menurunkan biaya komputasi, serta meningkatkan stabilitas model terhadap variasi data. Dengan jumlah fitur yang lebih sedikit namun relevan, model cenderung lebih sederhana dan robust, sehingga mampu memberikan kinerja yang lebih baik pada data yang belum pernah diamati sebelumnya.

## 3. METODOLOGI

Penelitian ini bertujuan untuk mengatasi tantangan yang muncul dalam pemodelan prediktif akibat keterbatasan ukuran dataset dengan mengeksplorasi apakah seleksi fitur menggunakan Shapley Additive Explanations (SHAP) dapat menjadi solusi yang efektif pada kondisi tersebut. Secara khusus, penelitian ini berfokus pada pemahaman bagaimana SHAP dapat meningkatkan kinerja model dengan mengidentifikasi fitur-fitur yang paling relevan dalam konteks ketersediaan data yang terbatas. Dataset yang digunakan dalam penelitian ini berkaitan dengan penyakit jantung koroner dan dikumpulkan secara lokal dari sebuah rumah sakit melalui metode observasional. Dataset ini memiliki relevansi yang tinggi terhadap penelitian, karena mencerminkan kondisi nyata pengumpulan data di bidang kesehatan, di mana regulasi privasi dan rendahnya prevalensi beberapa kondisi medis sering kali mengakibatkan keterbatasan ketersediaan data. Pada bagian selanjutnya, akan disajikan penjelasan secara rinci mengenai teori SHAP serta algoritma machine learning yang digunakan dalam penelitian ini untuk mengevaluasi solusi yang diusulkan.

### 3.1 Classification Model

*Random Forest* merupakan salah satu algoritma ensemble learning yang dikembangkan oleh Breiman, yang bekerja dengan menggabungkan sejumlah besar pohon keputusan (decision trees) untuk menghasilkan prediksi yang lebih stabil dan akurat. Prinsip utama Random Forest adalah membangun banyak pohon keputusan secara independen dan mengombinasikan hasil prediksinya melalui mekanisme majority voting untuk klasifikasi atau averaging untuk regresi. Pendekatan ini bertujuan untuk mengurangi varians model dan meningkatkan kemampuan generalisasi dibandingkan dengan penggunaan satu pohon keputusan tunggal [22].

Pada proses pembentukannya, Random Forest menerapkan dua sumber utama keacakan, yaitu bootstrap sampling dan random feature selection. Bootstrap sampling dilakukan dengan mengambil sampel data latih secara acak dengan pengembalian (sampling with replacement) untuk membangun setiap pohon keputusan. Sementara itu, pada setiap node pemisahan (node split), hanya sebagian fitur yang dipilih secara acak untuk dipertimbangkan dalam proses pemisahan. Kombinasi kedua mekanisme ini menghasilkan pohon-pohon yang saling tidak berkorelasi, sehingga kesalahan yang dilakukan oleh satu pohon dapat dikompensasi oleh pohon lainnya dalam ensemble.

### 3.2 Tahapan Penelitian

Proses penelitian diawali dengan tahap data cleaning, yang mencakup penghapusan outlier, duplikasi data, serta penerapan standardisasi z-score untuk memastikan seluruh nilai berada pada skala yang sama. Setelah proses pembersihan data selesai, dataset dibagi menjadi data pelatihan dan data validasi. Data pelatihan digunakan untuk membangun model dasar, yang dalam penelitian ini menggunakan algoritma Random Forest. Selanjutnya, proses seleksi fitur dilakukan menggunakan nilai

SHAP untuk melakukan pemeringkatan setiap fitur berdasarkan kontribusinya terhadap prediksi model. Proses ini dilakukan melalui pendekatan embedded, di mana nilai SHAP dihitung selama tahap pelatihan model.

Dalam penelitian ini, proses seleksi fitur menggunakan SHAP diuji dengan beberapa skenario pembagian data, yaitu 70:30, 80:20, dan 90:10 untuk data pelatihan dan validasi. Eksperimen ini bertujuan untuk mengevaluasi bagaimana sifat lokal (*locality*) dari SHAP memengaruhi kinerja model pada berbagai skenario pembagian data. Melalui pengujian pada beberapa rasio pembagian data tersebut, penelitian ini berupaya memahami apakah interpretabilitas lokal yang dimiliki SHAP dapat memberikan peningkatan kinerja model yang konsisten, baik dari sisi akurasi maupun kemampuan generalisasi, meskipun jumlah data pelatihan secara bertahap dikurangi.

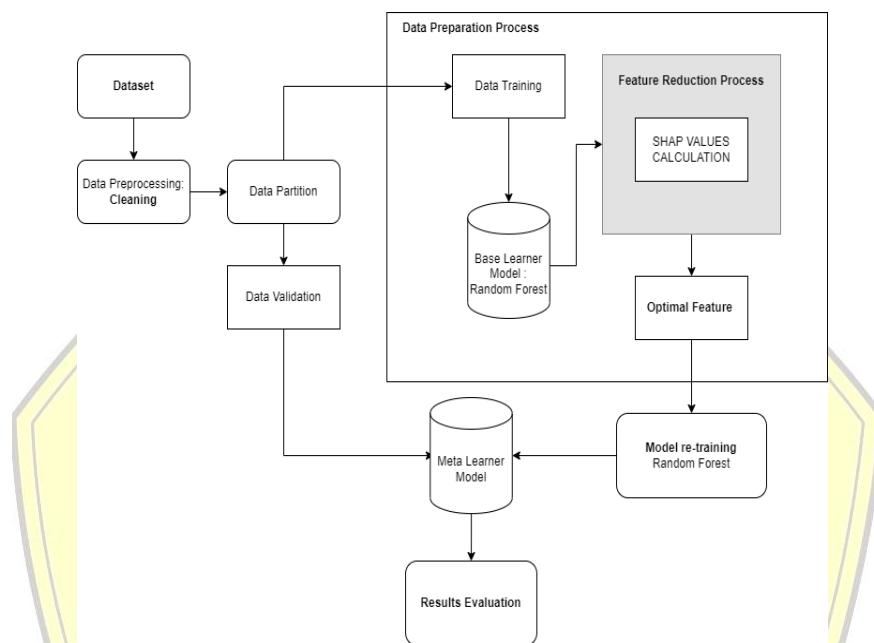
Untuk mengevaluasi efektivitas teknik seleksi fitur yang digunakan dalam penelitian ini, model klasifikasi dibangun setelah proses seleksi fitur dilakukan. Kinerja model dievaluasi menggunakan dua metrik utama, yaitu Area under the Precision–Recall Curve (AUPRC) dan Receiver Operating Characteristic–Area Under the Curve (ROC–AUC). AUPRC digunakan untuk mengukur keseimbangan antara precision dan recall pada berbagai ambang klasifikasi, sehingga sangat relevan untuk dataset yang tidak seimbang, di mana kasus AAD relatif lebih sedikit. Sementara itu, ROC–AUC digunakan untuk menilai kemampuan model dalam membedakan antara kelas AAD dan non-AAD pada berbagai nilai ambang. Kombinasi kedua metrik ini memberikan evaluasi yang komprehensif terhadap kinerja model klasifikasi pada dataset AAD yang tidak seimbang.

Berdasarkan evaluasi kinerja model klasifikasi yang telah dijelaskan

sebelumnya, penelitian ini selanjutnya berfokus pada analisis keluaran metode SHAP untuk mengidentifikasi jumlah serta tingkat relevansi fitur yang berkontribusi terhadap prediksi model. Efektivitas seleksi fitur berbasis SHAP kemudian diukur melalui analisis kinerja model klasifikasi yang dihasilkan. Selain itu, penelitian ini juga melakukan evaluasi

komprehensif, baik pada data yang merepresentasikan kondisi nyata di lapangan maupun pada data yang telah banyak digunakan dalam penelitian sebelumnya.

Dataset utama dikumpulkan secara mandiri dengan mengacu pada parameter klinis yang umum digunakan dalam kasus penyakit jantung, sebagaimana



Gambar 2. Tahapan Penelitian

komparatif untuk menilai kinerja model klasifikasi dengan seleksi fitur menggunakan SHAP dibandingkan dengan metode seleksi fitur konvensional lainnya. Sebagai langkah akhir, metode seleksi fitur berbasis SHAP dibandingkan dengan baseline dari penelitian-penelitian sebelumnya guna memastikan keunggulan dan konsistensi pendekatan yang diusulkan.

### 3.3 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari dua sumber utama, yaitu dataset yang dikumpulkan secara mandiri dan dataset publik yang digunakan sebagai pembanding. Penggunaan dua jenis dataset ini bertujuan untuk mengevaluasi efektivitas metode yang diusulkan secara lebih

direpresentasikan dalam dataset Heart Disease pada UCI Machine Learning Repository. Parameter-parameter tersebut mencakup variabel klinis dan demografis yang relevan terhadap diagnosis penyakit jantung, sehingga memastikan konsistensi dan keterbandingan struktur data dengan standar dataset publik yang telah mapan. Proses pengumpulan data dilakukan melalui metode observasional dengan memperhatikan aspek etika dan privasi data, sehingga dataset yang dihasilkan mencerminkan keterbatasan.

Sebagai pembanding, penelitian ini juga menggunakan dataset publik Z-Alizadeh Sani Coronary Artery Disease Dataset, yang secara luas digunakan dalam penelitian terkait penyakit jantung koroner. Dataset ini dipilih karena memiliki karakteristik klinis yang

sebanding serta telah digunakan sebagai benchmark dalam berbagai studi sebelumnya. Penggunaan dataset publik ini memungkinkan evaluasi yang lebih objektif terhadap kinerja metode seleksi fitur berbasis SHAP, sekaligus memastikan bahwa hasil penelitian tidak hanya bergantung pada satu sumber data.

#### 4. HASIL DAN PEMBAHASAN

Penelitian ini mengusulkan penggunaan SHAP sebagai metode

seleksi fitur yang dikombinasikan dengan algoritma Random Forest untuk tugas klasifikasi, khususnya dalam menghadapi kondisi keterbatasan jumlah sampel data. Dalam hal jumlah fitur, penelitian ini memfokuskan pada 11 fitur terpenting berdasarkan peringkat nilai SHAP tertinggi, yang kemudian diterapkan pada berbagai skenario pembagian data pelatihan dan validasi. Pendekatan ini dilakukan untuk menganalisis pengaruh sifat lokal (locality) SHAP terhadap kinerja model klasifikasi.

Tabel 1 Tabel Hasil Feature Selection SHAP

Size	SHAP-RF 70:30		SHAP-RF 80:20		SHAP-RF 90:10	
	ROC-AUC	AU-PRC	ROC-AUC	AU-PRC	ROC-AUC	AU-PRC
2	0.65	0.74	0.82	0.66	0.84	0.68
5	0.91	0.96	0.89	0.80	0.89	0.80
7	0.92	0.97	0.90	0.85	0.94	0.86
9	0.93	0.97	0.91	0.90	0.95	0.88
11	0.94	0.97	0.93	0.93	0.96	0.90

Berdasarkan Tabel 1, hasil evaluasi menunjukkan bahwa peningkatan jumlah fitur hasil seleksi SHAP secara konsisten meningkatkan kinerja model pada seluruh skenario pembagian data (70:30, 80:20, dan 90:10). Pada semua skenario, nilai ROC-AUC dan AU-PRC meningkat seiring bertambahnya jumlah fitur, dengan kinerja terbaik dicapai saat menggunakan 11 fitur terpilih. Skenario 90:10 menghasilkan performa tertinggi, dengan ROC-AUC mencapai 0,96 dan AU-PRC mencapai 0,90, mengindikasikan bahwa proporsi data pelatihan yang lebih besar berkontribusi terhadap kemampuan prediktif dan generalisasi model yang lebih baik.

Meskipun SHAP menghasilkan peringkat fitur yang berbeda pada setiap

skenario pembagian data akibat sifat lokalnya, variasi tersebut tidak berdampak negatif terhadap kinerja model. Sebaliknya, model tetap menunjukkan performa yang stabil dan tinggi di seluruh skenario, yang menunjukkan bahwa seleksi fitur berbasis SHAP mampu mempertahankan relevansi fitur secara kontekstual. Hasil juga menunjukkan bahwa penggunaan fitur yang terlalu sedikit menurunkan kinerja model, sementara penggunaan 7 hingga 9 fitur memberikan performa yang mendekati model dengan 11 fitur. Temuan ini menegaskan bahwa SHAP efektif sebagai metode seleksi fitur pada dataset berukuran kecil, dengan kemampuan menyeimbangkan kompleksitas model dan akurasi prediksi.

Tabel 2 Perbandingan Dengan Metode Feature Selection Lainnya

SHAP-RF		PCA-RF		CFS-RF		Expert knowladge	
ROC-AUC	AU-PRC	ROC-AUC	AU-PRC	ROC-AUC	AU-PRC	ROC-AUC	AU-PRC
0.96	0.90	0.88	0.89	0.84	0.90	0.75	0.86

Berdasarkan Tabel 2, eksperimen yang dilakukan dalam penelitian ini serta

perbandingan dengan metode seleksi fitur lainnya, model SHAP-RF mencapai

kinerja tertinggi dengan nilai ROC-AUC sebesar 0,96 dan AU-PRC sebesar 0,90, sehingga melampaui metode lainnya. Model PCA-RF menunjukkan kinerja yang cukup baik dengan ROC-AUC sebesar 0,88 dan AU-PRC sebesar 0,89, namun masih berada di bawah SHAP-RF pada kedua metrik tersebut. Model CFS-RF yang menggunakan metode tradisional berbasis tabel korelasi Pearson menunjukkan kinerja yang sedikit lebih rendah dibandingkan PCA-RF dengan ROC-AUC sebesar 0,84, meskipun memiliki nilai AU-PRC yang setara yaitu 0,90. Sebaliknya, metode seleksi fitur berbasis pengetahuan pakar menghasilkan kinerja terendah, dengan ROC-AUC sebesar 0,75 dan AU-PRC sebesar 0,86. Hasil ini menunjukkan bahwa fitur-fitur yang dipilih menggunakan SHAP secara konsisten meningkatkan kinerja model, yang mengindikasikan relevansinya dalam memprediksi dataset berukuran terbatas pada kasus penyakit arteri koroner. Meskipun demikian, validasi lebih lanjut dari perspektif medis tetap diperlukan untuk memastikan bahwa fitur-fitur tersebut memiliki makna klinis yang kuat.

## 5. KESIMPULAN

Terdapat tantangan dalam membangun model prediktif dengan data yang terbatas, karena kondisi ini dapat berdampak negatif terhadap kinerja model dan meningkatkan risiko terjadinya overfitting. Penelitian ini menganalisis apakah seleksi fitur dapat digunakan sebagai solusi, dengan SHAP (Shapley Additive Explanations) diterapkan sebagai metode utama seleksi fitur. Model SHAP-RF menunjukkan kinerja terbaik pada studi kasus dataset penyakit arteri koroner, dengan nilai ROC-AUC sebesar 0,96 dan AU-PRC sebesar 0,90. Selain itu, penelitian ini menerapkan beberapa skenario pembagian data latih dan validasi untuk mengkaji pengaruh sifat lokal (locality) SHAP pada dataset berukuran

terbatas. Hasil penelitian menunjukkan bahwa meskipun menggunakan dataset yang sama, SHAP menghasilkan peringkat fitur penting yang berbeda akibat sifat lokalnya. Hal ini menunjukkan bahwa perubahan dalam pengaturan eksperimen, seperti pembagian data, modifikasi model, atau penambahan skenario pengujian, dapat memengaruhi urutan fitur penting yang diidentifikasi oleh SHAP dan berpotensi berdampak pada kinerja model.

Berdasarkan hasil eksperimen, dapat disimpulkan bahwa SHAP dapat digunakan sebagai metode seleksi fitur pada dataset dengan jumlah sampel terbatas dalam konteks penyakit arteri koroner. Namun, penelitian ini masih memiliki beberapa keterbatasan yang dapat menjadi arah penelitian selanjutnya. Studi ini belum mengkaji pengaruh keberadaan noise dalam data maupun kemampuan SHAP dalam menangani nilai hilang (missing values), yang merupakan permasalahan umum pada dataset medis di dunia nyata. Selain itu, interaksi SHAP dengan data temporal atau sekuensial juga belum dianalisis, mengingat dataset yang digunakan bersifat statis. Penelitian selanjutnya dapat mengkaji aspek-aspek tersebut dengan memasukkan mekanisme penanganan noise serta mengevaluasi perilaku SHAP pada data deret waktu, guna meningkatkan penerapan SHAP sebagai metode seleksi fitur.

## DAFTAR PUSTAKA

- [1] A. Althnian et al., "Impact of dataset size on classification performance: An empirical evaluation in the medical domain," *Applied Sciences* (Switzerland), vol. 11, no. 2, pp. 1–18, Jan. 2021, doi: 10.3390/app11020796.
- [2] M. Waqar, H. Dawood, H. Dawood, N. Majeed, A. Banjar, and R. Alharbey, "An Efficient SMOTE-Based Deep Learning Model for Heart Attack Prediction," *Sci Program*, vol. 2021, 2021, doi: 10.1155/2021/6621622.

- [3] S. Hong, S. An, and J.-J. Jeon, "Improving SMOTE via Fusing Conditional VAE for Data-adaptive Noise Filtering," May 2024, [Online]. Available: <http://arxiv.org/abs/2405.19757>
- [4] D. C. Li, H. Y. Chen, and Q. S. Shi, "Learning from small datasets containing nominal attributes," *Neurocomputing*, vol. 291, pp. 226–236, May 2018, doi: 10.1016/j.neucom.2018.02.069.
- [5] R. J. Ellis, R. M. Sander, and A. Limon, "Twelve key challenges in medical machine learning and solutions," Jan. 01, 2022, Elsevier B.V. doi: 10.1016/j.ibmed.2022.100068.
- [6] A. Safanova, G. Ghazaryan, S. Stiller, M. Main-Knorn, C. Nendel, and M. Ryo, "Ten deep learning techniques to address small data problems with remote sensing," Dec. 01, 2023, Elsevier B.V. doi: 10.1016/j.jag.2023.103569.
- [7] Z. Shen, "Machine Learning Model for Heart Failure Prediction with Feature Selection and Data Expansion," in 2024 7th International Conference on Artificial Intelligence and Big Data, ICAIBD 2024, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 6–11. doi: 10.1109/ICAIBD62003.2024.10604567.
- [8] J. Spiegelberg and J. Rusz, "Can we use PCA to detect small signals in noisy data?," *Ultramicroscopy*, vol. 172, pp. 40–46, Jan. 2017, doi: 10.1016/j.ultramic.2016.10.008.
- [9] S. Galli, "Overview of Feature Selection," in Feature Selection in Machine Learning with Python, 2022, pp. 5–7.
- [10] G. Isabelle, "Filters for Feature Selection," in Feature Extraction Foundations and Applications. Pattern Recognition, Springer, 2006, pp. 109–111.
- [11] G. Chandrashekhar and F. Sahin, "A survey on feature selection methods," *Computers and Electrical Engineering*, vol. 40, no. 1, pp. 16–28, Jan. 2014, doi: 10.1016/j.compeleceng.2013.11.024.
- [12] R. Kohavi and G. H. John, "Wrappers for feature subset selection," 1996. [Online]. Available: <http://robotics.stanford.edu/>
- [13] Y. Gebreyesus, D. Dalton, S. Nixon, D. De Chiara, and M. Chinnici, "Machine Learning for Data Center Optimizations: Feature Selection Using Shapley Additive exPlanation (SHAP)," *Future Internet*, vol. 15, no. 3, Mar. 2023, doi: 10.3390/fi15030088.
- [14] H. Wang, Q. Liang, J. T. Hancock, and T. M. Khoshgoftaar, "Feature selection strategies: a comparative analysis of SHAP-value and importance-based methods," *J Big Data*, vol. 11, no. 1, Dec. 2024, doi: 10.1186/s40537-024-00905-w.
- [15] S. S. Shaukat, T. A. Rao, and M. A. Khan, "Impact of sample size on principal component analysis ordination of an environmental data set: Effects on eigenstructure," *Ekologia Bratislava*, vol. 35, no. 2, pp. 173–190, Jun. 2016, doi: 10.1515/eko-2016-0014.
- [16] Y. Saeys, I. Inza, and P. Larrañaga, "A review of feature selection techniques in bioinformatics," Oct. 01, 2007, Oxford University Press. doi: 10.1093/bioinformatics/btm344.
- [17] W. E. Marcilio and D. M. Eler, "From explanations to feature selection: Assessing SHAP values as feature selection mechanism," in Proceedings - 2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images, SIBGRAPI 2020, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, pp. 340–347. doi: 10.1109/SIBGRAPI51738.2020.00053.
- [18] C. Sebastián and C. E. González-Guillén, "A feature selection method based on Shapley values robust to concept shift in regression," Apr. 2023, doi: 10.1007/s00521-024-09745-4.
- [19] C. H. Tsai and D. C. Li, "Improving knowledge acquisition capability of M5' model tree on small

datasets,” in Proceedings - 3rd International Conference on Applied Computing and Information Technology and 2nd International Conference on Computational Science and Intelligence, ACIT-CSI 2015, Institute of Electrical and Electronics Engineers Inc., Nov. 2015, pp. 379–386. doi: 10.1109/ACIT-CSI.2015.72.

[20] S. Zhao, “A new algorithm for imbalanced datasets in presence of outliers and noise,” 2012 8th International Conference on Natural Computation, pp. 1–3, 2012.

[21] M. Kuhn and K. Johnson, “Feature Selection and Overfitting,” in Feature Engineering and Selection: A Practical Approach for Predictive Models, CRC Press, 2021, ch. 1, pp. 18–19.

[22] K. A. ElDahshan, A. A. A. AlHabshy, and L. T. Mohammed, “Filter and Embedded Feature Selection Methods to Meet Big Data Visualization Challenges,” Computers, Materials and Continua, vol. 74, no. 1, pp. 817–839, 2023, doi: 10.32604/cmc.2023.032287.

