

## Pengembangan Model Support Vector Machine untuk Meningkatkan Akurasi Klasifikasi Diagnosis Penyakit Jantung

Gantar Fitra Fahrudin<sup>1</sup>, Suroso<sup>2</sup>, Sopian Soim<sup>3</sup>

Program Studi Sarjana Terapan Teknik Telekomunikasi, Jurusan Teknik Elektro, Politeknik Negeri Sriwijaya, Jalan Sriwijaya Negara, Bukit Lama, Kec. Ilir Barat I, Palembang, Indonesia 30137  
e-mail: <sup>1</sup>fahrudingantar@gmail.com, <sup>2</sup>osorus11@gmail.com, <sup>3</sup>sopiansoim@gmail.com

Submitted Date: July 18<sup>th</sup>, 2024  
Revised Date: July 24<sup>th</sup>, 2024

Reviewed Date: July 19<sup>th</sup>, 2024  
Accepted Date: July 27<sup>th</sup>, 2024

### Abstract

Heart disease is a serious health issue that leads to high mortality risk worldwide. Contributing factors include high cholesterol, diabetes, and high blood pressure. Therefore, early prediction of heart disease is a crucial initial step to reduce mortality risk. This paper proposes a new heart disease classification model based on the Support Vector Machine (SVM) algorithm to enhance disease detection performance. To improve diagnostic accuracy, we apply feature selection techniques and grid search. The performance of the enhanced model is validated by comparing it with a simple model using a confusion matrix. The enhanced model achieves an accuracy of 96.56%, showing an improvement of 8.91% over the previous model, which had an accuracy rate of only 87.65%. Additionally, the number of features used is reduced from 14 to 8, decreasing the computational load from 100% to about 32%. These results indicate that the enhanced SVM provides better and more efficient performance compared to other methods in heart disease classification

Keywords: Support Vector Machine; Supervised Learning; Classification; Heart Disease

### Abstrak

Penyakit jantung merupakan salah satu masalah kesehatan serius yang menyebabkan risiko kematian tinggi di seluruh dunia. Faktor-faktor pemicunya meliputi kolesterol tinggi, diabetes, dan tekanan darah tinggi. Oleh karena itu, prediksi dini penyakit jantung adalah langkah awal yang sangat penting untuk mengurangi risiko kematian. Makalah ini mengusulkan model klasifikasi penyakit jantung baru yang berbasis algoritma *Support Vector Machine* (SVM) untuk meningkatkan performa deteksi penyakit. Untuk meningkatkan akurasi diagnosis, kami menerapkan teknik pemilihan fitur dan *grid search*. Kinerja model yang ditingkatkan divalidasi dengan membandingkannya dengan model sederhana menggunakan *confusion matrix*. Model yang ditingkatkan mencapai akurasi 96,56%, menunjukkan peningkatan akurasi sebesar 8,91% dibandingkan model sebelumnya yang hanya mencapai tingkat akurasi sebesar 87,65%. Selain itu, jumlah fitur yang digunakan dikurangi dari 14 menjadi 8, sehingga mengurangi beban komputasi dari 100% menjadi sekitar 32%. Hasil ini menunjukkan bahwa SVM yang ditingkatkan menawarkan kinerja yang lebih baik dan lebih efisien dibandingkan metode lain dalam klasifikasi penyakit jantung.

Keywords: Support Vector Machine; Supervised Learning; Klasifikasi; Penyakit Jantung

### 1 Pendahuluan

Pada saat ini, beban kerja yang meningkat secara signifikan telah menyebabkan keadaan yang sulit dihindari, yang meningkatkan kemungkinan seseorang menderita penyakit jantung (Das et al. 2020; Hasan, Jasim, and Hashim 2018; Rahman,

Saeed, Mohammed, Jaber, et al. 2022). Menurut studi Federasi Jantung Dunia tahun 2024, penyakit jantung menyebabkan jutaan kematian setiap tahun, pada tahun 2030. Tujuan Pembangunan berkelanjutan PBB bertujuan Untuk mengurangi angka kematian dini akibat penyakit tidak menular



hingga sepertiganya, upaya pencegahan terhadap penyakit kardiovaskular, seperti penyakit jantung dan stroke, menjadi krusial. Penyakit jantung paling banyak terkait dengan angina pektoris, kardiomiopati dilatasi, stroke, dan gagal jantung kongestif, di antaranya. Oleh karena itu, penting untuk memantau biomarker penyakit kardiovaskular (CVD) dan berkonsultasi dengan dokter Kesehatan (Javid, Khalaf, and Ghazali 2020; Mastoi et al. 2022; Muhsen, Khairi, and Alhamza 2021).

Sejak era teknologi belum ada, sampai sekarang manusia sudah mencapai era teknologi modern telah berkembang secara signifikan dalam bidang perawatan kesehatan. Di zaman modern setelah masuknya *Artificial intelligent* (AI) dalam bidang kesehatan dan kedokteran, hal ini menjadi kemajuan di bidang tersebut (Dinar, Zain, and Salehuddin 2018; Mohammed et al. 2020; Nasser et al. 2021; Soni et al. 2021). Dalam hal penyakit jantung, menentukan risiko seseorang mengalami gagal jantung secara dini merupakan perhatian utama (Diwakar et al. 2021; Rahman, Saeed, Mohammed, Krishnamoorthy, et al. 2022).

Studi tentang bagaimana komputer memperoleh pengetahuan melalui observasi dan pengalaman dikenal sebagai *machine learning*. Algoritma *machine learning* (ML) memiliki potensi untuk mengatasi berbagai masalah dalam pekerjaan pengganti manusia salah satunya mengdiagnosis seseorang terkena penyakit jantung atau tidaknya melalui data yang telah diberikan ke pada mesin untuk dipelajari, menganalisis dan menginterpretasikan kumpulan data yang besar menjadi lebih mudah dengan menggunakan alat dan metode ini. Penyakit jantung ditandai oleh beberapa faktor, termasuk usia, kolesterol, berat badan, tinggi badan, jenis kelamin, tekanan darah, EKG (elektrokardiogram) saat istirahat, nyeri dada, merokok, obesitas, dan kebiasaan makan (Elhoseny et al. 2021). Tantangan lain dalam bidang ini adalah banyaknya fitur yang digunakan dalam prediksi penyakit jantung, yang membuat tugas ini menjadi agak sulit. Selain itu, jumlah fitur yang banyak menyulitkan klasifikasi dalam pembelajaran mesin dan, pada gilirannya, mempengaruhi kinerja dan dengan demikian mengurangi nilai akurasi sistem ML.

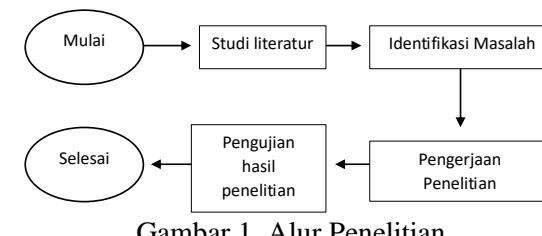
Beberapa penelitian terdahulu telah menginvestigasi prediksi penyakit jantung menggunakan dataset publik dari University of

California at Irvine (UCI) *machine-learning repository* (Janosi et al. 1988), dengan menggunakan berbagai metode prediksi. Penelitian sebelumnya (Kannan and Vasanthi 2019) mengaplikasikan *Logistic Regression*, *Random Forest*, *Stochastic Gradient Boosting*, dan *Support Vector Machine* dengan pembagian data 70%:30%, yang menunjukkan hasil yang menjanjikan. Namun, berdasarkan hasil yang diperoleh, metode *Logistic Regression* menghasilkan performa terbaik dengan AUC mencapai 91% dan akurasi mencapai 86%. Penelitian lainnya (Sarra et al. 2022) mencoba mengimprove satu algoritma yaitu *Support Vector Machine* (SVM) mendapatkan pengurangan setengah beban kompensial dan meningkatkan akurasi prediksi, menggunakan teknik pemilihan fitur optimal statistik. Kinerja model yang diusulkan kemudian divalidasi dengan membandingkannya dengan model tradisional menggunakan beberapa ukuran kinerja. Model yang diusulkan meningkatkan akurasi dari 85,29% menjadi 89,7%. Berdasarkan permasalahan tersebut maka penelitian selanjutnya akan mencoba meningkatkan akurasi dari SVM dengan cara menambahkan fitur *feature selection* dan *grid search* sebagai *hyperparameter tuning*.

## 2 Metode Penelitian

### 2.1 Kerangka Penelitian

Lihat gambar 1. Berikut adalah metodologi yang berisi tahapan-tahapan untuk melakukan penelitian dengan tujuan menentukan hasil yang sesuai dengan target penelitian. Kerangka dibuat dalam bentuk *flow chart* yang menggambarkan tahapan proses yang akan dilaksanakan selama penelitian.



Gambar 1. Alur Penelitian

Gambar 1 merupakan metodologi yang berisi tahapan-tahapan untuk melakukan penelitian dengan tujuan menentukan hasil yang sesuai dengan target penelitian. Kerangka dibuat dalam bentuk *flow chart* yang menggambarkan tahapan proses yang akan dilaksanakan selama penelitian.

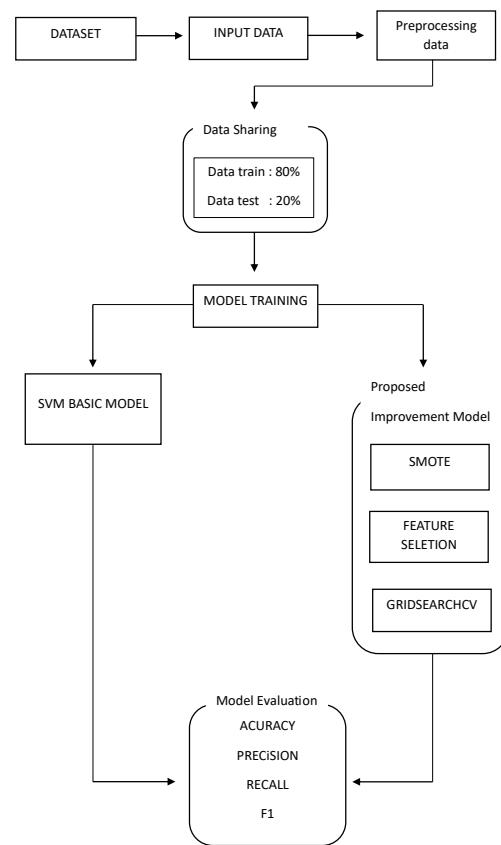


Penelitian ini dimulai dengan studi literatur yang berguna untuk mengumpulkan berbagai sumber yang mendukung sebagai referensi penelitian dengan topik pembahasan mengenai SVM, beberapa hasil dari studi literatur yang di dapatkan. Beberapa penelitian sebelumnya telah mengeksplorasi klasifikasi penyakit jantung menggunakan berbagai metode. Pada penelitian (Tougui, Jilbab, and El Mhamdi 2020), dilakukan perbandingan enam metode yaitu SVM, *Random Forest*, Regresi Logistik, KNN, ANN, dan *Naïve Bayes* dengan menggunakan enam alat yang berbeda, yaitu *Orange*, *RapidMiner*, *Weka*, *Matlab*, *Knime*, dan *Sci-Kit Learn*. Setiap metode diuji menggunakan keenam alat tersebut, dan hasil percobaan menunjukkan bahwa metode *Naïve Bayes* dan Regresi Logistik menunjukkan nilai akurasi yang signifikan dan stabil. Pada penelitian (Katarya and Meena 2021), dilakukan studi perbandingan dan analisis algoritma *machine learning* untuk memprediksi penyakit jantung. Algoritma yang dibandingkan termasuk Regresi Logistik, *K-nearest Neighbor* (KNN), *Support Vector Machine* (SVM), *Naïve Bayes*, *Decision Trees*, *Random Forest*, *Artificial Neural Network* (ANN), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN).

Langkah selanjutnya adalah proses pengerjaan penelitian dimana dalam proses ini akan dilakukan perancangan model *machine learning* untuk menghasilkan tingkat akurasi tertinggi menggunakan metode yang sudah di improvement untuk mengklasifikasi dari dataset pasien yang akan mendiagnosis pasien terkena penyakit jantung atau tidak. Hasil penelitian ini berupa kontribusi terhadap pengetahuan di metode *machine learning* klasifikasi SVM di bidang medis.

## 2.2 Perancangan Penelitian Model *Machine Learning*

Pada gambar 2 dibawah ini menunjukkan alur yang merupakan representasi langkah-langkah dalam mencapai hasil penelitian. Pembuatan alur perancangan bertujuan untuk memudahkan dalam memahami bagaimana sistematika pengerjaan mengenai proses kerja sistem, kita dapat memastikan agar setiap langkah yang dilakukan sudah direncanakan dengan sesuai.

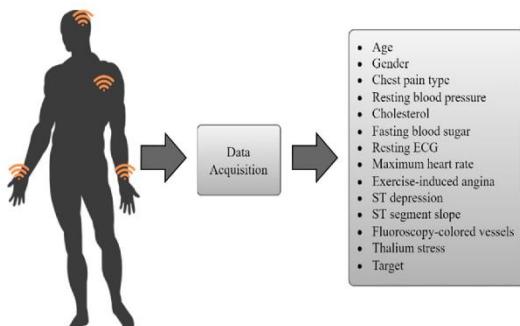


Gambar 2. Alur Perancangan Penelitian Model

### 2.3 Dataset Penelitian

Dalam penelitian ini, peneliti menggunakan dataset penyakit jantung yang tersedia untuk umum, set data Cleveland yang diperoleh dari repositori *machine learning* Universitas California di Irvine (UCI) <https://archive.ics.uci.edu/dataset/45/heart+disease> (Janosi et al. 1988). Data tersebut dipilih karena merupakan kumpulan data yang paling banyak digunakan oleh berbagai peneliti tentang prediksi penyakit jantung untuk menemukan efektivitas model mereka (Vijayashree and Parveen Sultana 2020). Dataset UCI ini berisi 303 kasus penyakit dan memiliki 76 fitur, Meskipun database penyakit jantung Cleveland memiliki 76 fitur yang berbeda, sebagian besar peneliti hanya menggunakan 14 di antaranya dalam eksperimen mereka (Ali et al. 2020). Pada gambar 3 fitur tersebut di meliputi 14 fiture yang di pakai *age*, *gender*, *chest pain type*, *resting blood sugar*, *resting ECG*, *Maximum Heart rate*, *exercise-induced angina*, *st depression*, *st segment slope*, *fluoroscopy-colored vessels*, *thallium stress*, *target*.





Gambar 3. Fitur Dataset

#### 2.4 Pre-Processing Data

Sebelum bisa digunakan, data harus dilakukan *pre-processing* terlebih dahulu agar menghasilkan *dataset* yang relevan untuk melakukan *training* pada model *machine learning*. Tahapan yang dilakukan pada proses ini seperti pembagian *dataset* menjadi data *training* dan data *testing*. Agar mencapai hasil evaluasi yang valid dilakukan pemisahan data menjadi dua jenis, yaitu *train*, *test*, dengan perbandingan 80%, 20% dari total 303 *dataset* UCI.

Tabel 1. Jumlah data pada setiap jenis data

| Jenis Data         | Presentase  | Jumlah Data |
|--------------------|-------------|-------------|
| TEST               | 20%         | 61          |
| TRAIN              | 80%         | 242         |
| <b>Jumlah</b>      | <b>100%</b> | <b>303</b>  |
| <b>Keseluruhan</b> |             |             |

#### 2.5 Evaluasi Model

Setelah membangun model SVM *basic* dan yang sudah *diimprovement*, langkah selanjutnya melakukan *testing* pada model. Melalui proses *testing* model akan didapatkan hasil evaluasi yang disebut dengan metrik *classification report* yang digunakan untuk mengukur kualitas prediksi algoritma klasifikasi. *Classification report* terbagi menjadi 4 parameter metrik yaitu akurasi, presisi, *recall* dan *F1-score*. Akurasi adalah seberapa sering model untuk dapat menentukan klasifikasi penyakit jantung. Presisi atau rasio prediksi adalah seberapa andal model bisa mengidentifikasi dengan meminimalkan kesalahan pada model atau Prediksi positif sejati dibandingkan dengan hasil positif sejati secara keseluruhan, *recall* adalah ukuran yang menggambarkan seberapa baik model dapat mengidentifikasi semua kasus yang benar-benar positif kemampuan model untuk mengidentifikasi secara akurat atau rasio prediksi benar positif dibandingkan dengan keseluruhan

data yang benar positif, dan *F1-score* adalah ukuran rata-rata gabungan dari presisi dan *recall*. Parameter metrik ini dapat dilihat menggunakan tabel 2 *confusion matrix* adalah metode pengujian yang digunakan untuk mengevaluasi kinerja algoritma *machine learning* (Terrada et al. 2019).

Tabel 2. Tabel *confusion matrix*

|                      | <b>False Positive</b> | <b>False Negative</b> |
|----------------------|-----------------------|-----------------------|
| <b>True positive</b> | TP                    | FN                    |
| <b>True Negative</b> | FP                    | TN                    |

Tabel yang digunakan untuk mengukur kinerja model klasifikasi dengan memberikan visualisasi hasil prediksi model dengan cara memberikan perbandingan antara data aktual dengan hasil prediksi yang dibuat oleh model. *Confusion Matrix* dapat digunakan untuk mengukur kinerja model untuk melihat seberapa baik model dalam melakukan kinerjanya. Hubungan antara *Confusion Matrix* dengan spesifikasi deteksi malware adalah sebagai berikut:

*True Positive* (TP) : Model berhasil mengidentifikasi bukan penyakit jantung

*True Negative* (TN) : Model berhasil mengidentifikasi Penyakit jantung

*False Positive* (FP) : Model mengidentifikasi tidak penyakit jantung sebagai penyakit jantung

*False Negative* (FN) : Model mengidentifikasi penyakit jantung sebagai tidak penyakit jantung.

*Confusion matrix* terdiri dari beberapa perhitungan (Derisma 2020):

##### 1. Presisi

Presisi adalah metrik untuk mengukur proporsi data yang diprediksi sebagai positif yang sebenarnya benar positif. Persamaan (1) dapat diterapkan untuk menghitung presisi (Derisma 2020; Mohan, Thirumalai, and Srivastava 2019; Santoso 2019).

$$\frac{TP}{(TP + FP)}$$

##### 2. Recall

*Recall* merupakan perhitungan untuk mengetahui jumlah data yang diprediksi benar positif dari keseluruhan data yang sebenarnya positif. Persamaan (2) dapat



digunakan untuk menghitung *recall* (Mohan et al. 2019; Santoso 2019; Terrada et al. 2019).

$$\frac{TP}{(TP + FN)}$$

### 3. F1 Score

*F1 score* adalah perhitungan untuk menentukan rata-rata harmonik dari *precision* dan *recall*. *F1 score* dapat dihitung dengan menggunakan Persamaan (3) (Derisma 2020; Mohan et al. 2019; Santoso 2019).

$$\frac{2(Precision \times Recall)}{(Precision + Recall)}$$

### 4. Akurasi

Akurasi merupakan perhitungan untuk mengetahui seberapa baik model dapat mengklasifikasikan dengan benar. Akurasi dapat dihitung menggunakan Persamaan (8) (Haq et al. 2018; Mohan et al. 2019; Santoso 2019).

$$\frac{(TP + TN)}{(TP + TN + FP + FN)}$$

## 3 Hasil dan Pembahasan

### 3.1 Fitur Dataset

Tabel 1 menunjukkan deskripsi atribut dari *dataset* yang digunakan dalam membuat model, yang memiliki jenis dan jumlah fitur. Dalam prediksi penyakit jantung, ada tiga belas atribut yang digunakan, dengan atribut terakhir berfungsi sebagai *output* yang menentukan apakah seseorang memiliki penyakit jantung.

Tabel 3. Deskripsi atribut *dataset* UCI

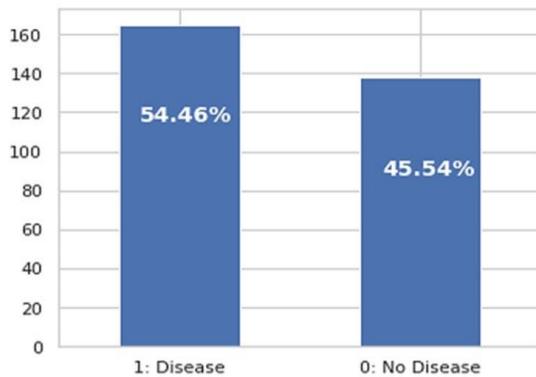
| Name     | Type       | Description  |
|----------|------------|--|
| Age      | Numeric    | Age in years   |
| Sex      | Categorial | 0 represents female and 1 represents male  |
| Cp       | Categorial | Type of chest pain categorized as follows: 1 = typical angina, 2 = atypical angina, 3 = non-anginal pain, 4 = asymptomatic |
| Trestbps | Numeric    | Resting blood pressure in  |

| Name    | Type       | Description  |
|---------|------------|--|
|         |            | millimeters of mercury (mm Hg)   |
| Chol    | Numeric    | Serum cholesterol measured in milligrams per deciliter (mg/dL)   |
| Fbs     | Categorial | Fasting blood sugar greater than 120 mg/dL represented as 0 for false and 1 for true   |
| Restecg | Categorial | Resting electrocardiography results categorized as follows: 0 = normal, 1 = ST-T wave abnormality, 2 = probable or definite left ventricular hypertrophy |
| Thalach | Numeric    | Maximum heart rate achieved during the thalium stress test   |
| Exang   | Categorial | Exercise-induced angina categorized as follows: 1 = yes, 0 = no  |
| Oldpeak | Numeric    | ST depression induced by exercise relative to rest   |
| Slope   | Categorial | Type of peak exercise ST segment slope categorized as: 1 = upsloping, 2 = flat, 3 = downsloping  |
| Ca      | Categorial | Number of significant vessels colored by fluoroscopy   |
| Thal    | Categorial | Thalium stress test results categorized as follows: 3 = normal, 6 = fixed defect, 7 = reversible defect  |
| Num     | Categorial | Heart disease status categorized as follows: 0 = less than 50% diameter narrowing, 1 = greater than 50% diameter narrowing                               |

### 3.2 Pre-Procesed Data

Distribusi data sangat penting ketika mencoba memprediksi (Bharti et al. 2021). Gambar 4 menggambarkan distribusi kelas atribut yang diharapkan untuk dua set data yang digunakan. Terdapat 138 orang dalam *dataset* Cleveland yang tidak memiliki penyakit jantung, dan 165 pasien dalam *dataset* yang memiliki penyakit jantung.





Gambar 4. Distribusi Kelas pada Data

Pada Gambar 5, peta panas digunakan untuk *correlation analysis of all attributes* dan target. Untuk setiap atribut, pada *heatmap's color indicates* menunjukkan sejauh mana atribut tersebut berkorelasi dengan semua atribut lainnya dan dengan kelas target keluaran. Secara umum, semakin kuat korelasinya, semakin hangat warnanya. Untuk *dataset Cleveland*, atribut target yang paling erat kaitannya dengan fitur *dataset Cleveland* adalah *exercise-induced depression*. In contrast, the Statlog dataset highlighted several features that exhibited the most robust correlations with the target variable, such as *thallium levels*, *number of major blood vessels*, *ST depression*, *exercise-induced angina*, *maximum heart rate achieved*, and *chest pain type*.



Gambar 5. Correlation Heat Map

Di bagian *cleaning* data, *dataset UCI* tidak terdapat *missing values* pada set data turunan. Dua masalah umum dalam sistem prediksi adalah *underfitting* dan *overfitting* dari data pelatihan. *Underfitting* terjadi ketika model yang dihasilkan tidak cukup belajar dari data pelatihan, yang

menghasilkan kinerja data pelatihan dan pengujian yang buruk. *Overfitting* terjadi ketika model belajar terlalu banyak dari data pelatihan dan mencapai hasil yang tidak memuaskan bahkan dari detail-detail kecil (Ali et al. 2019; Aliyar Vellameeran and Brindha 2022). Fitur-fitur yang tidak relevan dalam data pelatihan sering kali menyebabkan *overfitting* model. Bahkan jika model SVM berkinerja baik pada data pelatihan, model tersebut mungkin tidak dapat digeneralisasi dengan baik. Kami mengusulkan untuk menghilangkan fitur-fitur yang tidak relevan.

### 3.3 Peningkatan Akurasi Menggunakan Feature Selection dan Hyperparameter Tuning

Memiliki terlalu banyak fitur menyebabkan *overfitting*. Oleh sebab itu sangat penting untuk memilih data pelatihan dan pengujian untuk meningkatkan kinerja model. Fitur yang relevan dengan model ML dipilih, sedangkan fitur yang tidak relevan dibuang. Penelitian ini mengurangi *fiture* yang ada menggunakan metode *SelectKBest*. Berisi atribut *dataset feature* yang di gunakan untuk mendapatkan hasil akurasi yang optimal. Pada gambar 6.

```

best_selector
SelectKBest(k=8, score_func=<function chi2 at 0x7cfb3897c820>)

[38] best_selector.get_support(indices=True)
array([ 0,  3,  4,  6,  7,  9, 11, 12])

[43] feature_names = X_train.columns
selected_feature_names = feature_names[best_features_indices]
print(selected_feature_names)

Index(['age', 'trestbps', 'chol', 'restecg', 'thalach', 'oldpeak', 'ca',
       'thal'], dtype='object')

```

Gambar 6. Penerapan Seleksi Fitur oleh Selectkbest

Pada tabel 4, mendeskripsikan 8 fitur paling penting yang terseleksi untuk tujuan mentuning kinerja model pada klasifikasi diagnosa pasien dari data set UCI, lalu dari pemilihan *feature* tersebut dilakukan *hyperparameter tuning* untuk mendapatkan hasil yang lebih optimal.

Tabel 4. Deskripsi 8 fitur yang terpilih

| Nama     | Tipe    | Deskripsi                      |
|----------|---------|--------------------------------|
| Age      | Numeric | Age in years                   |
| Trestbps | Numeric | Resting blood pressure (mm hg) |



| Nama    | Tipe       | Deskripsi  |
|---------|------------|--|
| Chol    | Numeric    | Serum cholesterol (mg/dL)  |
| Restecg | Categorial | Resting electrocardiography results (0 = normal, 1 = ST-T wave abnormality, 2 = probable or definite left ventricular hypertrophy) |
| Thalach | Numeric    | Maximum heart rate achieved during thalium stress test   |
| Oldpeak | Numeric    | St depression induced by exercise relative to rest   |
| Ca      | Categorial | Number of significant vessels colored by fluoroscopy   |
| Thal    | Categorial | Thalium stress test result (3 = normal, 6 = fixed, 7 = reversible defect)  |

### 3.4 Pembahasan Model Evaluation

Dalam penelitian ini, melakukan percobaan perbandingan model SVM ditingkatkan dengan metode pemilihan fitur, pemilihan fitur yang digunakan seperti tabel 4 dan *hyperparameter tuning* menggunakan *grid search* 8 fitur paling penting yang terseleksi untuk tujuan mentuning kinerja model klasifikasi serta model dievaluasi

menggunakan Python dan pustaka belajar *sci-kit*. Lalu perbandingan dengan model yang menggunakan 14 fitur deskripsi fitur ada di tabel 3.

Pada pembahasan pertama *dataset* dengan total 14 fitur dinormalisasi, kemudian langsung digunakan untuk prediksi menggunakan pengklasifikasi SVM.

```
# See Training Accuracy
y_pred = svm_pipeline.predict(X_train)
print("Model Accuracy : ", accuracy_score(y_train, y_pred))
print("Classification Report: ", classification_report(y_train, y_pred))

Model Accuracy : 0.8765625
Classification Report:
precision    recall   f1-score   support
          0       0.88     0.88     0.88      130
          1       0.79     0.77     0.78      124
          2       0.89     0.88     0.88      135
          3       0.92     0.87     0.89      127
          4       0.91     0.98     0.94      124

accuracy                           0.88      640
macro avg       0.88     0.88     0.88      640
weighted avg    0.88     0.88     0.88      640
```

Gambar 7. Hasil Akurasi Model SVM dengan 14 Fitur

Seperti yang ditunjukkan pada gambar 7, dengan *dataset* dengan 14 fitur pengklasifikasian SVM mencapai hasil sebagai berikut di tabel 5.

Tabel 5. Performa model tanpa diimprovement

| Variabel target | Keterangan variabel           | Total Features | Precision | Recall | F1-score |
|-----------------|-------------------------------|----------------|-----------|--------|----------|
| 0               | Tidak ada penyakit jantung    | 14             | 0.88      | 0.88   | 0.88     |
| 1               | Penyakit jantung ringan       | 14             | 0.79      | 0.77   | 0.78     |
| 2               | Penyakit jantung sedang       | 14             | 0.89      | 0.88   | 0.88     |
| 3               | Penyakit jantung berat        | 14             | 0.92      | 0.87   | 0.89     |
| 4               | Penyakit jantung sangat berat | 14             | 0.91      | 0.98   | 0.94     |

Lalu pembahasan kedua metode seleksi fitur menggunakan *selectkbest* gambar 6. Pada *dataset* yang telah di normalisasi untuk mendapatkan 8 fitur yang paling signifikan untuk deteksi penyakit

jantung lalu menggunakan *grid search* pada pengoptimalan kinerja model.

Gambar 8. Berikut hasil dari akurasi dengan menggunakan pengoptimalan model SVM yang sudah diusulkan dengan hasil deskripsi di tabel 6.



```
[39] # See Training Accuracy
y_pred = grid_search.predict(X_train)
print('Model Accuracy :', accuracy_score(y_train, y_pred))
print("Classification Report: ", classification_report(y_train, y_pred))

Model Accuracy : 0.965625
Classification Report:
precision    recall    f1-score   support
          0       0.98     0.98      0.98     130
          1       0.92     0.93      0.92     124
          2       0.99     0.94      0.97     135
          3       0.95     0.98      0.97     127
          4       0.98     1.00      0.99     124

   accuracy                           0.97
  macro avg       0.97     0.97      0.97     640
weighted avg       0.97     0.97      0.97     640
```

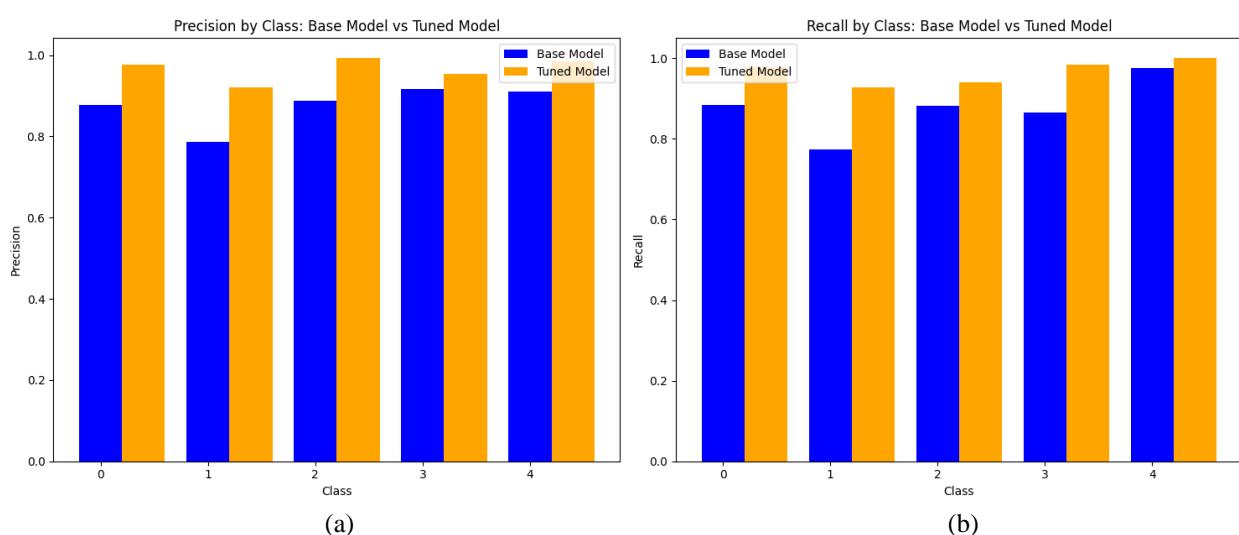
Gambar 8. Hasil *Training* Akurasi Model SVM Seleksi Fitur *Selectkbest*

Tabel 6. Performa model setelah *improvement*

| Variabel target | Keterangan variabel           | Total Features | Precision | Recall | F1-score |
|-----------------|-------------------------------|----------------|-----------|--------|----------|
| 0               | Tidak ada penyakit jantung    | 8              | 0.98      | 0.98   | 0.98     |
| 1               | Penyakit jantung ringan       | 8              | 0.92      | 0.93   | 0.92     |
| 2               | Penyakit jantung sedang       | 8              | 0.99      | 0.94   | 0.97     |
| 3               | Penyakit jantung berat        | 8              | 0.95      | 0.98   | 0.97     |
| 4               | Penyakit jantung sangat berat | 8              | 0.98      | 1.00   | 0.99     |

Hasil uji coba pembahasan dari kedua model ini ditunjukkan pada tabel 6. Dari gambar 6, dapat di tarik kesimpulan bahwa metode *feature selection* menggunakan *selectkbest* dengan menggunakan 8 fitur dari pengurangan 6 dari 14 fitur memainkan peran penting dalam meningkatkan akurasi model SVM, sekaligus meningkatkan hasil *precision*,

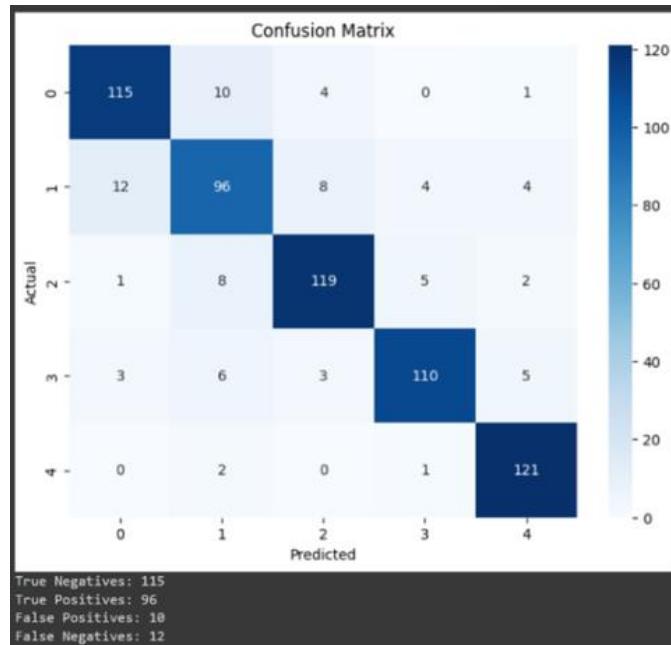
*recall*, *f1-score* yang menunjukkan kemampuan model untuk mengatasi mengidentifikasi dengan benar orang dengan dan tanpa penyakit jantung, model yang di improvisasi meningkatkan akurasi klasifikasi sebesar 0.97%. Sedangkan *base* model hanya mendapatkan hasil akurasi rata-rata sebesar 0.87%



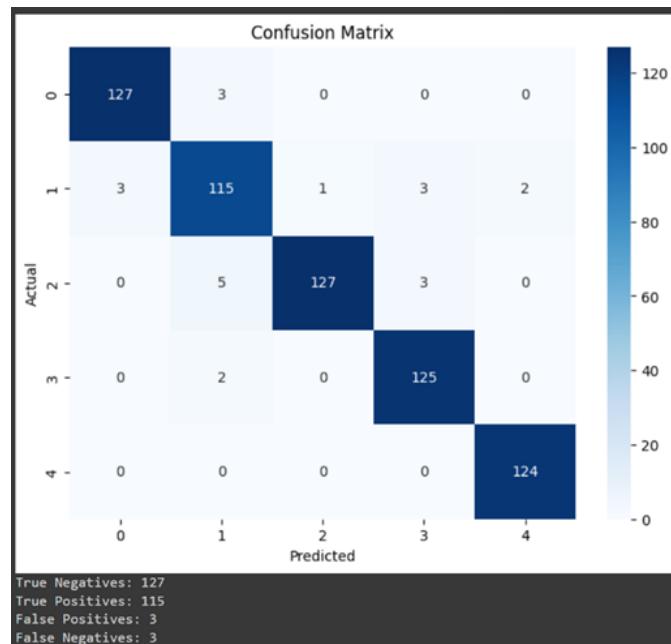
Gambar 9. Perbandingan Performa *Base Model* Vs *Tuned Model* (a) *Precision* (b) *Recall*

Untuk mengevaluasi model menggunakan confution matrix nilai parameter *True Positive* (TP) dan *False Negative* (FN) diletakkan dalam format seperti tabel. *Confution matrix* merangkum jumlah klasifikasi yang benar dan salah. Gambar 10 menggambarkan hasil dari *confusion matrix base* model SVM ini menunjukan bahwa *base model*

dapat dengan benar mendetksi ke 5 target dengan total *true negative* 115, *true positive* 96, *false positive* 10, *false negative* 12, yang kedua pada gambar. Gambar 11 menunjukan bahwa *tuned model* dapat mengungguli dan mengurangi tingkat kesalahan diagnosa dengan total *true negative* 115, *true positive* 96, *false positive* 10, *false negative* 12.



Gambar 10. *Confusion Matrix* dari *Base Model* dengan 14 Feature



Gambar 11. *Confusion Matrix Tuned Model*

Lebih lanjut, dalam hal akurasi dan jumlah fitur yang dipilih, model telah mengalami

perubahan yang signifikan dibandingkan yang sebelumnya yang sudah ada, seperti di tunjukan

pada gambar 9. Perbandingan performa *base* model vs *tuned* model terbukti berkinerja lebih baik daripada metode *base* model dengan akurasi 97%.

#### 4 Kesimpulan

Dalam penelitian ini, model yang *diimprovement* disempurnakan dan diimplementasikan untuk meningkatkan diagnosis penyakit jantung dan akurasi prediksi serta mengurangi beban komputasi. Algoritma *support vector machine* digunakan sebagai model klasifikasi untuk diagnosis penyakit jantung model ini dilakukan pada *dataset* penyakit jantung yang terkenal. set data Cleveland yang diperoleh dari repositori *machine learning* Universitas California di Irvine (UCI). Hasilnya menunjukkan peningkatan akurasi dari 87,65% menjadi 96,56% selain itu fitur yang digunakan dalam sistem dikurangi dari 14 menjadi 8 fitur, yang berarti beban komputasi berkurang dari 100% menjadi sekitar 32%. mengantisipasi bahwa penelitian ini akan berkontribusi pada pengembangan dan implementasi sistem prediksi dan diagnosis penyakit jantung di masa depan.

#### Referensi

- Ali, Liaqat, Atiqur Rahman, Aurangzeb Khan, Mingyi Zhou, Ashir Javeed, and Javed Ali Khan. 2019. "An Automated Diagnostic System for Heart Disease Prediction Based on  $\{\chi^2\}$  Statistical Model and Optimally Configured Deep Neural Network." *IEEE Access* 7:34938–45. doi: 10.1109/ACCESS.2019.2904800.
- Ali, Syed Arslan, Basit Raza, Ahmad Kamran Malik, Ahmad Raza Shahid, Muhammad Faheem, Hani Alquhaz, and Yogan Jaya Kumar. 2020. "An Optimally Configured and Improved Deep Belief Network (OCI-DBN) Approach for Heart Disease Prediction Based on Ruzzo-Tompa and Stacked Genetic Algorithm." *IEEE Access* 8:65947–58. doi: 10.1109/ACCESS.2020.2985646.
- Aliyar Vellameeran, Fathima, and Thomas Brindha. 2022. "A New Variant of Deep Belief Network Assisted with Optimal Feature Selection for Heart Disease Diagnosis Using IoT Wearable Medical Devices." *Computer Methods in Biomechanics and Biomedical Engineering* 25(4):387–411. doi: 10.1080/10255842.2021.1955360.
- Bharti, Rohit, Aditya Khamparia, Mohammad Shabaz, Gaurav Dhiman, Sagar Pande, and Parneet Singh. 2021. "Prediction of Heart Disease Using a Combination of Machine Learning and Deep Learning." *Computational Intelligence and Neuroscience* 2021:1–11. doi: 10.1155/2021/8387680.
- Das, Sujay, Ritesh Sharma, Mahendra Kumar Gourisaria, Siddharth Swarup Rautaray, and Manjusha Pandey. 2020. "Heart Disease Detection Using Core Machine Learning and Deep Learning Techniques: A Comparative Study." *International Journal on Emerging Technologies* 11(3):531–38.
- Derisma, D. 2020. "Perbandingan Kinerja Algoritma Untuk Prediksi Penyakit Jantung Dengan Teknik Data Mining." *Journal of Applied Informatics and Computing* 4(1):84–88. doi: 10.30871/jaic.v4i1.2152.
- Dinar, Ahmed M., Mohd Zain, and F. Salehuddin. 2018. *Utilizing Of Cmos Isfet Sensors In DNA Applications Detection: A Systematic Review*. Vol. 10.
- Diwakar, Manoj, Amrendra Tripathi, Kapil Joshi, Minakshi Memoria, Prabhisek Singh, and Neeraj kumar. 2021. "Latest Trends on Heart Disease Prediction Using Machine Learning and Image Fusion." *Materials Today: Proceedings* 37:3213–18. doi: 10.1016/j.matpr.2020.09.078.
- Elhoseny, Mohamed, Mazin Abed Mohammed, Salama A. Mostafa, Karrar Hameed Abdulkareem, Mashael S. Maashi, Begonya Garcia-Zapirain, Ammar Awad Mutlag, and Marwah Suliman Maashi. 2021. "A New Multi-Agent Feature Wrapper Machine Learning Approach for Heart Disease Diagnosis." *Computers, Materials & Continua* 67(1):51–71. doi: 10.32604/cmc.2021.012632.
- Haq, Amin Ul, Jian Ping Li, Muhammad Hammad Memon, Shah Nazir, and Ruinan Sun. 2018. "A Hybrid Intelligent System Framework for the Prediction of Heart Disease Using Machine Learning Algorithms." *Mobile Information Systems* 2018:1–21. doi: 10.1155/2018/3860146.
- Hasan, Tabreer T., Manal H. Jasim, and Ivan A. Hashim. 2018. "FPGA Design and Hardware Implementation of Heart Disease Diagnosis System Based on NVG-RAM Classifier." Pp. 33–38 in *2018 Third Scientific Conference of Electrical Engineering (SCEE)*. IEEE.
- Janosi, Andras, Steinbrunn, William, Pfisterer, Matthias, and Robert Detrano. 1988. *Heart Disease*.
- Javid, Irfan, Ahmed Khalaf, and Rozaida Ghazali. 2020. "Enhanced Accuracy of Heart Disease Prediction Using Machine Learning and Recurrent Neural Networks Ensemble Majority Voting Method." *International Journal of Advanced Computer Science and Applications* 11(3). doi: 10.14569/IJACSA.2020.0110369.



- Kannan, R., and V. Vasanthi. 2019. "Machine Learning Algorithms with ROC Curve for Predicting and Diagnosing the Heart Disease." Pp. 63–72 in.
- Katarya, Rahul, and Sunit Kumar Meena. 2021. "Machine Learning Techniques for Heart Disease Prediction: A Comparative Study and Analysis." *Health and Technology* 11(1):87–97. doi: 10.1007/s12553-020-00505-7.
- Mastoi, Qurat-ul-ain, Teh Ying Wah, Mazin Abed Mohammed, Uzair Iqbal, Seifedine Kadry, Arnab Majumdar, and Orawit Thinnukool. 2022. "Novel DERMA Fusion Technique for ECG Heartbeat Classification." *Life* 12(6):842. doi: 10.3390/life12060842.
- Mohammed, Mazin Abed, Karrar Hameed Abdulkareem, Alaa S. Al-Waisy, Salama A. Mostafa, Shumoos Al-Fahdawi, Ahmed Musa Dinar, Wajdi Alhakami, Abdullah Baz, Mohammed Nasser Al-Mhiqani, Hosam Alhakami, Nureize Arbaiy, Mashael S. Maashi, Ammar Awad Mutlag, Begona Garcia-Zapirain, and Isabel De La Torre Diez. 2020. "Benchmarking Methodology for Selection of Optimal COVID-19 Diagnostic Model Based on Entropy and TOPSIS Methods." *IEEE Access* 8:99115–31. doi: 10.1109/ACCESS.2020.2995597.
- Mohan, Senthilkumar, Chandrasegar Thirumalai, and Gautam Srivastava. 2019. "Effective Heart Disease Prediction Using Hybrid Machine Learning Techniques." *IEEE Access* 7:81542–54. doi: 10.1109/ACCESS.2019.2923707.
- Muhsen, Dena Kadhim, Teaba Wala Aldeen Khairi, and Noor Imad Abd Alhamza. 2021. "Machine Learning System Using Modified Random Forest Algorithm." Pp. 508–15 in.
- Nasser, Ahmed R., Ahmed M. Hasan, Amjad J. Humaidi, Ahmed Alkhayyat, Laith Alzubaidi, Mohammed A. Fadhel, José Santamaría, and Ye Duan. 2021. "IoT and Cloud Computing in Health-Care: A New Wearable Device and Cloud-Based Deep Learning Algorithm for Monitoring of Diabetes." *Electronics* 10(21):2719. doi: 10.3390/electronics10212719.
- Rahman, Atiqe Ur, Muhammad Saeed, Mazin Abed Mohammed, Mustafa Musa Jaber, and Begonya Garcia-Zapirain. 2022. "A Novel Fuzzy Parameterized Fuzzy Hypersoft Set and Riesz Summability Approach Based Decision Support System for Diagnosis of Heart Diseases." *Diagnostics (Basel, Switzerland)* 12(7). doi: 10.3390/diagnostics12071546.
- Rahman, Atiqe Ur, Muhammad Saeed, Mazin Abed Mohammed, Sujatha Krishnamoorthy, Seifedine Kadry, and Fatma Eid. 2022. "An Integrated Algorithmic MADM Approach for Heart Diseases' Diagnosis Based on Neutrosophic Hypersoft Set with Possibility Degree-Based Setting." *Life* 12(5):729. doi: 10.3390/life12050729.
- Santoso, Budi. 2019. "An Analysis of Spam Email Detection Performance Assessment Using Machine Learning." *Jurnal Online Informatika* 4(1):53. doi: 10.15575/join.v4i1.298.
- Sarra, Raniya R., Ahmed M. Dinar, Mazin Abed Mohammed, and Karrar Hameed Abdulkareem. 2022. "Enhanced Heart Disease Prediction Based on Machine Learning and X2 Statistical Optimal Feature Selection Model." *Designs* 6(5):87. doi: 10.3390/designs6050087.
- Soni, Mukesh, S. Gomathi, Pankaj Kumar, Prathamesh P. Churi, Mazin Abed Mohammed, and Akbal Omran Salman. 2021. "Hybridizing Convolutional Neural Network for Classification of Lung Diseases." *International Journal of Swarm Intelligence Research* 13(2):1–15. doi: 10.4018/IJSIR.287544.
- Terrada, Oumaima, Bouchaib Cherradi, Abdelhadi Raihani, and Omar Bouattane. 2019. "Classification and Prediction of Atherosclerosis Diseases Using Machine Learning Algorithms." Pp. 1–5 in *2019 5th International Conference on Optimization and Applications (ICOA)*. IEEE.
- Tougui, Ilias, Abdelilah Jilbab, and Jamal El Mhamdi. 2020. "Heart Disease Classification Using Data Mining Tools and Machine Learning Techniques." *Health and Technology* 10(5):1137–44. doi: 10.1007/s12553-020-00438-1.
- Vijayashree, J., and H. Parveen Sultana. 2020. "Heart Disease Classification Using Hybridized Ruzzo-Tompa Memetic Based Deep Trained Neocognitron Neural Network." *Health and Technology* 10(1):207–16. doi: 10.1007/s12553-018-00292-2.

