

Analisis Penyakit Jantung Menggunakan Metode Naive Bayes & Support Vector Machine (SVM)

Tasya Kamila

Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

Email: kamilatasya588@gmail.com

Abstrak– Tujuan utama dari penelitian ini adalah untuk menentukan model Klasifikasi antara Naive Bayes / Support Vector Machine (SVM) yang memiliki akurasi atau kinerja terbaik dalam memprediksi penyakit jantung terhadap data yang digunakan. Untuk mencari pengetahuan, proses KDD (Knowledge Discovery in Database) diterapkan dari proses preprocessing data, penambahan data, dan evaluasi hasil. Hasil klasifikasi kedua model tersebut kemudian dievaluasi dengan Test and Score (Cross Validation), Confusion Matric & ROC Analysis pada Orange mining. Hasil akhirnya, SVM lebih unggul dalam akurasi dan kinerja terbaik jika dibandingkan (Model Validasi Silang K-fold 10 dengan pembagian pelatihan 80:20 pengujian) Matriks Akurasi 92,3%, Skor F1 92,7%, Presisi 90,6%, Recall 94,9%, lebih unggul dari setiap matriks dibandingkan dengan Naive Bayes dengan nilai Akurasi 84,6%, F1-Score 85,2%, Presisi 84,1%, Recall 86,3% kemudian dalam Evaluasi Confusion Matriks Naive Bayes True Positive= 454, False Negatif= 72 dan model SVM True Positive= 499, False Negative= 27, SVM lebih unggul, kemudian pada Evaluasi ROC Analysis hasil SVM dengan nilai 0.8 di atas nilai dari Naive Bayes dengan nilai 0.6, Hasil Evaluasi menyimpulkan bahwa model dengan performa terbaik adalah SVM.

Kata Kunci: Data Mining, Classification, Naive Bayes, SVM, Orange Data Mining, Cross Validation, Confusion Matrix, ROC Analysis.

Abstract– The main objective of this study is to determine the classification model between Naive Bayes / Support Vector Machine (SVM) which has the best accuracy or performance in predicting heart disease on the data used. To find knowledge, the KDD (Knowledge Discovery in Database) process is applied from the process of data preprocessing, data mining, and evaluation of results. The results of the classification of the two models are then evaluated by Test and Score (Cross Validation), Confusion Matric & ROC Analysis in Orange mining. The final result, SVM was superior in accuracy and best performance when compared (K-fold 10 Cross-Validation Model with 80:20 training split of testing) Matrix Accuracy 92.3%, F1 Score 92.7%, Precision 90.6%, Recall 94.9%, superior to each matrix compared to Naive Bayes with an Accuracy value of 84.6%, F1-Score 85.2%, Precision 84.1%, Recall 86.3% then in the Confusion Evaluation of the Naive Bayes Matrix True Positive= 454, False Negative= 72 and the SVM model True Positive= 499, False Negative= 27, SVM was superior, then in the ROC Analysis Evaluation the results of SVM with a value of 0.8 above the value of Naive Bayes with a value of 0.6, the Evaluation Results concluded that the model with the best performance was SVM.

Kata Kunci: Data Mining, Classification, Naive Bayes, SVM, Orange Data Mining, Cross Validation, Confusion Matrix, ROC Analysis.

1. PENDAHULUAN

Fungsi jantung yang terganggu adalah dasar dari penyakit jantung, yang biasanya berkembang akibat pilihan gaya hidup yang buruk. Selain itu, kondisi ini dapat muncul pada usia muda maupun tua. Jelas bahwa ada banyak orang di Indonesia yang menderita penyakit jantung karena penyakit kardiovaskular (jantung dan stroke), menerima pendanaan terbanyak dalam program JKN pada tahun 2023, sebesar IDR 22,8 triliun[1]. Penyakit ini menjadi pengingat akan pentingnya menjalani gaya hidup sehat, yang mencakup makan dengan benar dan berolahraga. Untuk mendeteksi penyakit jantung diperlukannya pemeriksaan-pemeriksaan medis yang hasilnya dapat dilakukan diagnosa, Kini dengan banyaknya perubahan dalam hal teknologi diagnosa dapat dilakukan melalui proses penambahan data (*Data mining*) yang sering disebut analisis data dalam arti yang lebih umum sebagai proses mengubah data menjadi pengetahuan untuk pemecahan masalah dan pengambilan keputusan [2], dengan Teknik pembelajaran mesin (*Machine Learning*) untuk melakukan sebuah prediksi atau klasifikasi memakai metode *Supervised Learning* (pembelajaran terawasi) [3].

Klasifikasi diartikan sebagai proses menemukan definisi kesamaan karakteristik dalam sebuah kelompok atau kelas (*class*). Tujuannya untuk pengelompokan agar mudah dipelajari dan membantu menempatkan ke dalam kategori tertentu kemudian untuk melakukan prediksi kelas suatu objek yang labelnya belum diketahui [4]. Metode klasifikasi menggunakan pola pada data latihan (data yang telah dipelajari sebelumnya) untuk memproses kelas atau kategori yang ingin mengetahui 'ya' atau 'tidak' mengenai penyakit jantung dari data baru yang belum diketahui status ya/tidaknyanya.

Dari kumpulan *dataset* historis pasien penyakit jantung dilakukan penambahan dengan Algoritma klasifikasi yaitu Naive Bayes yang termasuk dalam pembelajaran mesin supervisi dan menggunakan metodologi berbasis probabilitas. menggunakan Teorema Bayes untuk menghitung kemungkinan kemunculan suatu kelas berdasarkan distribusi *fitur* dalam data [5]. Algoritma ini memanfaatkan konsep statistik melalui teori probabilitas

untuk menyelesaikan permasalahan *supervised learning*, yaitu jenis pembelajaran dimana data telah memiliki label kelas, atau *target* yang berfungsi sebagai acuan dalam proses pelatihan. [4]. Kekurangan Algoritma Naive Bayes dalam membuat keputusan, diperlukan pengetahuan awal mengenai masa sebelumnya. Pengetahuan awal tersebut krusial bagi keberhasilannya. Banyak kelemahan yang dapat membuatnya kurang efektif adalah karena hanya mengenali teks, bukan gambar. [6] dan memiliki keunggulan berupa komputasi yang cepat dan efektif. [7]

Dan penambahan dengan Algoritma Support Vector Machine (SVM) yang tujuannya adalah menentukan titik tertinggi *hyperplane* yang dapat digunakan untuk memperkirakan margin kedua kelas [8]. Secara teoritis, SVM mencari *hyperplane* terbaik untuk klasifikasi data. [9] SVM memiliki keunggulan dalam memaksimalkan jarak antara dua kelompok berbeda dengan menentukan garis pemisah yang optimal. Namun, SVM memiliki kendala dalam memilih *fitur* atau parameter yang tepat. Akurasi klasifikasi sangat dipengaruhi oleh pemilihan *fitur* dan prosedur penyetelan SVM. [10]

Aplikasi *Orange* kemudian dapat digunakan untuk mengeksekusi dengan kedua Algoritma ini. *Orange Data Mining* sebagai alat analisis interaktif di mana Antarmuka *Orange* berbasis *widget*, yang memungkinkan analisis modular mulai dari impor dan pra-pemrosesan data hingga visualisasi hasil. *Orange Data Mining* menawarkan sejumlah *widget* yang bekerja sama untuk menciptakan alur kerja yang metodis [11] Salah satu keuntungan dari aplikasi ini yang mudah digunakan dengan membuat alur kerja menggunakan *widget* yang dapat menjalankan tugas dan menyediakan visualisasi yang menarik.

Untuk permodelan semua langkah yang relevan, mulai dari mengakses dan memilih data hingga pembahasan data digunakan Konsep *Knowledge Discovery in Database* [12] dalam KDD terdiri dari 3 proses utama yaitu [13] : 1) *Preprocessing*: Sebelum memproses atau menggunakan Algoritma penambahan data, data harus terlebih dahulu menjalani prapemrosesan. Pembersihan, integrasi, seleksi, dan transformasi data merupakan beberapa langkah dalam proses ini. Tujuan dari langkah ini adalah mempersiapkan data untuk Algoritma penambahan data. 2) *Data mining*: Langkah utama KDD adalah penambahan data, ketika pengetahuan diekstraksi dari sumber data yang telah ada menggunakan metode penambahan data. 3) *Post processing*: Setelah proses penambahan data selesai, *post processing* dilakukan. Tujuan dari langkah ini adalah untuk menilai hasil/dievaluasi. Dan *Data mining* menjadi salah satu tahapan utama yang menentukan keberhasilan proses KDD.

Sementara KDD lebih fokus pada proses menemukan pengetahuan dalam basis data, penambahan data sering diterapkan lebih luas dan mencerminkan proses mendeteksi pola dalam data dari berbagai sumber [2].

Penggunaan Algoritma Naive Bayes & SVM dalam mengklasifikasi sudah pernah dilakukan sebelumnya pada penelitian lain dan diperoleh sebuah pengetahuan perbandingan kedua Algoritma pada klasifikasi kondisi penyakit hipertensi diperoleh model SVM bekerja lebih baik [14]. Lalu hasil terbaik pada model Naive bayes dalam mengklasifikasi penyakit diabetes [15]. Klasifikasi dalam menganalisis sentimen ulasan *e-commerce* menemukan model Naive Bayes bekerja lebih baik [5] Pada penelitian ini sama-sama menggunakan matriks evaluasi seperti akurasi, presisi, *recall*, dan evaluasi dengan *confusion matrix*.

Penelitian sebelumnya menghasilkan rata-rata, *recall*, dan akurasi sebesar 75.5%, 74.5%, 75% klasifikasi terbaik pada Algoritma Naive Bayes [15]. Penelitian lain Algoritma SVM menghasilkan akurasi terbaik 95,71%, kemudian presisi 89,00%, dan F1-score 89,00% [14]. Penelitian sebelumnya menggunakan matriks-matriks evaluasi yang masih terbatas dan belum menggunakan evaluasi lain seperti *Roc Analysis* untuk melihat performa kedua model dengan menetapkan ambang batas/*threshold* atau nilai batas untuk menentukan prediksi positif dan negatif serta membantu dalam memilih titik optimal untuk melihat performa Algoritma sesuai kebutuhan. Adanya keterbatasan/kesenjangan dalam matriks evaluasi sebelumnya seperti penggunaan *Roc Curva / Roc Analysis* dalam membedakan positif dan negatif dengan menentukan nilai batas/*threshold* belum diketahui oleh karna itu penelitian ini akan menggunakan *Roc Analysis*.

Berdasarkan uraian tersebut, Penelitian ini dilakukan untuk mengetahui kinerja Algoritma Naive Bayes dan SVM dalam diagnosis/prediksi status penyakit jantung akan menggunakan evaluasi dari *Test and Score (Cross Validation)*, matriks akurasi, presisi, *recall*, *f1-score*, *Confusion Matrix* dan evaluasi *ROC Analysis*

2. METODOLOGI PENELITIAN

2.1 Metode dan Sumber data

Metode yang dirancang untuk mencapai tujuan penelitian melalui beberapa proses atau tahapan di antaranya dengan beberapa proses KDD dimulai dengan ¹⁾ *PreProcessing* meliputi persiapan dan *Data Transformation* ²⁾ *Data Mining* dengan model klasifikasi Naive Bayes dan SVM ³⁾ Evaluasi Hasil.

Sumber data bersumber dari Situs Kaggle (*Public Health Dataset*) *Dataset* penyakit jantung berisi 1025 data 526 data *positive* penyakit jantung dan 499 *negativ* / tidak penyakit jantung dengan 14 *fiture*. Berikut link dari dataset: <https://www.kaggle.com/datasets/johnsmith88/heart-disease-dataset>

Tabel 1. Deskripsi *Fiture* dari *dataset*

No.	Nama Atribut/ <i>fiture</i>	Keterangan / Deskripsi
1	<i>Age</i>	Usia pasien
2	<i>Sex</i>	Jenis kelamin (1 = laki-laki, 0 = perempuan).
3	<i>Chest Pain Type</i>	Jenis nyeri dada (4 kategori): 1 = typical angina, 2 = atypical angina, 3 = non-anginal pain, 4 = asymptomatic.
4	<i>Resting Blood Pressure</i>	Tekanan darah saat istirahat (dalam mm Hg).
5	<i>Serum Cholesterol</i>	Kadar kolesterol dalam darah mg/dl.
6	<i>Fasting Blood Sugar</i>	Gula darah puasa > 120 mg/dl (1 = ya, 0 = tidak).
7	<i>Resting Electrocardiographic Results</i>	Hasil pemeriksaan EKG jantung saat istirahat (0 = normal, 1 = kelainan gelombang ST-T, 2 = hipertrofi ventrikel kiri).
8	<i>Maximum Heart Rate Achieved</i>	Detak jantung maksimum selama tes (olahraga).
9	<i>Exercise Induced Angina</i>	Apakah terjadi angina (nyeri dada) saat olahraga (1 = ya, 0 = tidak).
10	<i>Oldpeak</i>	penurunan grafik jantung yang diinduksi oleh latihan dibandingkan dengan kondisi istirahat.
11	<i>Slope of the Peak Exercise ST Segment</i>	Perubahan grafik jantung saat latihan (1 = naik, 2 = datar, 3 = turun).
12	<i>Number of Major Vessels Colored by Fluoroscopy</i>	Jumlah pembuluh darah utama yang terlihat tersumbat (0–3) yang terlihat melalui fluoroskopi.
13	<i>Thal</i>	Kondisi aliran darah ke jantung berdasarkan tes khusus. Status thalassemia (0 = normal, 1 = cacat tetap, 2 = cacat reversibel).
14	<i>Target (Diagnosis)</i>	Indikator adanya penyakit jantung (1 =, 0 = tidak).

2.2 PreProcessing & Data Miniing

Pada Tahapan ini data yang diperoleh disiapkan untuk dipastikan tidak ada data yang kosong dan dilakukan penentuan label kelas dan transformasi pada data value kolom *target* yang sebelumnya berisi 1/0 di rubah menjadi *Yes/No* memanfaatkan *Widget Edit Domain* kemudian untuk proses *mining* memanfaatkan *widget* Naive Bayes dan SVM dengan *karnel* RBF.

2.3 Proses Evaluasi

Pada Tahapan ini proses evaluasi dilakukan untuk penilaian model yang memiliki kinerja terbaik berdasarkan hasil evaluasi pada *widget Test and Score (Cross Validation)*, *Confusion Matrix*, *ROC Analysis*.

Analisis ROC membandingkan akurasi setiap model dalam klasifikasi biner. Studi ini dilakukan menggunakan *widget* analisis ROC pada aplikasi *Orange Data Mining*. Kurva yang mendekati 1 dalam analisis ROC merupakan model yang memberikan akurasi terbaik [16]

Confusion Matrix adalah tabel yang digunakan untuk mengukur kinerja model klasifikasi [17]. Untuk klasifikasi biner, *Confusion matrix* adalah matriks 2x2; untuk klasifikasi multikelas, matriksnya lebih besar. Matriks ini terdiri dari empat komponen, yang menggabungkan label aktual dengan hasil prediksi [18]. *True Positive* (TP): Jumlah sampel yang sebenarnya *positive* dan model memprediksi dengan benar sebagai positif. *True Negative* (TN): Jumlah sampel yang sebenarnya *negative* dan model memprediksi dengan benar sebagai negatif. *False Positive* yang sebenarnya (FP): Jumlah sampel negatif namun model salah memprediksi sebagai *positive*. *False Negative* (FN): Jumlah sampel *Positive* namun model salah memprediksi sebagai *Negative*. Nilai dari *Confusion matrix* kemudian dapat digunakan untuk perhitungan *Cross Validation*.

Tabel 1. *Confusion Matrix*

Kelas	Actual 0 Negative	Actual 1 Positive
Prediction 0 Negative	TN	FP
Prediction 1 Positive	FN	TP

Cross Validation membantu mengungkap sejauh mana sebuah model tangguh, yaitu akurasi dan keberhasilan klasifikasinya ketika diterapkan pada situasi baru atau berbeda [19]. menggunakan *K-Fold* 10, di mana *K-fold cross validation* adalah teknik yang digunakan untuk membagi data menjadi k... bagian dengan ukuran yang sama. Setiap bagian kemudian digunakan sebagai data uji sebanyak k... kali. Hasil akhir diperoleh dari rata-rata nilai yang diperoleh pada setiap kali pengujian [20]. matriks-matriks yang digunakan dalam *Cross Validation* dengan rumus sebagai berikut:

Accuracy

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

Recall

$$\frac{TP}{TP + FN} \quad (2)$$

Precision


$$\frac{TP}{TP + FP} \quad (3)$$

F1-Score

$$\frac{2 * (\text{Presisi} * \text{Recall})}{2 * (\text{Presisi} * \text{Recall}) + 1} \quad (4)$$


2.4 Alur Widget

Berikut Teknik Analisis Data pada *Orange* yang dijalankan dengan memanfaatkan *widget-widget* yang mewakili sebuah proses yang dibutuhkan.




Gambar 1. Alur hubungan *Widget*

Dari Gambar (1) Alur hubungan *Widget*. Proses pada Hitung dan pelatihan dalam mengklasifikasikan penyakit jantung Algoritma Naive Bayes dan SVM kernel RBF menggunakan alat/aplikasi *Orange mining* diawali *Widget File* untuk proses import data file heart.csv yang berisi dataset penyakit jantung dan menampilkan semua nama kolom termasuk kolom yang akan dijadikan label kelas. Perlu di perhatikan pada kolom yang dijadikan label agar kolom, (kolom target "role: target"). Selanjutnya Peneliti mengubah values 1/0 menjadi Yes/No dengan *widget Edite Domain*. Untuk melihat hasil dari perubahan tersebut digunakan *Widget Data Tabel*, Pada proses Data tabel ini peneliti dapat memastikan ada tidaknya data yang kosong, pada widget data tabel menampilkan "No missing data" yang artinya tidak ada data yang kosong kemudian peneliti dapat melihat berapa banyak data dan fitur yang ada sebagai bahan *training* dan *testing*. Berikut Gambar (2) *Widget Domain*:



Gambar 2. Widget Edit Domain

Selanjutnya menghubungkan *file heart.csv* melalui *Widget Data Tabel* dengan *Widget Naive bayes* dan *SVM (RBF Kernel parameter default orange.) setting model SVM* dengan pilihan *Type (SVM)* menandakan Nilai yang di dalam diformulasikan standar untuk SVM. $Cost (C) = 1.00$ Parameter regularisasi mengatur keseimbangan antara margin batas keputusan dan kesalahan klasifikasi pada data pelatihan. Nilai standar untuk keseimbangan adalah $C=1.00$. $Kernel = RBF$ Ini adalah keputusan yang penting. SVM dapat menemukan batas keputusan non-linier di ruang berdimensi tinggi berkat *kernel RBF*. Untuk data kompleks dengan hubungan *fitur* non-linier, seperti data medis, metode ini bekerja dengan sangat baik. $Iteration Limit = 100$ Batas Iterasi 100 Batas iterasi maksimum *optimisasi* numerik. Berikut Gambar (3) *Widget SVM*.




Gambar 3. Widget Edit Domain

Selanjutnya pada *Widget prediction* yang terhubung pada data tabel memprediksi 100% data sebagai data *training* dan *testing*. Selanjutnya widget-widget evaluasi yang akan menampilkan nilai yang menjadi penunjang keputusan pada kinerja model klasifikasi. Pada widget *Test and score* dengan *Cross Validation k-10* data dibagi 80 *training* dan 20% *testing* yang terhubung pada widget evaluasi *Confusion matrix* dan *ROC Analysis* dari pembagian data 80:20 tersebut.

3. HASIL DAN PEMBAHASAN

3.1 Evaluasi Test and Score (Cross Validaiton)

Widget Naive bayes dan SVM (RBF *Karnel*) dan *file* melalui *Widget* Data Tabel dengan *Widget* *Test and Score*, untuk melakukan Evaluasi *Scoring* akurasi, *Recall*, *F1-score*, AUC dengan *Test Type* : *Cross Validation* (K=10) dan perbandingan data *training:testing* 80:20 berikut tampilannya dari Evaluasi *Cross validation*:



Gambar 4 Hasil Evaluasi *Widget* *Test and Score*

Dari Gambar (4) di atas dapat diuraikan sebagai berikut: *Cross validation* dari 10 set pengujian berbeda, hasil Evaluasi pada *matrix-matrix* CA (*Accuray*), *F1*, *Prec*, *Recall* SVM lebih unggul dibanding Naive Bayes. Kemudian pada tabel bagian bawah terdapat “*Compare models by*” yang dapat menampilkan perbandingan statistik pada matriks tertentu sesuai pilihan untuk menunjukkan perbandingan probabilitas sebuah model lebih tinggi dibanding model lainnya, seperti pada gambar di atas terdapat hasil dari probabilitas pada *matrix Recall*. Matriks perbandingan berdasarkan hasil evaluasi pada tabel paling atas di mana *Recall* Naive bayes sebesar 0.863 sedangkan *Recall* untuk SVM sebesar 0.949 hasilnya lebih tinggi dibanding model Naive Bayes. Hasil dari Probabilitas pada matriks *Recall* kedua model menunjukkan bahwa model SVM adalah model yang lebih baik dibanding model lain. Dan Perbandingan model pada matriks akurasi di mana matriks ini menampilkan nilai perbandingan antra data yang diklasifikasi atau diprediksi dengan benar terhadap total data, dengan hasil model SVM lebih tinggi 0.923 sedangkan Naive Bayes 0.846. Pada matriks *F1-Score* yang menggabungkan hasil presisi dengan *recall* dengan nilai SVM 0.927 sedangkan Naive Bayes 0.852. lalu Matriks Presisi yang dihitung dengan membagi data *positive* dengan jumlah data yang diprediksi dengan benar, model SVM 0.906 dan Naive Bayes 0.841.

3.2 Evaluasi Confusion Matrix

		Predicted	
		No	Yes
Actual	No	447	52
	Yes	27	499
Σ		474	551

Gambar 5. Hasil *Widget* Evaluasi *Confusion Matrix* Model SVM

		Predicted	
		No	Yes
Actual	No	413	86
	Yes	72	454
Σ		485	540


Gambar 6. Hasil *Widget* Evaluasi *Confusion Matrix* Model Naive Bayes

Gambar (5) & (6) menunjukkan nilai kalsifikasi *Confusion Matrix* di mana kolom berwarna memiliki arti yaitu biru sebagai keberhasilan prediksi dan warna pink sebagai kegagalan/kekeliruan prediksi oleh model SVM. Dari gambar (5) di atas nilai dapat dijabarkan sebagai berikut : *True Positive* (TP): Jumlah sampel yang sebenarnya *positive* dan model memprediksi dengan benar sebagai positif adalah 499. *True Negative* (TN): Jumlah sampel yang sebenarnya *negative* dan model memprediksi dengan benar sebagai negatif adalah 447. *False Positive* yang sebenarnya (FP): Jumlah sampel negatif namun model salah memprediksi sebagai *positive* adalah 52. *False Negative* (FN): Jumlah sampel *Positive* namun model salah memprediksi sebagai *Negative* adalah 27.

Model Naive Bayes dari gambar (6) atas nilai dapat dijabarkan sebagai berikut: *True Positive* (TP): Jumlah sampel yang sebenarnya *positive* dan model memprediksi dengan benar sebagai positif adalah 454. *True Negative* (TN): Jumlah sampel yang sebenarnya *negative* dan model memprediksi dengan benar sebagai negatif adalah 413. *False Positive* yang sebenarnya (FP): Jumlah sampel negatif namun model salah memprediksi sebagai *positive* adalah 86. *False Negative* (FN): Jumlah sampel *Positive* namun model salah memprediksi sebagai *Negative* adalah 72.

Berdasarkan Hasil kedua model pada 1025 data dengan kasus positif sebanyak 526 dan 499 *Negative*. *Target Yes* dapat diuraikan sebagai berikut: Dari seluruh data diprediksi benar *True Positive* = 454 dan banyak prediksi yang tidak terdeteksi *False Negative* = 72, Sedangkan pada model SVM dengan banyaknya yang berhasil diprediksi benar *True Positive* = 499 dan banyak prediksi yang tidak terdeteksi *False Negative* = 27.


3.3 Evaluasi RoOC Analysis




Gambar 7. Hasil Widget Evaluasi Roc Analysis dua Model SVM & Naive Bayes

Dari Gambar (7) di dapat dilihat *Target Yes* dengan beberapa pengaturan *Default threshold (0.5)* point yang artinya jika nilai probabilitas dari hasil prediksi lebih besar dari 0.5 atau sama dengan 0.5 akan dibaca sebagai kelas *Yes*, sebaliknya jika di bawah maka akan dibaca *No*, namun pada proses ini dapat dilihat bahwa model Naive Bayes menghasilkan *threshold* atau Ambang batas probabilitas dengan nilai 0.489 bukan 0.5 atau 0.500, ini terjadi dikarenakan "*Merge Predictions from Folds*" dipakai di mana skor probabilitas prediksi tiap model dikumpulkan semua pada setiap *testing fold* sebanyak 10 iterasi.

Pada Model *Naive Bayes* sistem mencari nilai atau *score* yang mendekati 0.500 yaitu 0.489. Lalu dapat dilihat TP Rate (*Sensitivity*) sebagai *True Positive Rate* (Sumbu Y) yang berada garis ke atas dan FP Rate (*1-Specificity*) sebagai *False Positive Rate* (sumbu X) yang berada di bawah di mana penulis mengharapkan nilai tinggi pada *Sensitivity* dan nilai rendah pada *1-Specificity*, nilai tinggi mendekati 1 dan rendah mendekati 0.



Gambar 8. Hasil Roc Analysis Model Naive Bayes



Gambar 9. Hasil Roc Analysis Model SVM

Berdasarkan Hasil evaluasi dari Gambar (8) & (9) Hasil Roc Analysis di atas dapat diuraikan sebagai berikut : Model *Naive bayes* dengan *threshold* 0.489 memperoleh TP Rate 0.6 & Model SVM dengan *threshold* 0.500 memperoleh TP Rate 0.8

3.4 Perbandingan Manual Test and Score

Dari Hasil *Confusion Matrix* Peneliti dapat memphitungkan Hasil dari *Test and Score* dengan Rumus yang dipaparkan sebelumnya untuk mengetahui proses perhitungan yang terjadi. Dan Hasilnya Pada Model *Naive bayes* & SVM Akurasi, *F1-Score*, Presisi, *Recall* sesuai dengan hasil pada *Widget Test and Score*.

Tabel 2. Perhitungan *test and score* model SVM

Kelas	Actual 0 Negative	Actual 1 Positive	
Prediction 0 Negative	447 (TN)	52 (FP)	499
Prediction 1 Positive	27 (FN)	499 (TP)	526
	498	527	1025
Akurasi	<i>Recall</i>	Presisi	<i>F1-Score</i>
$\frac{TP + TN}{TP + TN + FP + FN}$	$\frac{TP}{TP + FN}$	$\frac{TP}{TP + FP}$	$\frac{2 * (Presisi * Recall)}{Presisi + Recall}$
$\frac{454 + 413}{1025}$	$\frac{499}{526 + 499}$	$\frac{499}{551}$	$\frac{1,718279243}{1,854295336}$
0,922926829 ≈0.923	0,948669201 ≈0.949	0,905626134 ≈0.906	0,926648097 ≈0.927

Tabel 3. Perhitungan test and score model Naïve Bayes

Kelas	Actual 0 Negative	Actual 1 Positive	
Prediction 0 Negative	413 (TN)	86 (FP)	499
Prediction 1 Positive	72 (FN)	454 (TP)	526
	485	540	1025
Akurasi	Recall	Presisi	F1-Score
$\frac{TP + TN}{TP + TN + FP + FN}$	$\frac{TP}{TP + FN}$	$\frac{TP}{TP + FP}$	$\frac{2 * (Presisi * Recall)}{Presisi + Recall}$
$\frac{454 + 413 = 867}{1025}$	$\frac{454}{454 + 72 = 526}$	$\frac{454}{454 + 86 = 540}$	$\frac{2 * (0.841 * 0.863)}{0.841 + 0.863}$
≈ 0.846	≈ 0.863	≈ 0.841	≈ 0.852

3.5 Penelitian Lain

Pada penelitian lain yang melakukan klasifikasi kondisi penyakit hipertensi dengan hasil SVM bekerja lebih baik diketahui hasil *test and score Cross Validation*. Pada penelitian ini Algoritma NB dan CSV digunakan dalam studi ini sebagai dasar untuk membuat sistem deteksi dini yang memprediksi dan menilai status hipertensi dan non-hipertensi. Rasio 70:30 digunakan untuk membagi *dataset* menjadi data pelatihan dan data uji. Temuan menunjukkan bahwa SVM berkinerja lebih baik dibandingkan algoritma lainnya dan bahwa algoritma-algoritma tersebut mampu mengklasifikasikan kondisi hipertensi dengan akurat [14].

Pada penelitian lainnya menggunakan dua metode pengujian persentase *split* dan *k-fold cross validation* untuk membandingkan algoritma SVM dan Naive Bayes dalam konteks diabetes. Data dibagi menjadi data uji (80%) dan data latih (20%) dengan perbandingan 8:2. Selain itu, hasil akurasi, presisi, dan recall dari kedua algoritma tersebut berada di atas rata-rata atau sebesar 70%. Hasil terbaik pada model naive bayes dalam mengklasifikasi penyakit diabetes [15].

Pada penelitian lainnya membandingkan 2 model *Classification* Naive Bayes dan SVM model tersebut dievaluasi menggunakan ukuran-ukuran seperti akurasi, presisi, recall, dan skor F1. Studi ini menemukan bahwa Naive Bayes berkinerja lebih baik daripada SVM untuk analisis sentimen ulasan *e-commerce* dalam penelitian ini [5].

4. KESIMPULAN

Dari evaluasi yang dilakukan menggunakan *Widget Evaluasi* pada *Orange data mining* dapat disimpulkan, bahwa Algoritma SVM dengan *kernal RBF* memiliki performa terbaik serta menjadi algoritma yang lebih optimal. Hal ini dibuktikan penulis dari Hasil Evaluasi. Pada Evaluasi *Cross Validation* dengan *k fold* 10 terhadap *matrix* Akurasi, Presisi, F1 Score dan *Rcall*, SVM menunjukkan keunggulan dibandingkan *Naive bayes*. Kemudian pada evaluasi *Confusion Matrix* SVM berhasil memprediksi *True Positive* atau prediksi benar penyakit jantung lebih banyak dengan sedikit kekeliruan, menunjukkan keberhasilan dalam memisahkan kelas. Dan hasil Evaluasi *ROC Analysis*, model yang paling akurat dengan hasil yang paling dekat dengan 1 adalah SVM *kernal RBF*.

UCAPAN TERIMA KASIH

Penulis menyampaikan ucapan terima kasih kepada Keluarga serta Dosen pembimbing dan pengajar, yang telah memberikan dukungan, bantuan serta arahan selama penelitian hingga dapat menyelesaikan Analisis Penyakit Jantung Menggunakan Metode Naive Bayes & Support Vector Machine (SVM) ini.

PERNYATAAN PENGGUNAAN KECERDASAN ARTIFISIAL (ARTIFICIAL INTELLIGENCE/AI)

Selama proses penyusunan karya ilmiah ini, penulis menggunakan ChatGpt untuk membantu penyuntingan tata bahasa, perbaikan struktur kalimat, penerjemahan, dan peningkatan keterbacaan naskah. Penggunaan alat tersebut dilakukan secara terbatas sebagai pendukung proses penulisan dan tidak menggantikan tanggung jawab akademik penulis dalam merancang penelitian, menganalisis dan menginterpretasikan data, serta merumuskan kesimpulan ilmiah. Setelah menggunakan alat AI tersebut, penulis meninjau, memverifikasi, dan menyunting seluruh keluaran yang digunakan untuk memastikan keakuratan informasi, kesesuaian konteks, validitas referensi, serta kepatuhan terhadap prinsip etika dan integritas akademik. Penulis bertanggung jawab penuh atas isi, orisinalitas, keakuratan data, interpretasi hasil, kutipan, referensi, dan kesimpulan yang disajikan dalam karya

ilmiah ini, termasuk segala kekeliruan atau ketidakakuratan yang mungkin timbul dari penggunaan alat AI. Penulis juga memastikan bahwa penggunaan AI tidak melanggar hak cipta, kerahasiaan data, privasi, maupun ketentuan etika penelitian yang berlaku. Penggunaan AI dalam karya ilmiah ini tidak mengalihkan tanggung jawab intelektual dan akademik dari penulis kepada alat atau layanan AI yang digunakan.

REFERENCES

- [1] K. K. R. Biro Komunikasi dan Pelayanan Publik, “Kenali Gejala Jantung Sejak Dini,” kemenkes. Available: <https://kemkes.go.id/id/kenali-gejala-jantung-sejak-dini>
- [2] S. Aisyah, A. C. Sembiring, D. Sitanggang, and Robert, *Buku Monograf Association Rule*. 2023.
- [3] D. H. N. Prof. Dr. Ermatita, Erwin Dwika Putra M.Kom., Marissa Utami, M.Kom., Muhammad Apriliansyah R, M.Kom., Winata Nugraha, M.Kom., *Kecerdasan Artifisial Untuk Citra Digital*. 2025. [Online]. Available: <https://books.google.co.id/books?id=ZWxyEQAAQBAJ&printsec=frontcover#v=onepage&q&f=false>
- [4] G. W. N. Dicky Nofriansyah, *Algoritma Data Mining Dan Pengujian*. 2015. [Online]. Available: [https://books.google.co.id/books?hl=en&lr=&id=fcBVEQAAQBAJ&oi=fnd&pg=PR4&dq=Nurcahyo,+D.+N.+dan+G.+W.+\(2015\).+Algoritma+Data+Mining+dan+Pengujian+\(p.+17\).+Deepublish.+android:+&ots=G2WaoYkjI0&sig=CjxgbfzMSqMgNCynTlnKJa42tvQ&redir_esc=y#v=onepage&q&f=false](https://books.google.co.id/books?hl=en&lr=&id=fcBVEQAAQBAJ&oi=fnd&pg=PR4&dq=Nurcahyo,+D.+N.+dan+G.+W.+(2015).+Algoritma+Data+Mining+dan+Pengujian+(p.+17).+Deepublish.+android:+&ots=G2WaoYkjI0&sig=CjxgbfzMSqMgNCynTlnKJa42tvQ&redir_esc=y#v=onepage&q&f=false)
- [5] A. D. H. Adinda Nabilla M, Abraham Adrian Y. L, Ahmad Indra J, Yudi Arya S, Sumanto, “Komparasi Naive Bayes dan SVM untuk Analisis Sentimen Pada E-Commerce Seller Center,” vol. 5, no. 3, pp. 199–208, 2025.
- [6] A. F. Watratan, A. P. B, D. Moeis, S. Informasi, and S. P. Makassar, “JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) Implementasi Algoritma Naive Bayes Untuk Memprediksi Tingkat Penyebaran Covid-19 Di Indonesia,” vol. 1, no. 1, pp. 7–14, 2020.
- [7] F. Amaliah and I. K. Dwi Nuryana, “Perbandingan Akurasi Metode Lexicon Based Dan Naive Bayes Classifier Pada Analisis Sentimen Pendapat Masyarakat Terhadap Aplikasi Investasi Pada Media Twitter,” *J. Informatics Comput. Sci.*, vol. 3, no. 03, pp. 384–393, 2022, doi: 10.26740/jinacs.v3n03.p384-393.
- [8] S. Rahayu and Y. Yamasari, “Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM),” *J. Informatics Comput. Sci.*, vol. 5, no. 03, pp. 440–446, 2024, doi: 10.26740/jinacs.v5n03.p440-446.
- [9] Z. Arifin *et al.*, “Penerapan Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function dalam Klasifikasi Sel Kanker,” vol. 4, no. 2, pp. 100–106, 2023.
- [10] D. Irawan, E. B. Perkasa, Y. Yurindra, D. Wahyuningsih, and E. Helmud, “Perbandingan Klasifikasi SMS Berbasis Support Vector Machine, Naive Bayes Classifier, Random Forest dan Bagging Classifier,” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 10, no. 3, pp. 432–437, 2021, doi: 10.32736/sisfokom.v10i3.1302.
- [11] A. A. Astafah, I. S. Habibba, and S. T. Prayoga, “Pemetaan Efektivitas Anggaran Kementerian Pada Tahun 2023 Melalui Klasterisasi Dengan Orange Data Mining,” *Integr. Perspect. Soc. ...*, vol. 2, no. 3, pp. 6236–6254, 2023, [Online]. Available: <https://ipssj.com/index.php/ojs/article/view/787?%0Ahttps://ipssj.com/index.php/ojs/article/download/787/717>
- [12] M. W. simon kamm, Nasser Jazdi, “ScienceDirect ScienceDirect Knowledge Discovery in Heterogeneous and Unstructured Data of Industry Knowledge Discovery in Design Heterogeneous and Unstructured Nantes , France Data of Industry 4 . 0 Systems : Challenges and Approaches 4 . 0 Systems : Chal,” *Procedia CIRP*, vol. 104, pp. 975–980, 2021, doi: 10.1016/j.procir.2021.11.164.
- [13] G. Gunadi and D. I. Sensuse, “Penerapan Metode Data Mining Market Basket Analysis Terhadap Data Penjualan Produk Buku Dengan Menggunakan Algoritma Apriori Dan Frequent Pattern Growth (Fp-Growth) :,” *Telematika*, vol. 4, no. 1, pp. 118–132, 2012.
- [14] M. D. Jannah, A. Fauzi, C. Emilia, and H. Hikmayanti, “Klasifikasi Penyakit Hipertensi Menggunakan Support Vector Machine dan Naive Bayes,” *J. Algoritma.*, vol. 22, no. 1, pp. 905–913, 2025, doi: 10.33364/algoritma/v.22-1.2316.
- [15] A. Desiani *et al.*, “PERBANDINGAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) DAN NAIVE,” vol. 10, no. 1, pp. 65–74, 2024.
- [16] T. Wigung, A. Prayitna, I. Yuadi, and U. Airlangga, “Implementation of Orange Data Mining for,” vol. 5, no. 5, pp. 5203–5214, 2025.
- [17] N. Nurwanda, N. Suarna, and W. Prihartono, “Penerapan Nlp (Natural Language Processing) Dalam Analisis Sentimen Pengguna Telegram Di Playstore,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 1841–1846, 2024, doi: 10.36040/jati.v8i2.8469.
- [18] N. F. S. Eliana Tangelobo, Wisye Mayaut, Hanjian Listanto, Iwan Binanto, “Perbandingan Algoritma Klasifikasi Random Forest, Gaussian Naive Bayes, dan K-Nearest untuk Data Tidak Seimbang dan Data yang diseimbangkan dengan metode Random Undersampling pada dataset LCMS Tanaman Keladi Tikus,” *Pros. Sains Nas. dan Teknol.*, vol. 13, no. 1, pp. 156–160, 2023, doi: 10.36499/psnst.v13i1.9002.
- [19] B. G. Marcot and A. M. Hanea, “What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis?,” *Comput. Stat.*, vol. 36, no. 3, pp. 2009–2031, 2021, doi: 10.1007/s00180-020-00999-9.
- [20] A. M. Japany and Y. T. Wijaya, “Penanganan Imbalance Data pada Klasifikasi Kabupaten/Kota di Kawasan Timur Indonesia Handling of Data Imbalance in Classification of Regencies/Municipalities in Eastern Indonesia,” *Sist. J. Sist. Inf.*, vol. 13, no. 1, pp. 2540–9719, 2024, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>