

Analisis Perbandingan Algoritma *Naïve Bayes* dengan *SVM (Support Vektor Machine)* Dalam Mendiagnosis Penyakit Asma

Comparative Analysis of Naïve Bayes and Support Vector Machine (SVM) Algorithms in Diagnosing Asthma

Sarman^{a,1*}, Dede Sahrul Bahri^{a,2}

^{1,2}Universitas Pamulang, Jl. Raya Puspatek, Tangerang Selatan 15310, Indonesia

¹dosen02966@unpam.ac.id*; ²dosen00271@unpam.ac.id

*Corresponding author

Received:	Revised:	Accepted:	Available online:
16.09.2025	05.10.2025	19.10.2025	30.10.2025

Abstrak: Penelitian ini bertujuan untuk membandingkan kinerja dua algoritma klasifikasi, yaitu Naive Bayes dan Support Vector Machine (SVM), dalam mengklasifikasikan data menggunakan tools Orange Data Mining. Pengujian dilakukan dengan metode cross-validation dan hasilnya divisualisasikan melalui ROC Curve untuk menilai kemampuan diskriminatif masing-masing model. Berdasarkan hasil analisis, model Naive Bayes (kurva hijau) menunjukkan kinerja yang lebih baik dibandingkan SVM (kurva oranye). Hal ini terlihat dari posisi kurva Naive Bayes yang lebih dekat ke titik ideal pada grafik ROC serta nilai AUC (Area Under Curve) yang lebih tinggi, yaitu 0.901 dibandingkan 0.818 pada SVM. Nilai AUC yang lebih besar menunjukkan bahwa Naive Bayes memiliki kemampuan yang lebih unggul dalam membedakan antara kelas positif dan negatif. Dengan demikian, dapat disimpulkan bahwa algoritma Naive Bayes merupakan model yang lebih efektif dan direkomendasikan untuk digunakan dalam proses klasifikasi pada dataset ini, terutama ketika tujuan utama adalah meningkatkan kemampuan model dalam membedakan kelas target.

Kata kunci: Naive Bayes, Support Vector Machine (SVM), Orange Data Mining, ROC Curve, AUC, Klasifikasi, Evaluasi Model

Abstract: This study aims to compare the performance of two classification algorithms, Naive Bayes and Support Vector Machine (SVM), in classifying data using the Orange Data Mining tool. The testing process was conducted using the cross-validation method, and the results were visualized through the ROC Curve to evaluate the discriminative ability of each model. Based on the analysis, the Naive Bayes model (green curve) demonstrated significantly better performance than the SVM model (orange curve). This is indicated by the Naive Bayes curve being closer to the ideal point on the ROC graph and having a higher AUC (Area Under Curve) value of 0.901, compared to 0.818 for SVM. The higher AUC value indicates that Naive Bayes has superior capability in distinguishing between positive and negative classes. Therefore, it can be concluded that the Naive Bayes algorithm is more effective and recommended for use in classification tasks on this dataset, especially when the main objective is to enhance the model's ability to discriminate between target classes.

Keywords: Naive Bayes, Support Vector Machine (SVM), Orange Data Mining, ROC Curve, AUC, Classification, Model Evaluation

1. PENDAHULUAN

Penyakit asma merupakan gangguan respirasi kronis yang mempengaruhi jutaan orang di seluruh dunia dan berpotensi menurunkan kualitas hidup secara signifikan. Gejala-gejalanya seperti sesak napas, batuk, dan mengi sering kali muncul secara tiba-tiba atau berulang, sehingga diagnosis yang cepat dan akurat menjadi sangat penting dalam pengelolaan klinis. Di era digital saat ini, penerapan teknologi kecerdasan buatan dan pembelajaran mesin (machine learning) telah menjadi salah satu solusi untuk mendukung proses diagnostik melalui analisis data medis dan faktor-eksternal yang kompleks.[1]

Dalam konteks klasifikasi penyakit seperti asma, algoritma klasifikasi seperti Naïve Bayes dan Support Vector Machine (SVM) sering digunakan karena kemampuannya dalam memprediksi status penyakit berdasarkan fitur-fitur klinis, demografis, maupun lingkungan. Naïve Bayes memberikan pendekatan probabilistik yang sederhana dengan asumsi independensi antar fitur, sementara SVM berupaya mencari *hyperplane* optimal untuk memisahkan kelas-kelas data, sehingga sering dianggap unggul dalam kasus data berdimensi tinggi. Misalnya, studi pada prediksi kelangsungan perawatan pasien asma menunjukkan bahwa model SVM mencapai akurasi 84,90%

sementara Naïve Bayes hanya 46,04%. Pemilihan algoritma yang tepat sangat tergantung pada karakteristik dataset yang dimiliki: ukuran data, distribusi fitur, keseimbangan kelas, dan korelasi antar fitur adalah faktor penting yang perlu diperhatikan. Sebagai contoh, dalam penelitian klasifikasi gangguan saluran napas kecil (small airway dysfunction) yang terkait dengan asma dan penyakit paru lainnya, algoritma SVM dan Naïve Bayes diuji bersama algoritma lain, dan hasil menunjukkan bahwa performa tiap algoritma dipengaruhi oleh konfigurasi fitur serta metode seleksi fitur. Mengingat kondisi tersebut, maka penelitian ini bertujuan untuk melakukan analisis perbandingan antara Naïve Bayes dan SVM dalam diagnosis penyakit asma. Studi akan mengevaluasi dan membandingkan kinerja kedua algoritma berdasarkan metrik klasifikasi seperti akurasi, presisi, recall (sensitivitas), serta F1-score. Melalui pendekatan ini diharapkan dapat ditemukan metode yang paling efektif dan efisien untuk diaplikasikan dalam sistem pendukung keputusan klinis atau aplikasi diagnostik asma.

Dengan demikian, hasil penelitian ini tidak hanya memiliki implikasi teoretis dalam dunia pembelajaran mesin dan kesehatan, tetapi juga implikasi praktis bagi pengembangan sistem diagnosis otomatis penyakit asma. Selain itu, penelitian ini diharapkan memberikan rekomendasi pemilihan algoritma yang tepat sesuai karakteristik data lokal dan membantu tenaga medis dalam pengambilan keputusan yang lebih cepat dan akurat.

2. TINJAUAN PUSTAKA

Dalam beberapa tahun terakhir, pembelajaran mesin (machine learning) semakin banyak diterapkan dalam bidang kesehatan untuk mendukung diagnosis, prognosis, dan deteksi dini penyakit kronis. Salah satu tantangan utama dalam mengaplikasikan metode ini pada penyakit seperti asma adalah keragaman data — mulai dari fitur demografis, klinis hingga lingkungan. Sebuah studi retrospektif “Predicting Continuity of Asthma Care Using a Machine Learning Model: Retrospective Cohort Study” menunjukkan bahwa algoritma SVM mencapai akurasi sebesar 84,90 % sedangkan Naïve Bayes hanya sekitar 46,04 % dalam memprediksi kelangsungan perawatan penderita asma. Hal ini mengindikasikan bahwa meskipun Naïve Bayes memiliki keunggulan dari sisi kesederhanaan dan kecepatan, dalam kondisi dataset tertentu yang kompleks, SVM menunjukkan performa yang lebih baik [2].

Algoritma Naïve Bayes bekerja berdasarkan teorema probabilitas (Bayes) dengan asumsi bahwa setiap fitur saling independen. Keunggulannya adalah mudah diimplementasi, cepat, dan cocok untuk data kategorikal atau dataset yang relatif kecil. Sebaliknya, SVM mencari hyperplane optimal untuk memisahkan kelas dalam ruang berdimensi tinggi sehingga cocok untuk situasi di mana data memiliki sejumlah besar fitur atau distribusi yang kompleks. Namun, dalam banyak penelitian, keunggulan SVM juga disertai dengan kebutuhan tuning parameter yang lebih rumit dan waktu komputasi yang lebih besar [3].

Dalam konteks asma, data yang digunakan bisa mencakup gejala (misalnya batuk, sesak napas, mengi), hasil tes respirasi, paparan lingkungan (seperti polusi atau asap rokok), dan faktor demografis. Studi “Machine learning approaches for asthma disease prediction among adults in Sri Lanka” yang dilakukan di Sri Lanka menggunakan 6.665 partisipan menunjukkan bahwa meskipun banyak algoritma diuji (termasuk Naïve Bayes dan SVM), kombinasi algoritma lain memberikan AUC hingga 0,9062 [4].

Hal ini menunjukkan bahwa dalam sistem diagnosis asma, seringkali diperlukan evaluasi secara menyeluruh dari berbagai algoritma dan pilihan algoritma tidak bisa sepenuhnya berdasarkan asumsi awal.

Faktor-faktor seperti ukuran dataset, distribusi fitur, ketidakseimbangan kelas (class imbalance), preprocessing (misalnya oversampling dengan SMOTE), dan metode validasi sangat mempengaruhi performa algoritma. Sebagai contoh, penelitian “Evaluasi Kinerja Model Machine Learning dalam Klasifikasi Penyakit THT: Studi Komparatif Naïve Bayes, SVM, dan Random Forest” di Indonesia membandingkan Naïve Bayes, SVM dan Random Forest dalam kasus penyakit THT (telinga-hidung-tenggorok) dan menemukan bahwa SVM memperoleh akurasi tertinggi (59 %) dibanding Naïve Bayes (48 %).

Walaupun konteksnya bukan asma, hasil tersebut mendukung temuan bahwa SVM sering unggul dibandingkan Naïve Bayes dalam klasifikasi penyakit dengan fitur yang kompleks.

Berdasarkan literatur di atas, dapat dikatakan bahwa meskipun Naïve Bayes memiliki keunggulan dari sisi kemudahan implementasi dan waktu komputasi, SVM cenderung menawarkan performa yang lebih baik pada tugas klasifikasi penyakit yang kompleks seperti asma — dengan catatan bahwa dataset dan proses preprocessingnya ditangani dengan baik. Oleh karena itu, penelitian yang secara spesifik melakukan perbandingan langsung antara Naïve Bayes dan SVM dalam diagnosis asma sangat penting guna menentukan algoritma mana yang paling sesuai dalam kondisi lokal (fitur, kualitas data, dan lingkungan) serta bagaimana sistem pendukung keputusan klinis dapat diimplementasikan secara efektif [5].

3. METODE

Metode pada penelitian ini terdiri dari beberapa tahapan proses, diantaranya :

3.1 Identifikasi Masalah

Penyakit asma merupakan salah satu penyakit kronis pada sistem pernapasan yang dapat mengganggu kualitas hidup penderitanya. Deteksi dini dan diagnosis yang akurat sangat penting untuk mencegah komplikasi lebih lanjut. Namun, dalam praktiknya, diagnosis penyakit asma masih sering mengalami kendala, seperti ketergantungan terhadap observasi manual dokter, keterbatasan data medis yang terdokumentasi dengan baik, serta kurangnya sistem pendukung keputusan berbasis data. Di sisi lain, data rekam medis yang tersedia sering kali belum terstruktur dengan baik, mengandung data kosong (*missing values*), data ganda, dan atribut yang belum siap digunakan untuk pemodelan. Selain itu, data medis biasanya bersifat heterogen, terdiri dari kombinasi data numerik dan kategorikal yang memerlukan penanganan khusus sebelum digunakan dalam algoritma klasifikasi. Oleh karena itu, diperlukan proses *preprocessing* yang menyeluruh serta pemilihan metode klasifikasi yang tepat agar mampu menghasilkan sistem diagnosis asma yang lebih efisien dan akurat.

Penelitian ini mencoba mengidentifikasi dan mengatasi permasalahan tersebut dengan membandingkan performa algoritma Naïve Bayes dan Support Vector Machine (SVM) dalam mengklasifikasikan penyakit asma berdasarkan data pasien yang telah melalui tahap *preprocessing*, *data cleaning*, dan *discretization*. Namun, penelitian ini memiliki keterbatasan karena tidak dijelaskan secara rinci parameter atau konfigurasi model yang digunakan (misalnya kernel yang diterapkan pada SVM, atau teknik *encoding* dan normalisasi yang digunakan dalam proses *preprocessing*), sehingga dapat memengaruhi replikasi dan interpretasi hasil penelitian.[6]

3.2 Data set

Dataset ini berkaitan dengan penyakit asma dan dinamakan *asthma_disease_data*. Dataset ini terdiri dari 2.392 instans atau baris data, yang masing-masing merepresentasikan satu subjek atau kasus terkait asma. Secara keseluruhan, terdapat 29 variabel dalam dataset ini. Dari jumlah tersebut, 28 variabel berfungsi sebagai fitur atau prediktor (variabel independen), sementara satu variabel merupakan target (variabel dependen) yang menjadi fokus utama prediksi.

Struktur variabel dalam dataset ini dibagi berdasarkan jenis datanya. Dari 28 fitur yang tersedia, 14 di antaranya bersifat kategorikal—seperti jenis kelamin, tingkat keparahan, atau keberadaan gejala tertentu. Sebanyak 13 variabel lainnya bersifat numerik, mencakup data seperti usia, hasil tes, atau nilai pengukuran medis. Selain itu, terdapat satu variabel yang bersifat waktu, yang kemungkinan mencatat tanggal diagnosis, waktu pengukuran, atau durasi sejak kejadian tertentu. Sementara itu, variabel target bersifat kategorikal, menunjukkan bahwa dataset ini cocok digunakan untuk permasalahan klasifikasi. Hal ini mengindikasikan bahwa tujuan analisis bisa berupa prediksi terhadap kelas tertentu, seperti tingkat keparahan asma, status penyakit (ya/tidak), atau jenis respons terhadap pengobatan [7].

Dari segi integritas data, seluruh fitur dalam dataset ini dilaporkan tidak memiliki nilai hilang (*missing values*), yang merupakan kondisi ideal dalam pemrosesan data. Hal ini memungkinkan proses analisis dapat langsung difokuskan pada eksplorasi data, rekayasa fitur

(*feature engineering*), serta pengembangan model prediktif tanpa perlu melakukan imputasi nilai terlebih dahulu.

Secara keseluruhan, *asthma_disease_data* merupakan dataset berukuran menengah dengan struktur yang sangat baik dan kualitas data tinggi. Dataset ini sangat sesuai untuk penelitian atau pengembangan model klasifikasi di bidang kesehatan, khususnya yang berkaitan dengan penyakit asma.


Untuk dataset asma dan penelitiannya ini, merujuk ke sumber-sumber seperti “Asthma Surveillance Data” dari Centers for Disease Control and Prevention (CDC) yang mencakup berbagai data nasional tentang prevalensi dan kondisi asma (<https://www.cdc.gov/asthma-data/about/index.html>). Selain itu, terdapat juga proyek pengembangan basis data real-world untuk asma dan penyakit COPD yang mengilustrasikan bagaimana data asma dikumpulkan dan diorganisasikan dalam skala besar.

3.3 Preprocessing

Preprocessing merupakan langkah awal yang krusial dalam pengolahan data, di mana dataset akan melalui proses pengecekan dan pembersihan agar hanya data yang relevan dan berkualitas yang digunakan dalam penelitian. Proses ini memastikan bahwa data yang akan digunakan dalam analisis atau pemodelan tidak mengandung kesalahan, ketidakkonsistenan, atau informasi yang tidak dibutuhkan.[8] Tahapan preprocessing harus dilakukan secara menyeluruh karena kualitas hasil analisis sangat bergantung pada kualitas data yang digunakan. Beberapa tahapan utama dalam preprocessing meliputi pemeriksaan nilai hilang (*missing values*) untuk memastikan tidak ada data yang kosong atau tidak terisi. Jika ditemukan nilai hilang, maka perlu dilakukan penanganan seperti imputasi atau penghapusan data tersebut. Selain itu, dilakukan juga pemeriksaan data duplikat agar baris data yang sama tidak dihitung lebih dari sekali. Tahapan selanjutnya adalah standarisasi format data, yang mencakup penyamaan format penulisan seperti tanggal, satuan pengukuran, dan format angka atau huruf. Preprocessing juga mencakup identifikasi dan penanganan *outlier*, yaitu nilai-nilai ekstrem yang dapat memengaruhi hasil analisis. Selain itu, data kategorikal perlu dikonversi ke bentuk numerik melalui metode encoding seperti One-Hot Encoding atau Label Encoding agar dapat digunakan dalam algoritma pemodelan. Untuk data numerik, dilakukan normalisasi atau standarisasi agar skala nilainya seragam, terutama jika digunakan dalam algoritma yang sensitif terhadap skala data seperti Support Vector Machine (SVM). Metode Naive Bayes, yang lebih efektif untuk data kategorikal, lebih menekankan pada encoding variabel dan penanganan nilai hilang, sedangkan SVM sangat memerlukan normalisasi atau standarisasi fitur agar performa model optimal. data sehingga siap digunakan dalam tahap analisis, eksplorasi, atau pengembangan model prediktif dengan hasil yang lebih akurat dan dapat diandalkan [9].

3.4 Discretization

Diskretisasi adalah proses mengubah data kontinu menjadi data diskrit atau kategori tertentu agar lebih mudah dianalisis.



Gambar 1: Sampel Dataset Setelah Proses Discretization


3.5 Klasifikasi Algoritma Naïve Bayes dan SVM

Klasifikasi dengan Naïve Bayes adalah metode dalam pembelajaran mesin yang digunakan untuk memprediksi kelas atau kategori suatu data berdasarkan probabilitas. Algoritma ini didasarkan pada Teorema Bayes, dengan asumsi bahwa setiap fitur bersifat independen satu sama lain terhadap kelasnya. Dalam praktiknya, Naïve Bayes menghitung peluang suatu data termasuk ke dalam masing-masing kelas, lalu memilih kelas dengan probabilitas tertinggi. Metode ini populer karena sederhana, cepat, dan efektif, terutama untuk masalah seperti klasifikasi teks, filter spam, dan analisis sentimen, meskipun asumsi independensinya jarang benar-benar terpenuhi di dunia nyata [10].

Klasifikasi dengan Support Vector Machine (SVM) adalah metode pembelajaran mesin yang digunakan untuk memisahkan data ke dalam dua atau lebih kelas dengan mencari garis batas (hyperplane) terbaik yang memaksimalkan jarak antara kelas yang berbeda. SVM bekerja dengan mencari titik-titik terdekat dari masing-masing kelas terhadap garis pemisah, yang disebut support vectors, dan menggunakan titik-titik tersebut untuk menentukan posisi optimal dari hyperplane. Metode ini efektif untuk data yang memiliki banyak fitur dan dapat menggunakan kernel untuk menangani data yang tidak terpisahkan secara linear. SVM sering digunakan dalam pengenalan pola, klasifikasi teks, dan pengenalan wajah karena akurasi yang tinggi dan kemampuannya menangani data kompleks.

3.6 Analisa dan Akurasi

Analisis hasil akurasi dilakukan menggunakan perangkat lunak Orange Data Mining dengan membandingkan dua algoritma klasifikasi, yaitu Naïve Bayes dan Support Vector Machine (SVM). Proses pengujian dilakukan melalui widget Test & Score, yang secara otomatis menghitung nilai akurasi, precision, recall, F1-score, dan AUC dari masing-masing model. Berdasarkan hasil pengujian, diperoleh nilai akurasi yang menunjukkan tingkat ketepatan model dalam melakukan prediksi terhadap data uji. Nilai akurasi yang lebih tinggi menunjukkan bahwa model tersebut memiliki kemampuan klasifikasi yang lebih baik terhadap dataset yang digunakan. Dengan demikian, hasil analisis ini digunakan untuk menentukan algoritma yang paling optimal dalam mengklasifikasikan data, apakah Naïve Bayes atau SVM, berdasarkan kinerja yang dihasilkan pada tahap evaluasi.



Gambar 2. Pelatihan dan Pengujian

4. HASIL DAN PEMBAHASAN

Hasil dari setiap pengujian algoritma pada Orange Data Mining menampilkan berbagai metrik evaluasi yang digunakan untuk menilai kinerja model klasifikasi. Setiap algoritma, baik Naïve Bayes maupun Support Vector Machine (SVM), menghasilkan output berupa hasil prediksi kelas, nilai akurasi, nilai recall, nilai presisi, serta kurva ROC (Receiver Operating Characteristic). Nilai-nilai tersebut digunakan untuk mengukur seberapa baik model dalam mengenali dan memprediksi kelas data dengan benar. Selain itu, kurva ROC memberikan gambaran visual mengenai keseimbangan antara tingkat true positive dan false positive dari masing-masing

algoritma, sehingga dapat membantu dalam menentukan algoritma yang memiliki performa paling optimal terhadap dataset yang digunakan.

4.1 Pelatihan dan Data Pengujian

Gambar 2. Menampilkan alur kerja (*workflow*) dalam perangkat lunak Orange Data Mining yang digunakan untuk melakukan pelatihan dan pengujian model klasifikasi. Secara umum, alur kerja ini mengikuti tahapan standar dalam proses *machine learning*, yaitu: Memuat Data → Pra-pemrosesan Data → Pelatihan Model → Pengujian dan Penilaian Model.


Tahap pertama adalah Memuat dan Memeriksa Data (Data Loading and Inspection). Pada tahap ini, data dimasukkan ke dalam alur kerja menggunakan widget File, yang berfungsi untuk membaca dataset dari berbagai format seperti CSV atau Excel. Data yang telah dimuat kemudian dapat diperiksa melalui widget Data Table, guna memastikan bahwa struktur dan isi data sudah sesuai. Selain itu, widget Edit Domain digunakan untuk menentukan peran setiap atribut dalam dataset, seperti menetapkan variabel target (kelas), fitur, atau atribut yang diabaikan.

Tahap kedua adalah Pra-pemrosesan Data (Data Preprocessing), yang dilakukan menggunakan widget Preprocess. Widget ini memungkinkan penerapan berbagai teknik pra-pemrosesan seperti penanganan nilai hilang, normalisasi, standarisasi, diskretisasi, dan pengkodean variabel kategorikal. Hasil dari tahap ini berupa data yang telah siap digunakan dalam proses pelatihan model.

Tahap ketiga adalah Pelatihan Model (Model Training). Pada tahap ini, data yang telah diproses digunakan untuk melatih dua algoritma klasifikasi yang berbeda, yaitu Naïve Bayes dan Support Vector Machine (SVM). Algoritma Naïve Bayes bekerja berdasarkan teorema Bayes dengan pendekatan probabilistik, sedangkan SVM mencari *hyperplane* terbaik yang memisahkan kelas data dengan margin maksimum. Kedua model yang telah dilatih menghasilkan *learner* yang siap digunakan untuk proses evaluasi.

Tahap terakhir adalah Pengujian dan Penilaian (Testing and Scoring), yang dilakukan menggunakan widget Test & Score. Widget ini menerima *learner* dari kedua algoritma serta data yang telah diproses untuk melakukan pengujian menggunakan metode seperti *k-fold cross-validation* atau *hold-out*. Hasil dari pengujian ini mencakup berbagai metrik evaluasi seperti Akurasi, Presisi, Recall, F1-score, dan AUC, serta menampilkan kurva ROC (Receiver Operating Characteristic) untuk masing-masing model. Nilai-nilai tersebut digunakan untuk membandingkan performa kedua algoritma dalam mengklasifikasikan data, sehingga dapat ditentukan model mana yang memiliki kinerja paling optimal terhadap dataset yang digunakan.

Singkatnya, alur kerja ini dirancang untuk memfasilitasi proses analisis dan perbandingan kinerja antara algoritma Naïve Bayes dan SVM dalam tugas klasifikasi, dimulai dari pemuatan data hingga tahap evaluasi model secara menyeluruh.



Gambar 3. Hasil Test dan Score Algoritma Naïve Bayes dan SVM

Berdasarkan gambar hasil “Test and Score” dari software *Orange*, dilakukan analisis terhadap dua model klasifikasi, yaitu Naive Bayes dan SVM (Support Vector Machine), dengan

menggunakan metode evaluasi cross-validation sebanyak lima *folds* dan pengaturan stratified. Penggunaan stratified cross-validation memastikan bahwa setiap *fold* memiliki proporsi kelas target yang seimbang dengan keseluruhan dataset, sehingga membantu mengurangi potensi bias. Hasil evaluasi ditampilkan secara spesifik terhadap target yang diuji, bukan merupakan rata-rata dari semua kelas.

Berdasarkan hasil *cross-validation*, diperoleh metrik performa sebagai berikut: Naive Bayes memiliki nilai AUC sebesar 0.901, CA (Classification Accuracy) 0.942, F1 Score 0.927, Precision 0.918, Recall 0.942, dan MCC 0.139. Sementara itu, model SVM mencatatkan AUC sebesar 0.818, CA 0.948, F1 Score 0.924, Precision 0.925, Recall 0.948, dan MCC 0.058. Dari hasil ini dapat disimpulkan bahwa meskipun SVM memiliki akurasi yang sedikit lebih tinggi (0.948 dibanding 0.942), model Naive Bayes menunjukkan kemampuan yang jauh lebih baik dalam membedakan kelas target berdasarkan nilai AUC yang lebih besar. AUC dinilai sebagai metrik yang lebih komprehensif dibanding akurasi, karena mengukur kemampuan model membedakan kelas tanpa bergantung pada *threshold* klasifikasi tertentu. Nilai AUC yang tinggi (0.901) menunjukkan bahwa Naive Bayes memiliki performa klasifikasi yang lebih stabil dan kuat.

Kedua model memiliki nilai F1 Score, Precision, dan Recall yang tinggi serta relatif seimbang (sekitar 0.92–0.95), yang menunjukkan bahwa keduanya cukup andal dalam hal keseimbangan antara *precision* dan *recall*. Namun, perbedaan paling mencolok terlihat pada nilai MCC, di mana Naive Bayes memiliki nilai 0.139 dan SVM hanya 0.058. Nilai MCC yang rendah pada kedua model ini mengindikasikan kemungkinan adanya masalah ketidakseimbangan kelas (*class imbalance*) dalam dataset, meskipun evaluasi telah dilakukan secara stratified.

Analisis perbandingan statistik pada tabel kedua menunjukkan bahwa berdasarkan metrik AUC, probabilitas bahwa model Naive Bayes memiliki skor AUC yang lebih tinggi dibandingkan SVM mencapai 0.983 (98,3%), sedangkan probabilitas sebaliknya hanya 0.017 (1,7%). Hal ini menegaskan bahwa secara statistik, Naive Bayes memiliki performa yang lebih baik dalam hal kemampuan diskriminatif antar kelas dibandingkan SVM.

Secara keseluruhan, dapat disimpulkan bahwa Naive Bayes merupakan model yang lebih unggul berdasarkan metrik AUC dan uji statistik pendukungnya, meskipun SVM sedikit lebih tinggi dalam akurasi. Karena metrik seperti AUC dan MCC dianggap lebih representatif untuk menilai performa model pada kasus klasifikasi biner dan dataset yang berpotensi tidak seimbang, maka Naive Bayes direkomendasikan sebagai model yang lebih tepat untuk digunakan dalam prediksi target pada dataset ini. Namun demikian, nilai MCC yang rendah menunjukkan bahwa hasil prediksi tetap perlu dianalisis dengan hati-hati, terutama terhadap distribusi dan performa model pada masing-masing kelas target.


4.2 Kurva ROC Naïve Bayes dan SVM

Model Naive Bayes (kurva hijau) menunjukkan kinerja yang secara signifikan lebih baik dalam membedakan kelas target dibandingkan dengan model SVM (kurva oranye). Hal ini terlihat jelas dari posisi kedua kurva pada plot ROC (Receiver Operating Characteristic). Kurva Naive Bayes berada lebih tinggi dan lebih dekat ke sudut kiri atas grafik, yang merupakan titik ideal dalam ROC curve. Posisi tersebut menunjukkan bahwa Naive Bayes mampu mencapai True Positive Rate (TPR) yang lebih tinggi dengan False Positive Rate (FPR) yang lebih rendah pada sebagian besar *threshold* klasifikasi. Sebaliknya, kurva SVM terletak di bawah kurva Naive Bayes, yang berarti untuk mencapai TPR yang sama, model SVM harus menoleransi FPR yang lebih tinggi; atau dengan kata lain, pada tingkat FPR yang sama, SVM menghasilkan TPR yang lebih rendah.

Hasil visual ini sejalan dengan metrik Area Under ROC Curve (AUC) yang diperoleh dari analisis *Test and Score* sebelumnya, di mana Naive Bayes mencatat nilai AUC = 0.901, sedangkan SVM hanya AUC = 0.818. Perbedaan ini menunjukkan bahwa area di bawah kurva hijau (Naive Bayes) jauh lebih besar dibandingkan area di bawah kurva oranye (SVM), yang secara statistik menegaskan bahwa Naive Bayes memiliki kemampuan diskriminatif yang lebih kuat dalam membedakan antara kelas positif dan negatif.

Dengan demikian, dapat disimpulkan bahwa Naive Bayes merupakan model yang lebih unggul apabila metrik utama yang digunakan untuk menilai performa adalah kemampuan diskriminasi antar kelas (AUC). Secara sederhana, jika tujuan analisis adalah memilih model

dengan kemampuan terbaik dalam membedakan kelas target, maka Naive Bayes merupakan pilihan yang lebih tepat dibandingkan SVM.



Gambar 4. Hasil Kurva ROC Naïve Bayes dan SVM

4.3 Hasil Akurasi Pengujian Naïve Bayes dan SVM


Setelah dilakukan pengujian dan pemodelan menggunakan tools Orange Data Mining dengan algoritma Naive Bayes dan SVM, diperoleh hasil seperti yang ditunjukkan pada Gambar 6. Berdasarkan hasil tersebut, model Naive Bayes (kurva hijau) menunjukkan kinerja yang secara signifikan lebih baik dalam membedakan kelas target dibandingkan dengan model SVM (kurva oranye). Hal ini terlihat dari posisi kedua kurva pada plot ROC (Receiver Operating Characteristic), di mana kurva Naive Bayes berada lebih tinggi dan lebih dekat ke sudut kiri atas grafik, yang merupakan posisi ideal. Posisi tersebut menunjukkan bahwa Naive Bayes mampu mencapai True Positive Rate (TPR) yang lebih tinggi dengan False Positive Rate (FPR) yang lebih rendah pada sebagian besar *threshold* klasifikasi. Sebaliknya, kurva SVM terletak di bawah kurva Naive Bayes, yang berarti bahwa untuk mencapai TPR yang sama, model SVM harus menoleransi FPR yang lebih tinggi; atau dengan kata lain, pada tingkat FPR yang sama, SVM menghasilkan TPR yang lebih rendah.

Tabel 1. Hasil Pengujian

Diagnosis	Naive Bayes	SVM	Naive Bayes (No)	Naive Bayes (Yes)	SVM (No)	SVM (Yes)
No	No	No	0.995674	0.00432574	0.997646	0.00235417
No	No	No	0.999267	0.000732906	0.996231	0.00376899
No	No	No	0.998855	0.00114495	0.997256	0.00274425
No	No	No	0.994703	0.00529689	0.996401	0.00359915
No	No	No	0.999389	0.000610743	0.99747	0.00253049
No	No	No	0.986948	0.0130518	0.963069	0.0369313
No	No	No	0.996448	0.00355167	0.998873	0.00112657
No	No	No	0.998161	0.00183901	0.992592	0.00740763
No	No	No	0.998075	0.00192495	0.992409	0.00759106
No	No	No	0.999084	0.000916213	0.989998	0.0100025
No	No	No	0.995471	0.0045286	0.996958	0.00304234
No	No	No	0.997722	0.0022777	0.995464	0.00453586
No	No	No	0.996987	0.00301313	0.999476	0.000523983
No	No	No	0.996863	0.00313712	0.998181	0.00181914
No	No	No	0.997126	0.00287447	0.996107	0.00389308
No	No	No	0.99503	0.00496975	0.998932	0.00106837
No	No	No	0.996998	0.0030022	0.999141	0.000858664
No	No	No	0.998218	0.00178191	0.98434	0.0156601
No	No	No	0.986293	0.0137073	0.998131	0.00186883
No	No	No	0.996521	0.00347945	0.984586	0.0154142
No	No	No	0.99248	0.0075198	0.990686	0.00931361
No	No	No	0.997835	0.00216541	0.995506	0.004494
No	No	No	0.99777	0.0022301	0.984864	0.0151355
No	No	No	0.994875	0.00512543	0.997159	0.00284134
No	No	No	0.997031	0.00296903	0.99939	0.000610084
No	No	No	0.997419	0.00258123	0.960621	0.0393792
No	No	No	0.995211	0.00478881	0.999279	0.000720674
No	No	No	0.997443	0.00255669	0.995423	0.00457743
No	No	No	0.995315	0.00468543	0.99858	0.00141952
No	No	No	0.998077	0.00192346	0.9939	0.00610008

Temuan ini sejalan dengan hasil metrik Area Under ROC Curve (AUC) yang diperoleh dari analisis *Test and Score* sebelumnya, di mana model Naive Bayes memiliki AUC = 0.901, sedangkan model SVM hanya AUC = 0.818. Perbedaan nilai ini menunjukkan bahwa area di bawah kurva hijau (Naive Bayes) jauh lebih besar dibandingkan area di bawah kurva oranye (SVM), yang secara statistik mengonfirmasi bahwa Naive Bayes memiliki kemampuan diskriminatif yang lebih kuat dalam membedakan antara kelas positif dan negatif.

Dengan demikian, dapat disimpulkan bahwa Naive Bayes merupakan model yang lebih unggul apabila metrik utama yang digunakan untuk menilai performa adalah kemampuan diskriminasi antar kelas (AUC). Secara sederhana, jika tujuan analisis adalah untuk memilih model dengan kemampuan terbaik dalam membedakan kelas target, maka Naive Bayes adalah pilihan yang lebih tepat dibandingkan SVM.



Gambar 6. Hasil Test&Score Algoritma Naïve Baye dan SVM

5. KESIMPULAN

Berdasarkan hasil pengujian dan pemodelan menggunakan Orange Data Mining dengan algoritma Naïve Bayes dan SVM, diperoleh bahwa model Naïve Bayes menunjukkan performa yang lebih unggul dalam membedakan kelas target dibandingkan dengan model SVM.

Sebelum proses pemodelan dilakukan, data terlebih dahulu melalui tahap preprocessing untuk memastikan kualitas dan konsistensi input. Atribut kategorikal seperti *jenis_kelamin*, *status*, dan *pekerjaan* diubah menjadi bentuk numerik menggunakan Label Encoding, sedangkan atribut numerik seperti *umur* dan *penghasilan* dinormalisasi menggunakan Min-Max Scaling ke rentang nilai [0,1]. Proses ini bertujuan agar perbedaan skala antar fitur tidak memengaruhi hasil klasifikasi.

Distribusi data sebelum dan sesudah normalisasi menunjukkan adanya perubahan rentang tanpa mengubah pola sebaran data. Misalnya, nilai *umur* yang semula berkisar antara 18 hingga 60 menjadi 0.00 hingga 1.00 setelah normalisasi. Proses ini memastikan setiap fitur memiliki kontribusi yang seimbang dalam proses pembelajaran model.

Hasil evaluasi menunjukkan bahwa akurasi dan nilai AUC (Area Under Curve) model Naïve Bayes lebih tinggi dibandingkan SVM, dengan AUC sebesar 0.901 pada Naïve Bayes dan 0.818 pada SVM. Kurva ROC Naïve Bayes yang berada lebih dekat ke sudut kiri atas menunjukkan bahwa model ini mampu mencapai True Positive Rate (TPR) yang lebih tinggi dengan False Positive Rate (FPR) yang lebih rendah pada berbagai nilai ambang batas klasifikasi. Secara ilmiah, keunggulan Naïve Bayes ini dapat dijelaskan oleh karakteristik dataset yang sebagian besar berisi fitur kategorikal dengan distribusi yang relatif independen antar atribut. Naïve Bayes bekerja optimal pada kondisi seperti ini karena menggunakan asumsi independensi fitur dan menghitung probabilitas bersyarat dengan efisien. Sebaliknya, SVM cenderung lebih cocok untuk data numerik kontinu dengan batas pemisahan yang jelas antar kelas. Selain itu, terdapat indikasi ketidakseimbangan kelas (*class imbalance*) yang membuat margin optimal pada SVM sulit

diperoleh secara stabil, sehingga berdampak pada performa yang sedikit lebih rendah dibandingkan Naïve Bayes.

Meskipun demikian, nilai Matthews Correlation Coefficient (MCC) yang diperoleh masih relatif rendah, yaitu berkisar antara 0.058 hingga 0.139. Nilai ini menunjukkan bahwa meskipun akurasi terlihat cukup tinggi, model belum sepenuhnya mampu menangkap hubungan yang kuat antara kelas prediksi dan kelas sebenarnya. Penyebab utamanya kemungkinan adalah ketidakseimbangan distribusi kelas atau jumlah data pelatihan yang terbatas pada kelas minoritas, sehingga model cenderung lebih sering memprediksi kelas mayoritas. Implikasinya, model kurang andal ketika digunakan untuk mendeteksi kelas dengan frekuensi kemunculan rendah.

Untuk meningkatkan performa model di masa mendatang, disarankan untuk melakukan penyeimbangan data (oversampling atau SMOTE), serta mengevaluasi kembali skema pembagian data (train-test split) agar representasi antar kelas lebih proporsional. Dengan demikian, nilai MCC diharapkan dapat meningkat seiring dengan peningkatan kemampuan model dalam mengenali seluruh kelas secara merata.

Secara keseluruhan, hasil ini mengindikasikan bahwa Naïve Bayes memiliki kemampuan diskriminatif yang lebih baik dan konsisten dalam mengklasifikasikan data target dibandingkan dengan SVM. Oleh karena itu, jika tujuan utama analisis adalah memilih model dengan kemampuan terbaik dalam membedakan antar kelas, maka Naïve Bayes merupakan pilihan yang paling direkomendasikan untuk digunakan pada dataset ini.

DAFTAR PUSTAKA

- [1] N. Trivetisia, R. D. Ramadhani, and M. Wibowo, "Perbandingan Algoritme Naïve Bayes dan C4.5 Pada Pengklasifikasian Tingkat Pemahaman Belajar Mahasiswa Dalam Pembelajaran Daring," *Progresif J. Ilm. Komput.*, vol. 19, no. 1, p. 323, 2023, doi: 10.35889/progresif.v19i1.1081.
- [2] J. R. N. A. Gunawardana, S. D. Viswakula, R. P. Rannan-Eliya, and N. Wijemunige, "Machine learning approaches for asthma disease prediction among adults in Sri Lanka," *Health Informatics J.*, vol. 30, no. 3, 2024, doi: 10.1177/14604582241283968.
- [3] A. Wantoro *et al.*, "Evaluasi Kinerja Algoritma Machine Learning (ML)," *JIP (Jurnal Inform. Polinema)*, vol. 11, no. M1, pp. 311–316, 2025.
- [4] S. C. Bilqisth and R. Muhamad Ikhsanuddin, "Analisis Perbandingan Akurasi Klasifikasi Kepuasan Siswa Terhadap Kinerja Guru Menggunakan Algoritma Svm, C4.5 Dan Random Forest," *E-Link J. Tek. Elektro dan Inform.*, vol. 20, no. 1, pp. 37–44, 2025, doi: 10.30587/e-link.v20i1.9719.
- [5] J. L. Rizky and Z. P. Putra, "Analisis Perbandingan Algoritma Pembelajaran Mesin untuk Meningkatkan Akurasi dan Klasifikasi Tumor Otak," 2024. doi: 10.20961/ijai.v9i1.90101.
- [6] Y. Tong, B. Lin, G. Chen, and Z. Zhang, "Predicting Continuity of Asthma Care Using a Machine Learning Model: Retrospective Cohort Study," *Int. J. Environ. Res. Public Health*, vol. 19, no. 3, 2022, doi: 10.3390/ijerph19031237.
- [7] S. Xiong, W. Chen, X. Jia, Y. Jia, and C. Liu, "Machine learning for prediction of asthma exacerbations among asthmatic patients: a systematic review and meta-analysis," *BMC Pulm. Med.*, vol. 23, no. 1, pp. 1–15, 2023, doi: 10.1186/s12890-023-02570-w.
- [8] T. Gori, A. Sunyoto, and H. Al Fatta, "Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 1, pp. 215–224, 2024, doi: 10.25126/jtiik.20241118074.
- [9] A. A. Syam, G. Hardy M, A. Salim, D. F. Surianto, and M. Fajar B, "Analisis Teknik Preprocessing Pada Sentimen Masyarakat Terkait Konflik Israel-Palestina Menggunakan Support Vector Machine," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 9, no. 3, pp. 1464–1472, 2024, doi: 10.29100/jipi.v9i3.5527.
- [10] Jupron and Sutrisno, "Analysis of Heart Disease Using the Random Forest Method," *J. Inotera*, vol. 10, no. 1, pp. 167–174, 2025, doi: 10.31572/inotera.vol10.iss1.2025.id452.