

Optimalisasi Kinerja Tenaga Kependidikan di MTSN 1 Labuhanbatu Selatan Studi Kasus Penggunaan Algoritma Naïve Bayes

¹Aida Zahrah Hasanati Br Rambe, ²Angga Putra Juledi, ³Deci Irmayani,
⁴Syaiful Zuhri Harahap

^{1,2,4}Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Labuhanbatu
³Manajemen Informatika, Fakultas Sains dan Teknologi, Universitas Labuhanbatu

Email : ¹aidazahra269@gmail.com, ²anggaj19@gmail.com,
³deacyirmayani@gmail.com, ⁴syaifulzuhriharahap@gmail.com

Corresponding Author : aidazahra269@gmail.com

Abstract

This study aims to optimize the performance of Education personnel in MTsN 1 Labuhanbatu Selatan through the application of Naive Bayes algorithm for performance classification. The performance of Education personnel, including administrative, administrative, and service staff for one school year was analyzed using data involving attributes such as attendance, punctuality, productivity, and work attitude. Naive Bayes algorithm was chosen because of its ability to classify data accurately and efficiently despite the large amount of data. The results showed that the use of this algorithm can produce a more objective, accurate, and data-based evaluation system, as well as provide clearer insights in improving work efficiency and service to teachers and students. The evaluation of the model was conducted using accuracy, precision, recall, and F1-score metrics to ensure that the classification of educational staff performance can be done appropriately. The study also provides recommendations to improve data quality and the use of additional attributes to improve model performance.

Keywords : *Education Personnel Performance, Naive Bayes, Performance Evaluation, Data mining, Performance Classification.*

1. Pendahuluan

Tenaga kependidikan memegang peranan penting dalam kelancaran proses pendidikan, namun sering kali kurang mendapat perhatian dalam hal evaluasi kinerja. Di MTsN 1 Labuhanbatu Selatan, tenaga kependidikan yang mencakup staf administrasi, tata usaha, dan bagian pelayanan berkontribusi besar terhadap operasional sekolah, tetapi penilaian terhadap kinerja mereka masih bersifat subjektif dan belum terukur dengan sistematis. Hal ini menyulitkan pihak sekolah dalam menentukan langkah strategis untuk peningkatan kinerja dan pengelolaan sumber daya manusia. Perkembangan teknologi informasi mendorong sektor pendidikan untuk memanfaatkan pendekatan berbasis data dalam pengambilan keputusan. Salah satu metode yang dapat diterapkan untuk evaluasi kinerja tenaga kependidikan adalah algoritma klasifikasi Naive Bayes, yang dikenal dengan kesederhanaannya dan akurasi dalam mengelompokkan data. Metode ini dapat digunakan untuk mengolah data atribut tenaga kependidikan seperti kehadiran, ketepatan waktu, produktivitas, dan sikap kerja, sehingga menghasilkan evaluasi yang lebih objektif, akurat, dan berbasis

data. Penelitian ini bertujuan untuk mengeksplorasi penerapan algoritma Naive Bayes dalam mengklasifikasikan kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan, guna menghasilkan sistem evaluasi yang transparan dan terukur. Dengan mengoptimalkan penggunaan data yang tersedia, diharapkan dapat meningkatkan efisiensi kerja dan pelayanan kepada guru serta siswa. Pendekatan ini diharapkan dapat menggantikan metode tradisional yang masih digunakan dalam evaluasi kinerja tenaga kependidikan, serta memberikan dasar pengambilan keputusan yang lebih akuntabel dan berbasis data.

2. Landasan Teori

Knowledge Discovery in Database

Knowledge Discovery in Databases (KDD) merupakan suatu proses sistematis untuk menemukan pola-pola yang bermakna dari sekumpulan data dalam jumlah besar (Hartati et al., 2021). Proses ini melibatkan beberapa tahapan penting, seperti pemilihan data (*data selection*), pembersihan data (*data cleaning*), transformasi data (*data transformation*), data mining, dan interpretasi hasil. KDD bukan hanya sekadar penggalian data, tetapi juga mencakup pemahaman dan validasi terhadap informasi yang dihasilkan (Palacios et al., 2021). Tujuan utamanya adalah untuk mengubah data mentah menjadi pengetahuan yang dapat digunakan dalam pengambilan keputusan. Proses ini banyak dimanfaatkan di berbagai bidang, termasuk bisnis, kesehatan, keuangan, dan pendidikan, terutama ketika data yang tersedia sangat kompleks dan berjumlah besar.

Machine Learning

Machine learning merupakan cabang dari kecerdasan buatan (Artificial Intelligence) yang memungkinkan sistem komputer untuk belajar dari data dan meningkatkan kinerjanya tanpa harus diprogram secara eksplisit (Lakhdari et al., 2023). Teknik ini bekerja dengan cara mengenali pola-pola dalam data, kemudian menggunakan pola tersebut untuk membuat prediksi atau keputusan terhadap data baru (Arcinas et al., 2021). Terdapat berbagai jenis pendekatan dalam machine learning, seperti supervised learning, unsupervised learning, dan reinforcement learning, dengan masing-masing metode memiliki keunggulan dan penerapan yang berbeda tergantung pada jenis data dan tujuan analisis (Jahwar, 2021).

Metode Naïve Bayes

Naive Bayes merupakan salah satu algoritma klasifikasi yang didasarkan pada Teorema Bayes, dengan asumsi bahwa setiap fitur bersifat independen terhadap fitur lainnya (Yoridi & Pakereng, 2023). Meskipun asumsi tersebut jarang benar secara mutlak dalam dunia nyata, algoritma ini terbukti sangat efektif dalam berbagai kasus klasifikasi karena kesederhanaannya dan efisiensi dalam proses komputasi (Putra & Fahrizal, 2021). Naive Bayes bekerja dengan menghitung probabilitas posterior dari suatu kelas berdasarkan data pelatihan, kemudian memilih kelas dengan nilai probabilitas tertinggi untuk setiap data baru. Karena metode ini menggunakan pendekatan statistik, ia sangat cocok untuk pengolahan data dengan jumlah besar dan variabel yang cukup kompleks (Ali et al., 2021).

Model Klasifikasi

Model klasifikasi merupakan salah satu pendekatan dalam machine learning

yang digunakan untuk mengelompokkan data ke dalam kategori tertentu berdasarkan atribut atau fitur yang dimiliki (Setiawan et al., 2024). Tujuan utama dari klasifikasi adalah memetakan input data ke dalam label output yang telah ditentukan sebelumnya, sehingga proses pengambilan keputusan dapat dilakukan secara otomatis dan objektif (Mulyanto et al., 2021). Model klasifikasi bekerja dengan membangun pola atau hubungan dari data yang telah diberi label, kemudian pola tersebut digunakan untuk memprediksi label pada data baru yang belum dikenali. Berbagai algoritma dapat digunakan untuk membangun model klasifikasi, seperti Decision Tree, Naive Bayes, k-Nearest Neighbor (k-NN), dan Support Vector Machine (SVM), masing-masing dengan kelebihan dan kelemahannya sendiri dalam hal akurasi, kompleksitas komputasi, serta kemampuannya dalam menangani data besar atau data dengan fitur yang saling bergantung (Siddik et al., 2022).

Evaluasi Model Naïve Bayes

Evaluasi model Naive Bayes dilakukan untuk mengukur sejauh mana algoritma mampu melakukan klasifikasi secara akurat berdasarkan data yang telah dilatih sebelumnya. Proses evaluasi ini biasanya menggunakan metrik seperti akurasi, presisi, recall, dan f1-score, yang masing-masing memberikan gambaran tentang performa model dalam mengelompokkan data ke dalam kelas yang benar. Akurasi mengukur seberapa besar prediksi model sesuai dengan label sebenarnya, sementara presisi dan recall digunakan untuk mengetahui sejauh mana model tepat dalam mendeteksi suatu kelas tertentu. Evaluasi juga dapat dilakukan melalui metode validasi silang (cross-validation) untuk memastikan model tidak overfitting dan tetap stabil saat digunakan terhadap data baru. Selain itu, confusion matrix sering digunakan untuk melihat distribusi hasil klasifikasi yang benar dan salah, sehingga dapat dianalisis kelemahan spesifik dari model.

3. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan teknik data mining untuk menganalisis dan mengklasifikasikan kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan. Algoritma klasifikasi Naive Bayes dipilih sebagai metode utama dalam penelitian ini, karena kesederhanaannya dalam implementasi dan kemampuannya menghasilkan klasifikasi yang akurat berdasarkan data yang tersedia. Berikut adalah langkah-langkah yang ditempuh dalam penelitian ini:

1. Desain Penelitian

Penelitian ini bersifat deskriptif dengan pendekatan studi kasus. Peneliti menganalisis data kinerja tenaga kependidikan yang meliputi staf administrasi, tata usaha, dan bagian pelayanan di MTsN 1 Labuhanbatu Selatan.

2. Populasi dan Sampel

Populasi dalam penelitian ini adalah seluruh tenaga kependidikan di MTsN 1 Labuhanbatu Selatan, yang terdiri dari staf administrasi, tata usaha, dan bagian pelayanan. Sampel penelitian dipilih secara purposive, yaitu dengan memilih tenaga kependidikan yang memiliki data kinerja lengkap selama satu tahun ajaran terakhir. Pemilihan sampel ini dilakukan untuk memastikan representativitas data yang akan digunakan dalam analisis.

3. Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari dua jenis data, yaitu data primer dan data sekunder. Data primer diperoleh melalui observasi dan

wawancara dengan pihak terkait di MTsN 1 Labuhanbatu Selatan untuk menggali informasi mengenai atribut kinerja tenaga kependidikan.

4. Pengolahan Data
Setelah data terkumpul, dilakukan tahap preprocessing untuk mempersiapkan data agar siap digunakan dalam proses analisis. Proses preprocessing meliputi:
5. Pembersihan Data
Menghapus data yang tidak lengkap atau tidak relevan.
6. Transformasi Data
Mengubah data numerik menjadi kategori untuk mempermudah proses klasifikasi (misalnya, kategori kinerja baik, sedang, atau buruk).
7. Pemilihan Fitur
Menentukan atribut-atribut yang relevan untuk digunakan sebagai input dalam model Naive Bayes, seperti kehadiran, ketepatan waktu, produktivitas, dan sikap kerja.
8. Penerapan Algoritma Naive Bayes
Setelah data diproses, algoritma Naive Bayes diterapkan untuk mengklasifikasikan kinerja tenaga kependidikan.
9. Evaluasi Model
Untuk mengevaluasi kinerja model Naive Bayes, beberapa metrik evaluasi digunakan, seperti:
 - a. Akurasi: Mengukur seberapa tepat model dalam mengklasifikasikan kinerja tenaga kependidikan.
 - b. Presisi: Mengukur ketepatan model dalam mengidentifikasi kinerja yang baik.
 - c. Recall: Mengukur kemampuan model dalam mendeteksi seluruh data dengan kinerja baik.
 - d. F1-Score: Menyediakan keseimbangan antara presisi dan recall.
10. Analisis dan Interpretasi Hasil
Hasil klasifikasi yang diperoleh dari model Naive Bayes akan dianalisis untuk memberikan gambaran mengenai kinerja tenaga kependidikan. Hasil ini diharapkan dapat memberikan informasi yang lebih objektif dan terukur terkait dengan kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan

4. Hasil dan Pembahasan

Analisis Data

Analisis data pada penelitian ini dilakukan dengan memanfaatkan beberapa atribut utama tenaga kependidikan, yaitu kehadiran, ketepatan penyelesaian tugas, dan pelayanan terhadap warga sekolah. Setiap atribut dianalisis untuk melihat pengaruhnya terhadap kategori kinerja pegawai di MTsN 1 Labuhanbatu Selatan. Sebelum digunakan dalam proses pelatihan model klasifikasi dengan algoritma Naive Bayes, data terlebih dahulu ditransformasi agar sesuai dengan kebutuhan perhitungan probabilitas. Melalui analisis ini, pola hubungan antar atribut dapat diidentifikasi, seperti bagaimana kehadiran dan ketepatan penyelesaian tugas berkontribusi terhadap kategori kinerja tinggi atau rendah. Hasil analisis ini kemudian digunakan untuk membangun model klasifikasi yang mampu mengevaluasi kinerja tenaga kependidikan secara lebih akurat dan berbasis data.

Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan mengambil data kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan. Data yang dikumpulkan sebanyak 20 data testing dan beberapa data training, yang mencakup atribut penting seperti kehadiran, ketepatan penyelesaian tugas, dan pelayanan terhadap warga sekolah. Setiap data mewakili kinerja individu pegawai dan memberikan gambaran yang cukup representatif terhadap kualitas layanan pendidikan di sekolah tersebut. Data ini kemudian digunakan sebagai dasar dalam membangun model klasifikasi dengan algoritma Naive Bayes, untuk mengidentifikasi pola kinerja serta mengelompokkan tenaga kependidikan ke dalam kategori tinggi atau rendah secara lebih akurat dan berbasis data.

Tabel 1. Data Sampel Penelitian

ID	Kehadiran	Ketepatan Penyelesaian Tugas	Pelayanan Terhadap Warga Sekolah	Kategori Kinerja
TK1	Baik	Tepat Waktu	Baik	Tinggi
TK2	Baik	Tepat Waktu	Baik	Tinggi
TK3	Kurang	Terlambat	Kurang	Rendah
TK4	Baik	Terlambat	Baik	Tinggi
TK5	Kurang	Tepat Waktu	Baik	Tinggi
TK6	Baik	Tepat Waktu	Kurang	Tinggi
TK7	Kurang	Terlambat	Baik	Rendah
TK8	Baik	Tepat Waktu	Baik	Tinggi
TK9	Kurang	Terlambat	Kurang	Rendah
TK10	Baik	Terlambat	Kurang	Rendah
TK11	Baik	Tepat Waktu	Baik	Tinggi
TK12	Kurang	Tepat Waktu	Baik	Tinggi
TK13	Baik	Tepat Waktu	Kurang	Tinggi
TK14	Kurang	Terlambat	Kurang	Rendah
TK15	Baik	Tepat Waktu	Baik	Tinggi
TK16	Baik	Terlambat	Baik	Tinggi
TK17	Kurang	Tepat Waktu	Kurang	Rendah
TK18	Baik	Tepat Waktu	Baik	Tinggi
TK19	Baik	Terlambat	Kurang	Rendah
TK20	Kurang	Tepat Waktu	Baik	Tinggi
TK21	Baik	Tepat Waktu	Baik	Tinggi
TK22	Kurang	Terlambat	Baik	Rendah
TK23	Baik	Tepat Waktu	Kurang	Tinggi
TK24	Kurang	Tepat Waktu	Baik	Tinggi
TK25	Baik	Terlambat	Baik	Tinggi
TK26	Kurang	Terlambat	Kurang	Rendah
TK27	Baik	Tepat Waktu	Baik	Tinggi
TK28	Baik	Tepat Waktu	Baik	Tinggi
TK29	Kurang	Terlambat	Baik	Rendah
TK30	Baik	Terlambat	Kurang	Rendah

Pada tabel di atas merupakan data kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan yang terdiri dari 30 entri, masing-masing dengan identitas unik (TK1 hingga TK30) dan empat variabel utama, yaitu Kehadiran, Ketepatan Penyelesaian Tugas, Pelayanan Terhadap Warga Sekolah, serta Kategori Kinerja

sebagai label. Atribut Kehadiran dibagi menjadi dua kategori, yaitu “Baik” dan “Kurang”; atribut Ketepatan Penyelesaian Tugas memiliki kategori “Tepat Waktu” dan “Terlambat”; sedangkan atribut Pelayanan Terhadap Warga Sekolah terdiri dari “Baik” dan “Kurang”. Kategori Kinerja sebagai hasil akhir terbagi menjadi dua kelas, yaitu “Tinggi” dan “Rendah”, yang merepresentasikan tingkat performa setiap tenaga kependidikan. Data ini memperlihatkan variasi kombinasi antaratribut yang memengaruhi klasifikasi kinerja, sehingga dapat digunakan sebagai basis pelatihan dan pengujian model Naive Bayes dalam penelitian ini.

Pembagian Data

Pembagian data merupakan tahap penting dalam penelitian ini yang bertujuan untuk memisahkan data kinerja tenaga kependidikan agar siap digunakan dalam proses analisis. Dari total 30 data yang tersedia, data dibagi menjadi dua bagian, yaitu data training dan data testing. Data training digunakan untuk melatih model algoritma Naive Bayes agar dapat mengenali pola hubungan antara atribut kehadiran, ketepatan penyelesaian tugas, dan pelayanan terhadap warga sekolah dengan kategori kinerja, sedangkan data testing digunakan untuk menguji kemampuan model dalam memprediksi kinerja pada data yang belum pernah dipelajari. Pembagian ini dilakukan secara proporsional sehingga kedua dataset dapat merepresentasikan variasi kondisi yang ada, sehingga evaluasi model menjadi lebih akurat dan dapat diandalkan.

Tabel 2. Data Training

ID	Kehadiran	Ketepatan Penyelesaian Tugas	Pelayanan Terhadap Warga Sekolah	Kategori Kinerja
TK1	Baik	Tepat Waktu	Baik	Tinggi
TK2	Baik	Tepat Waktu	Baik	Tinggi
TK3	Kurang	Terlambat	Kurang	Rendah
TK4	Baik	Terlambat	Baik	Tinggi
TK5	Kurang	Tepat Waktu	Baik	Tinggi
TK6	Baik	Tepat Waktu	Kurang	Tinggi
TK7	Kurang	Terlambat	Baik	Rendah
TK8	Baik	Tepat Waktu	Baik	Tinggi
TK9	Kurang	Terlambat	Kurang	Rendah
TK10	Baik	Terlambat	Kurang	Rendah

Pada tabel di atas merupakan tabel data training yang digunakan dalam penelitian ini sebanyak 10 data yang mewakili sebagian dari keseluruhan dataset kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan. Data ini memuat empat atribut utama, yaitu Kehadiran, Ketepatan Penyelesaian Tugas, Pelayanan Terhadap Warga Sekolah, dan Kategori Kinerja sebagai label. Atribut Kehadiran terbagi menjadi kategori “Baik” dan “Kurang”, Ketepatan Penyelesaian Tugas terdiri dari “Tepat Waktu” dan “Terlambat”, sedangkan Pelayanan Terhadap Warga Sekolah memiliki kategori “Baik” dan “Kurang”. Label Kategori Kinerja dibagi menjadi dua kelas, yaitu “Tinggi” dan “Rendah”. Data training ini digunakan untuk melatih model algoritma Naive Bayes agar mampu mempelajari pola hubungan antaratribut dalam menentukan tingkat kinerja tenaga kependidikan.

Data yang digunakan sebagai data testing sebanyak 20 data yang diambil dari keseluruhan dataset kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan. Data ini terdiri dari empat atribut, yaitu Kehadiran, Ketepatan Penyelesaian Tugas, Pelayanan Terhadap Warga Sekolah, serta Kategori Kinerja sebagai label. Setiap atribut memiliki dua kategori, seperti Kehadiran yang terbagi menjadi “Baik” dan “Kurang”, Ketepatan Penyelesaian Tugas terdiri dari “Tepat Waktu” dan “Terlambat”, serta Pelayanan Terhadap Warga Sekolah dengan kategori “Baik” dan “Kurang”. Label Kategori Kinerja dibagi menjadi dua kelas, yaitu “Tinggi” dan “Rendah”. Data testing ini digunakan untuk menguji kinerja model yang telah dilatih, sehingga dapat mengukur tingkat akurasi dan kemampuan model dalam memprediksi kategori kinerja berdasarkan atribut yang tersedia.

Buka Aplikasi Orange

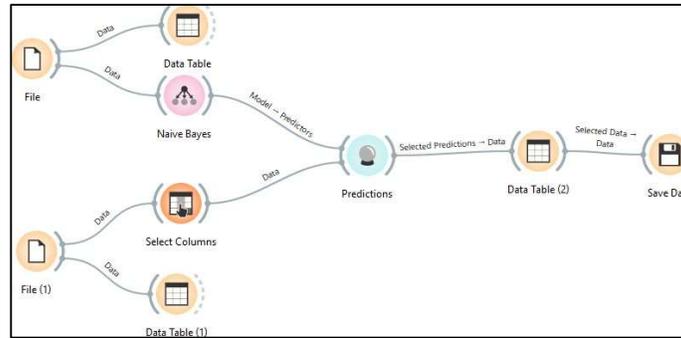


Gambar 1. Tampilan Awal Aplikasi Orange

Pada gambar di atas ditampilkan tampilan awal aplikasi Orange Data Mining yang digunakan dalam penelitian ini untuk membangun model klasifikasi kinerja tenaga kependidikan di MTsN 1 Labuhanbatu Selatan. Antarmuka awal menampilkan beberapa menu utama seperti New, Open, dan Recent, yang berfungsi untuk membuat proyek baru, membuka file proyek yang sudah ada, serta mengakses proyek terakhir yang digunakan. Terdapat pula pilihan seperti Video Tutorials, Examples, dan Documentation yang membantu memahami fungsi-fungsi dasar aplikasi. Dalam penelitian ini, analisis dimulai dengan memilih tombol New untuk membuka area kerja (canvas) baru, yang memungkinkan peneliti menyusun alur proses klasifikasi secara visual dan interaktif. Dengan antarmuka yang intuitif dan ramah pengguna, Orange memudahkan proses pemodelan data kinerja tenaga kependidikan, mulai dari pemilihan atribut hingga evaluasi performa model menggunakan algoritma Naive Bayes.

Perancangan Model Klasifikasi

Pada penelitian ini, perancangan model klasifikasi dilakukan dengan menerapkan algoritma Naive Bayes yang memproses data atribut kinerja tenaga kependidikan seperti disiplin kerja, kualitas kerja, tanggung jawab, dan kerja sama untuk memprediksi kategori kinerja. Model dirancang untuk belajar dari *data training* yang telah dipersiapkan, kemudian diuji menggunakan *data testing* guna mengevaluasi kemampuannya dalam mengenali pola-pola yang terdapat pada data. Melalui proses pelatihan ini, model diharapkan mampu membentuk representasi yang akurat terhadap hubungan antaratribut, sehingga dapat melakukan klasifikasi kinerja tenaga kependidikan ke dalam kategori Baik atau Kurang berdasarkan kombinasi variabel yang diberikan.



Gambar 2. Perancangan Model Klasifikasi

Pada gambar di atas merupakan rancangan model klasifikasi menggunakan algoritma Naive Bayes pada aplikasi Orange Data Mining. Proses dimulai dari *input* data training melalui widget File yang kemudian ditampilkan di Data Table dan diproses oleh widget Naive Bayes untuk membentuk model klasifikasi. Model ini dihubungkan ke widget Predictions untuk menguji data uji (*testing data*) yang diimpor melalui jalur terpisah, dimulai dari widget File, kemudian Data Table (1), dan Select Columns untuk memilih atribut yang sesuai. Hasil prediksi yang dihasilkan ditampilkan dalam Data Table (2) dan selanjutnya disimpan melalui widget Save Data. Alur ini memastikan bahwa proses pelatihan dan pengujian model dilakukan secara terstruktur, sehingga hasil klasifikasi dapat dianalisis dan digunakan lebih lanjut.

Hasil Klasifikasi

Hasil klasifikasi akan dipaparkan dalam bentuk tabel yang memuat data asli beserta label prediksi dari model Naive Bayes. Tabel ini memudahkan pembaca untuk membandingkan antara kategori aktual dengan hasil prediksi sehingga akurasi model dapat dievaluasi secara jelas.

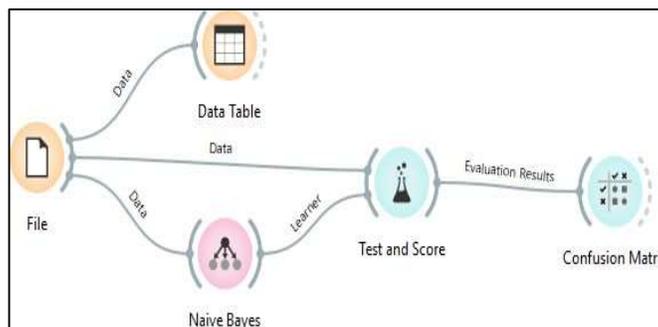
Tabel 3. Hasil Klasifikasi

ID	Kehadiran	Ketepatan Penyelesaian Tugas	Pelayanan Terhadap Warga Sekolah	Kategori Kinerja
TK1	Baik	Tepat Waktu	Baik	Tinggi
TK2	Kurang	Tepat Waktu	Baik	Tinggi
TK3	Baik	Tepat Waktu	Kurang	Tinggi
TK4	Kurang	Terlambat	Kurang	Rendah
TK5	Baik	Tepat Waktu	Baik	Tinggi
TK6	Baik	Terlambat	Baik	Tinggi
TK7	Kurang	Tepat Waktu	Kurang	Rendah
TK8	Baik	Tepat Waktu	Baik	Tinggi
TK9	Baik	Terlambat	Kurang	Rendah
TK10	Kurang	Tepat Waktu	Baik	Tinggi
TK11	Baik	Tepat Waktu	Baik	Tinggi
TK12	Kurang	Terlambat	Baik	Rendah
TK13	Baik	Tepat Waktu	Kurang	Tinggi
TK14	Kurang	Tepat Waktu	Baik	Tinggi
TK15	Baik	Terlambat	Baik	Tinggi
TK16	Kurang	Terlambat	Kurang	Rendah
TK17	Baik	Tepat Waktu	Baik	Tinggi
TK18	Baik	Tepat Waktu	Baik	Tinggi
TK19	Kurang	Terlambat	Baik	Rendah
TK20	Baik	Terlambat	Kurang	Rendah

Berdasarkan hasil klasifikasi pada tabel di atas, dari total 20 data kinerja, diperoleh bahwa sebagian besar data masuk dalam kategori Kinerja Tinggi, yaitu sebanyak 13 data (TK1, TK2, TK3, TK5, TK6, TK8, TK10, TK11, TK13, TK14, TK15, TK17, dan TK18). Sementara itu, Kinerja Rendah tercatat sebanyak 7 data (TK4, TK7, TK9, TK12, TK16, TK19, dan TK20). Hal ini menunjukkan bahwa mayoritas responden atau objek penelitian memiliki performa kerja yang baik, dilihat dari kombinasi faktor kehadiran, ketepatan penyelesaian tugas, serta pelayanan terhadap warga sekolah. Dominasi kategori tinggi mengindikasikan bahwa sebagian besar indikator kinerja berada pada level yang diharapkan atau bahkan melebihi standar. Jika dilihat lebih mendalam, kombinasi atribut pada data menunjukkan pola tertentu yang berkontribusi pada penentuan kategori kinerja. Misalnya, mayoritas data dengan kehadiran “Baik” dan penyelesaian tugas “Tepat Waktu” cenderung masuk kategori kinerja tinggi, meskipun pelayanan terhadap warga sekolah kadang berada pada kategori “Kurang”. Sebaliknya, kehadiran “Kurang” yang disertai ketepatan penyelesaian tugas “Terlambat” dan pelayanan “Kurang” hampir selalu mengarah pada kategori kinerja rendah. Menariknya, terdapat beberapa data yang walaupun memiliki kehadiran “Kurang”, namun tetap dikategorikan tinggi, seperti pada TK2, TK10, dan TK14, yang kemungkinan disebabkan oleh tingginya skor pada atribut lain seperti pelayanan dan ketepatan waktu. Secara keseluruhan, hasil klasifikasi ini memberikan gambaran jelas bahwa atribut ketepatan penyelesaian tugas dan pelayanan terhadap warga sekolah memiliki pengaruh besar terhadap penentuan kategori kinerja, bahkan lebih kuat dibandingkan atribut kehadiran. Dengan kata lain, meskipun kehadiran penting, penyelesaian tugas tepat waktu dan pelayanan yang baik mampu mengkompensasi kehadiran yang kurang optimal dalam penentuan kategori kinerja. Informasi ini dapat menjadi acuan strategis dalam meningkatkan performa, yaitu dengan fokus pada peningkatan ketepatan waktu penyelesaian tugas serta kualitas pelayanan, yang terbukti mampu mendorong kinerja ke kategori tinggi.

Perancangan Model Evaluasi

Pada perancangan ini, dibuat model evaluasi untuk mengukur sejauh mana kemampuan metode yang digunakan dalam melakukan klasifikasi. Evaluasi ini penting untuk menilai akurasi, presisi, dan efektivitas model dalam memprediksi kategori dengan benar.



Gambar 3. Perancangan Model Evaluasi

Pada gambar di atas merupakan rancangan model evaluasi menggunakan algoritma Naive Bayes pada aplikasi Orange. Alur proses dimulai dari komponen File yang berfungsi untuk memanggil dataset, kemudian data tersebut ditampilkan pada Data Table agar dapat dilihat isinya. Selanjutnya, data yang sama juga dialirkan ke algoritma Naive Bayes untuk proses pembelajaran model. Hasil pembelajaran tersebut diuji menggunakan Test and Score, yang mengukur performa model berdasarkan metrik

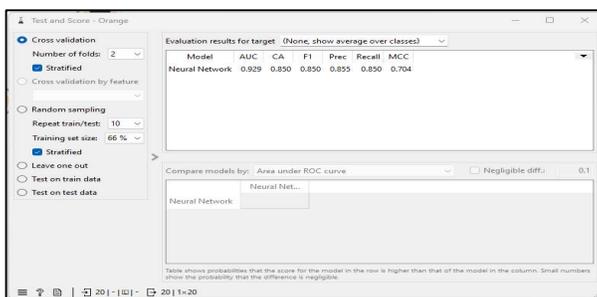
evaluasi seperti akurasi, presisi, dan recall. Output evaluasi ini kemudian divisualisasikan dalam Confusion Matrix, yang menampilkan perbandingan antara hasil prediksi dengan nilai aktual sehingga memudahkan analisis tingkat keberhasilan model dalam klasifikasi.

Hasil Evaluasi

Hasil evaluasi yang diperoleh menggunakan node Test and Score menunjukkan performa model Naive Bayes dalam mengklasifikasikan data berdasarkan metrik seperti akurasi, presisi, recall, dan F1-score. Sementara itu, node Confusion Matrix menampilkan distribusi prediksi benar dan salah untuk setiap kategori kinerja, sehingga dapat dilihat seberapa banyak data yang berhasil diprediksi sesuai label aslinya dan berapa yang mengalami kesalahan prediksi.

Hasil Test and Score

Test and Score merupakan komponen evaluasi pada Orange Data Mining yang digunakan untuk mengukur kinerja model pembelajaran mesin dengan berbagai metrik seperti akurasi, presisi, recall, dan F1-score. Komponen ini memungkinkan pengguna membandingkan performa beberapa algoritma secara objektif menggunakan data uji yang sama.



Gambar 4. Hasil Evaluasi Test and Score

Pada gambar di atas merupakan tampilan hasil evaluasi model menggunakan komponen Test and Score pada Orange Data Mining dengan metode *Cross Validation* sebanyak 2 *folds* dan opsi *Stratified*. Model yang digunakan adalah Neural Network, dan evaluasi dilakukan dengan mengukur berbagai metrik performa seperti AUC (*Area Under Curve*), CA (*Classification Accuracy*), F1- score, Precision, Recall, dan MCC (*Matthews Correlation Coefficient*). Metode *Stratified Cross Validation* memastikan bahwa distribusi kelas pada data uji dan data latih tetap proporsional, sehingga hasil evaluasi menjadi lebih representatif.

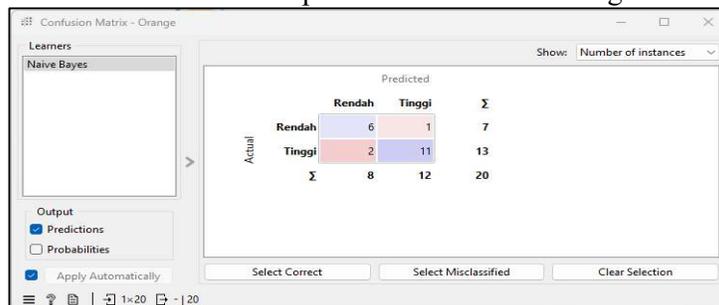
Berdasarkan hasil yang ditampilkan, nilai AUC model adalah 0.929, yang menunjukkan kemampuan model membedakan antara kelas positif dan negatif dengan sangat baik. Nilai CA sebesar 0.850 menunjukkan bahwa akurasi klasifikasi model adalah 85%, atau dengan kata lain 85% prediksi model sesuai dengan label sebenarnya. Selain itu, nilai F1-score sebesar 0.850 mengindikasikan keseimbangan yang baik antara Precision dan Recall, yang penting untuk mengukur kinerja model secara keseluruhan terutama jika data memiliki distribusi kelas yang tidak seimbang.

Selanjutnya, nilai Precision sebesar 0.855 menunjukkan bahwa 85,5% dari prediksi positif model adalah benar, sedangkan nilai Recall sebesar 0.850 berarti model mampu menemukan 85% dari seluruh data positif yang ada. Nilai MCC sebesar 0.704 juga menunjukkan adanya hubungan korelasi yang cukup kuat antara prediksi model dengan label aktual, yang menandakan bahwa model memiliki performa yang

solid dan andal dalam melakukan klasifikasi. Secara keseluruhan, hasil ini memperlihatkan bahwa model Neural Network yang digunakan memiliki kinerja yang cukup baik dalam memproses dan memprediksi data pada penelitian ini.

Hasil *Confusion Matrix*

Confusion Matrix adalah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan antara nilai prediksi dan nilai sebenarnya dari data uji. Tabel ini menampilkan jumlah prediksi benar dan salah untuk setiap kelas, sehingga memudahkan analisis terhadap kesalahan model dan tingkat akurasi prediksi.



Gambar 5. Hasil Evaluasi *Confusion Matrix*

Pada gambar di atas merupakan hasil evaluasi model klasifikasi Naive Bayes yang divisualisasikan melalui *Confusion Matrix* pada aplikasi Orange Data Mining. Matriks ini menunjukkan perbandingan antara label aktual dan label prediksi untuk dua kategori kinerja, yaitu “Rendah” dan “Tinggi”. Dari total 20 data yang diuji, terdapat 6 data aktual kategori “Rendah” yang berhasil diprediksi dengan benar sebagai “Rendah” dan 11 data aktual kategori “Tinggi” yang diprediksi benar sebagai “Tinggi”. Sementara itu, terjadi kesalahan prediksi pada 1 data aktual “Rendah” yang diklasifikasikan sebagai “Tinggi”, serta 2 data aktual “Tinggi” yang diprediksi sebagai “Rendah”.

Interpretasi hasil ini menunjukkan bahwa model memiliki tingkat akurasi yang cukup tinggi karena sebagian besar data berhasil diprediksi dengan benar. Tingkat kesalahan relatif rendah, yaitu hanya 3 dari 20 data (15%) yang salah klasifikasi. Kesalahan terbesar terjadi pada prediksi “Tinggi” yang sebenarnya “Rendah” sebanyak 1 data, dan prediksi “Rendah” yang sebenarnya “Tinggi” sebanyak 2 data. Hal ini mengindikasikan bahwa model Naive Bayes cukup mampu mengenali pola atribut kinerja, namun masih ada sedikit tumpang tindih antar kategori yang mungkin disebabkan oleh kemiripan nilai atribut pada beberapa data.

Secara keseluruhan, *Confusion Matrix* ini memberikan gambaran kuantitatif yang jelas mengenai performa model, khususnya dalam membedakan kategori kinerja “Rendah” dan “Tinggi”. Dominasi angka pada diagonal utama (6 untuk “Rendah” dan 11 untuk “Tinggi”) menandakan bahwa model cenderung stabil dalam prediksi yang sesuai dengan label aktual. Meskipun demikian, analisis lebih lanjut terhadap data yang salah klasifikasi diperlukan untuk memahami faktor penyebabnya, sehingga dapat dilakukan perbaikan baik pada preprocessing data maupun penyesuaian parameter model untuk meningkatkan akurasi di masa mendatang.

5. Kesimpulan

Berdasarkan hasil evaluasi menggunakan *Confusion Matrix*, dapat disimpulkan bahwa model klasifikasi Naive Bayes memiliki kinerja yang cukup baik dalam

membedakan kategori kinerja “Rendah” dan “Tinggi” pada tenaga kependidikan. Dari total 20 data uji, sebanyak 17 data berhasil diprediksi dengan benar, menghasilkan akurasi sekitar 85%. Dominasi prediksi yang tepat pada diagonal utama matriks menunjukkan bahwa model mampu menangkap pola hubungan antaratribut secara efektif, sesuai dengan data pelatihan yang diberikan.

Hasil ini juga mengindikasikan bahwa meskipun model cukup andal, masih terdapat kesalahan klasifikasi pada 3 data, yang dapat disebabkan oleh kemiripan karakteristik antar kelas atau adanya atribut yang tidak terlalu membedakan kategori. Kesalahan prediksi ini terutama muncul ketika data aktual “Tinggi” diprediksi sebagai “Rendah” dan sebaliknya, yang menunjukkan bahwa model kadang kesulitan membedakan data dengan nilai atribut yang berada di batas antara dua kategori tersebut.

Secara keseluruhan, model Naive Bayes layak digunakan sebagai alat bantu pengambilan keputusan dalam mengklasifikasikan kinerja tenaga kependidikan, mengingat tingkat akurasi yang cukup tinggi dan kemampuannya mengidentifikasi mayoritas data dengan benar. Namun, untuk meningkatkan performa di masa mendatang, perlu dilakukan evaluasi lebih lanjut terhadap atribut yang digunakan, pemurnian data, atau pengujian dengan metode klasifikasi lain sebagai pembanding, sehingga hasil yang diperoleh semakin konsisten dan akurat.

Saran

Berdasarkan hasil evaluasi yang diperoleh, disarankan agar pengolahan data pada tahap pra-pemrosesan (*preprocessing*) dilakukan lebih optimal, misalnya melalui normalisasi nilai atribut, penanganan data yang tidak konsisten, dan penghapusan data outlier yang berpotensi mengganggu pola pembelajaran model. Dengan memastikan kualitas data yang lebih bersih dan terstruktur, model Naive Bayes diharapkan dapat mengenali pola dengan lebih akurat, sehingga mengurangi tingkat kesalahan prediksi yang terjadi.

Selain itu, disarankan untuk menambahkan atau memodifikasi atribut yang digunakan dalam klasifikasi. Atribut seperti riwayat prestasi kerja, partisipasi dalam kegiatan sekolah, atau penilaian dari pihak atasan dapat menjadi variabel tambahan yang memperkaya informasi dalam dataset. Dengan atribut yang lebih beragam dan relevan, model akan memiliki lebih banyak parameter pembeda antara kategori “Rendah” dan “Tinggi”, sehingga meningkatkan kemampuan prediksi.

Saran berikutnya adalah melakukan pengujian model dengan metode klasifikasi lain seperti *Decision Tree*, *Random Forest*, atau *Support Vector Machine* sebagai pembanding. Melalui perbandingan ini, dapat diketahui metode mana yang memberikan hasil terbaik untuk dataset yang digunakan. Selain itu, penggunaan teknik *cross-validation* dengan jumlah lipatan (*folds*) yang lebih banyak dapat membantu menghasilkan evaluasi yang lebih representatif dan mengurangi kemungkinan *overfitting*.

6. Daftar Pustaka

- Al Fathir As, R. S., Utami, E., & Dwi Hartono, A. (2023). Comparison of Sentiment Analysis Methods on Topic Haram of Music In Youtube. *Sinkron*, 8(4), 2294–2307. <https://doi.org/10.33395/sinkron.v8i4.12776>
- Ali, R., Yusro, M. M., Hitam, M. S., & Ikhwanuddin, M. (2021). Machine Learning With Multistage Classifiers For Identification Of Of Ectoparasite Infected Mud

- Crab Genus Scylla. *Telkomnika (Telecommunication Computing Electronics and Control)*, 19(2), 406–413.
<https://doi.org/10.12928/TELKOMNIKA.v19i2.16724>
- Arcinas, M. M., Sajja, G. S., Asif, S., Gour, S., Okoronkwo, E., & Naved, M. (2021). Role of Data Mining in Education for Improving Students Performance for Social Change. *Turkish Journal of Physiotherapy and Rehabilitation*, 32(3), 6519–6526.
- Budiman, B. (2021). Perbandingan Algoritma Klasifikasi Data Mining untuk Penelusuran Minat Calon Mahasiswa Baru. *Nuansa Informatika*, 15(2), 37–52.
<https://doi.org/10.25134/nuansa.v15i2.4162>
- Dr. V. Suma. (2020). Data Mining based Prediction of Demand in Indian Market for Refurbished Electronics. *Journal of Soft Computing Paradigm*, 2(3), 153–159.
<https://doi.org/10.36548/jscp.2020.3.002>
- Ekstraksi, D., Kompetensi, P., & Mardiani, L. (2021). *Desain Model Data Mining Pada Model SECI Untuk Pemetaan*. 8(3), 1607.
- Farid Naufal, M., Fernando Susanto, A., Nathaneil Kansil, C., Huda, S., & kunci, K. (2023). Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Potensi Hilangnya Nasabah Bank Application of Machine Learning to Predict Potential Loss of Bank Customer. *Februari*, 22(1), 1–11.
- Hartati, T., Nurdiawan, O., & Wiyandi, E. (2021). Analisis Dan Penerapan Algoritma K-Means Dalam Strategi Promosi Kampus Akademi Maritim Suaka Bahari. *Jurnal Sains Teknologi Transportasi Maritim*, 3(1), 1–7.
<https://doi.org/10.51578/j.sitektransmar.v3i1.30>
- Jahwar, A. (2021). Meta-Heuristic Algorithms for K-means Clustering: A Review. *PalArch's Journal of Archaeology of Egypt/Egyptology*, 17(7), 7–9.
- Karim, F., Nurcahyo, G. W., & Sumijan, S. (2021). Sistem Pakar dalam Mengidentifikasi Gejala Stroke Menggunakan Metode Naive Bayes. *Jurnal Sistikam Informasi Dan Teknologi*, 3, 221–226.
<https://doi.org/10.37034/jsisfotek.v3i4.69>
- Lakhdari, Y., Soldevila, E., Rezgui, J., & Renault, É. (2023). Detection of Plant Diseases in an Industrial Greenhouse: Development, Validation & Exploitation. *2023 International Symposium on Networks, Computers and Communications, ISNCC 2023*. <https://doi.org/10.1109/ISNCC58260.2023.10323932>
- Mulyanto, A., Susanti, E., Rossi, F., Wajiran, W., & Borman, R. I. (2021). Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR). *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(1), 52. <https://doi.org/10.26418/jp.v7i1.44133>
- Nizam Fadli, M., Sudahri Damanik, I., Irawan, E., Tunas Bangsa, S., & Utara, S. (2021). Penerapan Metode Naive Bayes Dalam Menentukan Tingkat Kenyamanan Pada Rumah Sakit Terhadap Pasien. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 2(3), 117–122.
- Palacios, C. A., Reyes-Suárez, J. A., Bearzotti, L. A., Leiva, V., & Marchant, C. (2021). Knowledge discovery for higher education student retention based on data mining: Machine learning algorithms and case study in chile. *Entropy*, 23(4), 1–23. <https://doi.org/10.3390/e23040485>
- Poerwandono, E., & Perwitosari, J. (2023). Penerapan Data Mining Untuk Penilaian Kinerja Karyawan Di PT. Riksa Dinar DJaya Menggunakan Metode Naive Bayes Classification (Edhy Poerwandono 1, Faizal Joko Perwitosari 2)

- Penerapan Data Mining Untuk Penilaian Kinerja Karya Di PT Riksa Dinar Djaya Men. *Jurnal Sains Dan Teknologi*, 5(1), |pp.
- Punkastyo, D. A., Septian, F., & Syaripudin, A. (2024). Implementasi Data Mining Menggunakan Algoritma Naïve Bayes Untuk Prediksi Kelulusan Siswa. *Journal of System and Computer Engineering (JSCE)*, 5(1), 24–35. <https://doi.org/10.61628/jsce.v5i1.1073>
- Putra, Y. E., & Fahrizal, M. (2021). Rancang Bangun Menggunakan Metode Naive Bayes Dalam Sistem Pakar Penentuan Penyakit Tanaman Nanas Berbasis WEB. *Journal Portal Data*, 1(1), 1–18.
- Ridwan, A. (2020). Penerapan Algoritma Naïve Bayes Untuk Klasifikasi Penyakit Diabetes Mellitus. *Jurnal SISKOM-KB (Sistem Komputer Dan Kecerdasan Buatan)*, 4(1), 15–21. <https://doi.org/10.47970/siskom-kb.v4i1.169>
- Setiawan, A., Rabi, A., & Gumilang, Y. S. A. (2024). Pengolahan Citra untuk Sortir Buah Stroberi Berdasarkan Kematangan Menggunakan Algoritma K-Nearest Neighbors (KNN). *Blend Sains Jurnal Teknik*, 2(4), 322–328. <https://doi.org/10.56211/blendsains.v2i4.551>
- Siddik, A. M. A., Lawi, A., & wahid islahfari, M. (2022). Perbandingan Kinerja Model Ensembled Transfer Learning Pada Klasifikasi Penyakit Daun Tomat. *Seminar Nasional Teknik Elektro Dan Informatika (SNTEI)*, 8(1), 286–291.
- Syahputri, N. (2020). Penerapan Data Mining Asosiasi pada Pola Transaksi dengan Metode Apriori. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 4(2), 728–736.
- Wibisono, A. D., Dadi Rizkiono, S., & Wantoro, A. (2020). Filtering Spam Email Menggunakan Metode Naive Bayes. *TELEFORTECH: Journal of Telematics and Information Technology*, 1(1). <https://doi.org/10.33365/tft.v1i1.685>
- Xu, Y., Zheng, X., Li, Y., Ye, X., Cheng, H., Wang, H., & Lyu, J. (2023). Exploring patient medication adherence and data mining methods in clinical big data: A contemporary review. In *Journal of Evidence-Based Medicine* (Vol. 16, Issue 3). <https://doi.org/10.1111/jebm.12548>
- Yoridi, M. L. Y., & Pakereng, M. A. I. (2023). Klasifikasi Anak Berpotensi Putus Sekolah dengan Metode Naïve Bayes Di Kabupaten Manokwari. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 7(2), 968–976.