Jurnal IPTEK Bagi Masyarakat
Vol. 6, No. 2, (2026), pp. 489-500
https://doi.org/10.55537/j-ibm.v6i2.1867
e-ISSN: 2807-7253 | p-ISSN: 2807-7261

Decision Support System for Vocational Training Suitability of Job Applicants Using Naïve Bayes

(Sistem Pendukung Keputusan Kesesuaian Bidang Pelatihan Calon Tenaga Kerja Menggunakan Naïve Bayes)

Nazwatul Husna [a,1*], **Novica Irawati** [a,2], **Sahren** [a,3]

[a] Universitas Royal, Kisaran 21227, Indonesia

E-mail: [1]nazwatulh19@gmail.com; [2]novicairawati11@gmail.com; [3]sahren.one@gmail.com

***Corresponding Author:** nazwatulh19@gmail.com (Nazwatul Husna).

ARTICLE INFO

Received: 4 August 2026
Revised: 26 August 2026
Accepted: 7 September 2026

ABSTRACT

Selecting suitable vocational training for job applicants requires a consistent and efficient assessment process. This study develops a web-based decision support system using the Naïve Bayes algorithm to classify applicants' training suitability. The model was evaluated using 233 historical records, consisting of 186 training data and 47 testing data, with a stratified hold-out scheme. System functionality was tested using Black Box Testing, while classification performance was assessed through a confusion matrix. The system correctly classified 44 of 47 test records, achieving 93.61% accuracy and 85% balanced accuracy. It identified all suitable applicants with 100% recall, while recall for unsuitable applicants was 70%. Because the target labels were derived from historical staff decisions rather than independently validated ground truth, the system should be used as a decision-support tool rather than a replacement for staff judgment.

Keywords:
Naïve Bayes; Vocational Training Program Suitability; Job Training Center; Classification; Web-Based Decision Support System.

How to Cite:

Husna, N., Irawati, N., & Sahren. (2026). Decision Support System for Vocational Training Suitability of Job Applicants Using Naïve Bayes. *Jurnal IPTEK Bagi Masyarakat, 6*(2), 489-500. https://doi.org/10.55537/j-ibm.v6i2.1867

ABSTRAK

Penentuan kesesuaian bidang pelatihan calon tenaga kerja memerlukan proses penilaian yang konsisten dan efisien. Penelitian ini mengembangkan sistem pendukung keputusan berbasis web menggunakan algoritma Naïve Bayes untuk mengklasifikasikan kesesuaian bidang pelatihan peserta. Model dievaluasi menggunakan 233 data historis, terdiri atas 186 data latih dan 47 data uji, dengan skema stratified hold-out. Fungsionalitas sistem diuji melalui Black Box Testing, sedangkan kinerja klasifikasi dievaluasi menggunakan confusion matrix. Sistem berhasil mengklasifikasikan 44 dari 47 data uji dengan akurasi 93,61% dan balanced accuracy 85%. Recall kelas Cocok mencapai 100%, sedangkan kelas Tidak Cocok sebesar 70%. Karena label target berasal dari keputusan historis petugas dan belum divalidasi sebagai ground truth independen, sistem lebih tepat digunakan sebagai alat pendukung, bukan pengganti keputusan petugas.

Kata kunci:
Naïve Bayes; Kesesuaian Bidang Pelatihan; Balai Latihan Kerja; Klasifikasi; Sistem Berbasis Web.

Pendahuluan

Pemilihan bidang pelatihan yang sesuai bagi calon tenaga kerja merupakan tahap penting pada Balai Latihan Kerja (BLK) agar peserta memperoleh pembekalan keterampilan yang relevan dengan kemampuannya. Balai Latihan Kerja yang menjadi lokus studi ini merupakan salah satu instansi pemerintah daerah yang menyelenggarakan pelatihan pada bidang teknik dan industri, teknologi informasi, tata boga dan kecantikan, pertanian, kewirausahaan, hingga konstruksi. Pada setiap periode penerimaan, jumlah pendaftar seleksi tergolong cukup banyak dengan latar belakang pendidikan, pengalaman kerja, usia, serta minat bidang pelatihan yang beragam, sehingga petugas perlu menilai kesesuaian setiap calon peserta terhadap bidang pelatihan yang dipilihnya sebelum keputusan penempatan ditetapkan. Data jumlah pendaftar dan tahapan seleksi (pemeriksaan berkas, tes potensi akademik, tes kejuruan, dan wawancara) pada uraian berikut merupakan data primer yang diperoleh peneliti langsung dari arsip dan hasil wawancara dengan instansi terkait, bukan dikutip dari literatur.

Pada praktiknya, seleksi calon peserta masih dilakukan dengan memeriksa berkas dan hasil tes satu per satu tanpa dukungan sistem yang terintegrasi. Informasi riwayat pendidikan, nilai tes potensi akademik, nilai tes kejuruan, dan hasil wawancara tersimpan pada dokumen terpisah sehingga petugas harus mengumpulkan dan

© 2026 The Author(s).
Published by Ali Institute of Research and Publication (AIRA) – Ali Bersaudara Sejahtera Foundation.
This is an open-access article under the CC BY-NC-SA license.

mencocokkan data tersebut secara manual untuk setiap calon peserta, yang tidak hanya memakan waktu tetapi juga membuka peluang kekeliruan ketika jumlah pendaftar meningkat. Persoalan lain yang tidak kalah penting adalah belum tersedianya standar penilaian yang terdokumentasikan secara baku: penentuan kecocokan peserta selama ini bergantung pada pertimbangan petugas berdasarkan pengalaman, tanpa acuan tertulis mengenai ambang batas nilai atau bobot kriteria, sehingga hasil seleksi antarperiode berpotensi bervariasi meskipun kondisi calon peserta relatif serupa. Kebutuhan akan pendekatan yang lebih terstruktur, mampu mengolah berbagai variabel penilaian secara bersamaan dan memberikan hasil yang konsisten, mendorong pemanfaatan metode klasifikasi berbasis data mining, karena metode tersebut dirancang untuk mengenali pola dari data historis dan menggunakannya memprediksi kelas pada data baru (Farhan et al., 2026).

Metode Naïve Bayes dipilih pada penelitian ini karena struktur perhitungannya relatif sederhana, tidak menuntut volume data latih yang besar, dan tetap memberikan hasil yang cukup baik meskipun jumlah atribut yang diolah cukup banyak. Metode ini telah diterapkan pada berbagai persoalan klasifikasi, di antaranya analisis sentimen ulasan pengguna aplikasi (Riskawati et al., 2024; Daud et al., 2024), klasifikasi kesegaran ikan berdasarkan citra (Muchtar et al., 2024), penentuan penerima bantuan pendidikan (Priyanto et al., 2024), prediksi prestasi siswa (Apsari, 2024), serta prediksi peluang kerja penyandang disabilitas (Yuliadarnita et al., 2025). Kesamaan pada berbagai penerapan tersebut terletak pada kebutuhan mengambil keputusan secara cepat dari data yang terus bertambah tanpa mengorbankan akurasi. Namun demikian, sebagian besar penelitian tersebut menerapkan Naïve Bayes langsung pada data yang telah berbentuk kategorikal atau pada domain analisis sentimen yang berbeda karakteristik datanya dari data seleksi berbasis kriteria numerik-kategorikal seperti pada penelitian ini. Secara metodologis, Naïve Bayes diketahui dapat tetap memberikan kinerja klasifikasi yang baik meskipun asumsi independensi antaratribut tidak selalu sepenuhnya terpenuhi (Domingos & Pazzani, 1997; Hand & Yu, 2001).

Penelitian ini disusun bukan untuk mengklaim kebaruan metodologis pada algoritma Naïve Bayes itu sendiri, melainkan untuk mendokumentasikan penerapan praktisnya pada persoalan nyata di layanan publik ketenagakerjaan, yaitu seleksi kesesuaian bidang pelatihan pada BLK pemerintah daerah. Kontribusi yang ditekankan adalah pada sisi implementasi: (1) pembangunan sistem pendukung keputusan berbasis web yang dapat langsung digunakan petugas; (2) dokumentasi prosedur transformasi data numerik menjadi kategorikal secara transparan agar dapat direplikasi dan diaudit; serta (3) evaluasi kinerja sistem secara menyeluruh, baik dari sisi fungsional (black box testing) maupun akurasi klasifikasi pada kedua kelas target. Penelitian ini juga mendokumentasikan keterbatasan metodologis yang ditemukan selama proses penelitian, termasuk isu validitas label historis, potensi bias pada atribut sensitif, dan kebutuhan validasi silang pada penelitian lanjutan, dengan harapan dokumentasi tersebut bermanfaat bagi pengembangan sistem serupa di instansi lain

Metode

Penelitian ini menggunakan pendekatan kuantitatif terapan (applied research) untuk mengembangkan sistem pendukung keputusan penentuan kesesuaian bidang pelatihan bagi calon peserta BLK. Atribut yang digunakan meliputi usia, jenis kelamin, status perkawinan, pendidikan terakhir, pengalaman kerja atau pelatihan, nilai Tes Potensi Akademik (TPA), nilai tes kejuruan, nilai wawancara, serta bidang pelatihan yang dipilih peserta. Data penelitian merupakan data primer yang diperoleh melalui observasi dan wawancara dengan pimpinan instansi serta kepala bidang terkait, dilengkapi data sekunder berupa arsip pendaftaran, dokumen hasil seleksi periode 2024-2025, dan literatur ilmiah pendukung. Lokasi penelitian adalah kantor Dinas Ketenagakerjaan yang membawahi BLK di Kota Tanjungbalai; alamat lengkap tidak dicantumkan karena tidak diperlukan untuk reproduksibilitas ilmiah.

Penggunaan Atribut Jenis Kelamin dan Status Perkawinan

Dalam penelitian ini, atribut jenis kelamin dan status perkawinan digunakan sebagai bagian dari variabel yang dianalisis karena kedua informasi tersebut tercatat secara historis dalam formulir pendaftaran peserta dan telah menjadi bagian dari data yang digunakan oleh petugas dalam proses penilaian sebelumnya. Penggunaan kedua atribut tersebut tidak didasarkan pada asumsi teoritis bahwa jenis kelamin maupun status perkawinan secara langsung menentukan kesesuaian kompetensi peserta terhadap bidang pelatihan. Dengan demikian, keberadaan kedua atribut lebih berkaitan dengan karakteristik data historis dan mekanisme penilaian yang telah berlangsung sebelum sistem dikembangkan. Meskipun demikian, penggunaan atribut tersebut perlu dipertimbangkan secara hati-hati, khususnya karena sistem yang diterapkan dalam konteks layanan publik memiliki potensi untuk mempertahankan pola keputusan yang kurang objektif apabila terdapat bias pada data historis. Model pembelajaran mesin pada dasarnya mempelajari pola yang terdapat dalam data pelatihan. Oleh karena itu, apabila keputusan sebelumnya dipengaruhi oleh faktor-faktor yang tidak relevan terhadap kompetensi peserta, pola tersebut berpotensi ikut dipelajari dan direproduksi oleh model. Kondisi ini menjadi salah satu aspek penting yang perlu diperhatikan dalam penerapan sistem agar proses rekomendasi tidak menghasilkan perlakuan yang tidak adil terhadap kelompok tertentu. Untuk meningkatkan keterbukaan dan mengendalikan risiko bias, penelitian ini menetapkan batasan yang lebih jelas terhadap penggunaan kedua atribut tersebut. Data individu yang digunakan dalam penelitian sebelumnya saat ini tidak lagi tersedia secara lengkap sehingga analisis ablation untuk mengetahui kontribusi masing-masing atribut serta pengujian kesetaraan kinerja model antar kelompok

belum dapat dilakukan secara kuantitatif. Atas keterbatasan tersebut, jenis kelamin dan status perkawinan direkomendasikan untuk tidak memberikan kontribusi terhadap skor rekomendasi otomatis pada tahap implementasi operasional. Langkah ini ditujukan untuk mengurangi kemungkinan penggunaan karakteristik demografis yang belum terbukti memiliki relevansi langsung terhadap kesesuaian kompetensi peserta. Pada versi penelitian yang dilaporkan dalam artikel ini, kedua atribut tetap dicantumkan dalam model sebagai bagian dari representasi data historis yang dianalisis. Penyertaan tersebut diperlukan untuk menjaga kesesuaian antara model penelitian dan pola data yang menjadi dasar evaluasi. Namun, kondisi tersebut tidak dimaknai sebagai rekomendasi untuk menggunakan kedua atribut sebagai dasar penentuan keputusan dalam proses seleksi secara langsung. Untuk penggunaan operasional, model yang lebih disarankan adalah model yang menonaktifkan pengaruh jenis kelamin dan status perkawinan terhadap skor akhir. Evaluasi lebih lanjut melalui ablation analysis dan audit kesetaraan performa antar kelompok perlu dilakukan menggunakan data periode berikutnya yang tersedia secara lengkap sebelum kedua atribut tersebut dapat dipertimbangkan kembali dalam sistem pengambilan keputusan. Risiko bahwa model pembelajaran mesin dapat mereproduksi bias yang terkandung dalam data historis juga telah dibahas secara luas dalam literatur fairness pada machine learning (Mehrabi et al., 2021).

Status Purwarupa dan Rencana Evaluasi Dampak

Sistem yang dikembangkan dalam penelitian ini masih berada pada tahap purwarupa (prototype). Pengujian yang telah dilakukan mencakup pengujian fungsional menggunakan metode black box testing serta evaluasi performa klasifikasi melalui confusion matrix sebagaimana disajikan pada Tabel 6–8. Pengujian tersebut digunakan untuk memastikan bahwa fungsi utama sistem dapat berjalan sesuai rancangan serta mengetahui kemampuan model dalam melakukan klasifikasi berdasarkan data yang tersedia. Meskipun telah dilakukan pengujian fungsional dan evaluasi kinerja model, sistem belum diterapkan melalui uji coba penggunaan secara langsung dalam proses seleksi operasional. Oleh sebab itu, penelitian ini belum memiliki data empiris mengenai perubahan waktu yang dibutuhkan petugas sebelum dan sesudah menggunakan sistem, tingkat kemudahan penggunaan berdasarkan instrumen usability seperti System Usability Scale (SUS), maupun tingkat penerimaan dan adopsi sistem oleh pengguna. Ketiadaan data tersebut menjadi batasan dalam menarik kesimpulan mengenai dampak sistem terhadap proses kerja institusi. Berdasarkan kondisi tersebut, kontribusi penelitian ini dibatasi pada pengembangan purwarupa dan evaluasi teknis awal, sehingga hasil yang diperoleh belum digunakan untuk menyatakan adanya dampak institusional secara langsung. Pengukuran dampak secara empiris memerlukan penerapan sistem dalam lingkungan operasional yang sebenarnya. Sebagai tindak lanjut, penelitian berikutnya diarahkan pada pelaksanaan pilot pada satu periode seleksi berikutnya dengan melibatkan petugas sebagai pengguna sistem. Evaluasi tersebut dapat mencakup perbandingan waktu penyelesaian proses seleksi sebelum dan sesudah penggunaan sistem, pengukuran usability, tingkat penerimaan pengguna, serta evaluasi konsistensi hasil rekomendasi. Dengan pendekatan tersebut, penelitian lanjutan diharapkan dapat memberikan bukti yang lebih kuat mengenai manfaat praktis sistem sekaligus menjadi dasar untuk menilai kelayakan penerapannya dalam proses seleksi secara operasional.

Ground Truth dan Validitas Label

Label target 'Cocok' dan 'Tidak Cocok' pada dataset ini bersumber dari catatan keputusan penempatan yang telah dibuat petugas pada proses seleksi periode 2024-2025, berdasarkan kriteria yang digali melalui wawancara namun tidak terdokumentasi dalam bentuk rubrik penilaian tertulis maupun diverifikasi ulang oleh pihak ketiga yang independen. Dengan demikian, model yang dilatih dari label ini pada dasarnya mempelajari dan mereplikasi pola keputusan historis petugas, bukan sebuah standar kesesuaian yang objektif dan tervalidasi secara independen. Dengan demikian, sistem ini diposisikan sebagai model yang memprediksi pola keputusan historis petugas seleksi, bukan sebagai mekanisme penentuan kesesuaian yang objektif dan tervalidasi secara independen. Implikasinya, apabila pola keputusan historis tersebut mengandung bias atau inkonsistensi, model akan mempelajari dan berpotensi meneruskan bias tersebut. Oleh karena itu, hasil klasifikasi sistem sebaiknya diposisikan sebagai rekomendasi pendukung, bukan keputusan akhir, dan tetap memerlukan tinjauan petugas berwenang.

Transformasi Data Numerik ke Kategorikal

Empat variabel numerik, yaitu nilai TPA, nilai kejuruan, nilai wawancara, dan usia, dikonversi menjadi bentuk kategorikal menggunakan ambang batas tetap (TPA/Kejuruan/Wawancara ≥ 75 dikategorikan Tinggi; usia ≥ 25 tahun dikategorikan sebagai kelompok usia ≥25). Ambang batas ini merupakan parameter yang ditetapkan mengikuti konvensi nilai kelulusan/kompetensi yang lazim digunakan pada evaluasi tes semacam ini, dan bukan hasil perhitungan statistik formal (median atau mean) terhadap data latih; ambang batas tersebut tidak didasarkan pada median atau mean data latih karena bukti perhitungan statistik formal tidak tersedia. Penulis mengakui bahwa ambang batas tetap semacam ini, meskipun praktis dan konsisten dengan konvensi penilaian di lapangan, tidak otomatis menjadi batas substantif yang membedakan peserta 'kompeten' dan 'tidak kompeten', dan proses dikotomisasi ini turut menghilangkan informasi kontinu yang terkandung pada nilai asli. Untuk mengurangi risiko ini pada penelitian selanjutnya, disarankan dilakukan analisis sensitivitas terhadap pilihan

ambang batas (misalnya menguji beberapa titik potong dan membandingkan dampaknya terhadap performa model) atau menerapkan varian Naïve Bayes yang mampu menangani atribut kontinu secara langsung (Gaussian Naïve Bayes), tanpa memerlukan proses diskritisasi. Untuk menjaga netralitas istilah, kategori usia ditulis menggunakan label numerik netral '<25 tahun' dan '≥25 tahun'.

Dari 233 data historis, 186 data (79,8%) digunakan sebagai data latih dan 47 data (20,2%) sebagai data uji. Pembagian dilakukan secara stratified agar proporsi kelas Cocok dan Tidak Cocok pada kedua subset tetap sebanding dengan distribusi data asal. Skema evaluasi yang digunakan adalah hold-out berstrata satu kali, bukan validasi silang k-fold. Berkas data mentah periode 2024–2025 dalam bentuk yang dapat diproses ulang tidak lagi tersedia secara lengkap, sehingga validasi silang dan audit ulang pada tingkat individu tidak dapat dijalankan untuk artikel ini. Sebagian distribusi frekuensi data latih yang masih terdokumentasi digunakan untuk menelusuri perhitungan likelihood dan ditampilkan pada tabel perhitungan yang tersedia, tetapi tabel frekuensi agregat lengkap untuk seluruh kategori atribut tidak tercantum dalam naskah. Karena itu, verifikasi ulang perhitungan prior, likelihood, dan posterior hanya dapat dilakukan secara terbatas. Nilai akurasi 93,61% dan metrik lain pada Tabel 7 dan Tabel 8 merupakan hasil dari satu pembagian hold-out dan diposisikan sebagai gambaran performa pada data uji penelitian, bukan estimasi yang telah dikonfirmasi melalui validasi silang atau replikasi independen. Penelitian selanjutnya perlu merencanakan k-fold cross-validation sejak awal dan menerapkan pengelolaan, pencadangan, serta anonimisasi data yang memungkinkan audit dan pengujian ulang dengan tetap menjaga privasi peserta. Keterbatasan evaluasi berbasis satu pembagian data perlu diperhatikan karena estimasi galat model dipengaruhi oleh prosedur validasi yang digunakan (Varma & Simon, 2006).

Model klasifikasi dibangun menggunakan algoritma Naïve Bayes dengan menerapkan prinsip Teorema Bayes: probabilitas prior tiap kelas dihitung dari proporsi data latih, probabilitas likelihood tiap atribut dihitung dari frekuensi kemunculan kategori pada masing-masing kelas, kemudian nilai posterior diperoleh dari perkalian prior dengan seluruh likelihood. Kelas dengan nilai posterior tertinggi ditetapkan sebagai hasil prediksi. Implementasi sistem yang digunakan pada evaluasi hold-out 47 data uji belum menggunakan teknik Laplace smoothing. Kondisi tersebut menimbulkan permasalahan zero-frequency, yaitu munculnya probabilitas bernilai nol ketika suatu kategori atribut tidak ditemukan pada data latih untuk kelas tertentu. Permasalahan ini terlihat pada hasil perhitungan tanpa smoothing, khususnya pada Peserta2, Peserta11, Peserta16, dan Peserta28 yang menghasilkan nilai posterior untuk kelas Tidak Cocok sebesar 0,000000. Nilai tersebut menunjukkan bahwa terdapat setidaknya satu probabilitas kondisional pada kombinasi atribut peserta yang bernilai nol sehingga menyebabkan keseluruhan hasil perkalian likelihood untuk kelas tersebut menjadi nol. Berdasarkan pemeriksaan terhadap distribusi data latih, kategori status "Pernah Menikah" menjadi salah satu faktor yang menyebabkan munculnya kondisi tersebut. Kategori ini tidak ditemukan pada kelas Tidak Cocok, dengan frekuensi 0 dari 34 data latih pada kelas tersebut. Apabila kondisi tersebut digunakan secara langsung dalam perhitungan Naive Bayes tanpa mekanisme penanganan, probabilitas posterior kelas terkait akan menjadi nol meskipun atribut lainnya memiliki nilai probabilitas yang lebih besar dari nol. Hal ini dapat memengaruhi proses klasifikasi karena keberadaan satu kategori yang tidak muncul dalam data latih dapat secara langsung menghilangkan kemungkinan suatu kelas. Untuk mengatasi permasalahan tersebut, secara analitis diterapkan Laplace smoothing atau additive smoothing pada perhitungan likelihood. Teknik ini dilakukan dengan menambahkan nilai 1 pada frekuensi setiap kategori dan menyesuaikan penyebut berdasarkan jumlah kategori yang terdapat pada atribut terkait. Perhitungan probabilitas kondisional dilakukan menggunakan persamaan:

$$P(x_i|C_j) = \frac{n(x_i,C_j)+1}{n(C_j)+k} \quad (1)$$

dengan $n(x_i, C_j)$ merupakan jumlah kemunculan kategori x_i pada kelas C_j, $n(C_j)$ menunjukkan jumlah keseluruhan data pada kelas tersebut, dan k merupakan jumlah kategori pada atribut yang sedang dihitung. Dengan pendekatan ini, kategori yang sebelumnya tidak memiliki kemunculan pada suatu kelas tidak lagi menghasilkan probabilitas nol.

Dalam analisis tambahan, Laplace smoothing diterapkan pada likelihood yang dapat dihitung ulang dari distribusi frekuensi agregat. Namun, evaluasi final terhadap 47 data uji tetap merefleksikan implementasi sistem tanpa smoothing karena profil atribut individu data uji tidak lagi tersedia secara lengkap. Nilai likelihood hasil penyesuaian yang dapat diverifikasi digunakan untuk menunjukkan mekanisme penanganan zero-frequency pada algoritma Naïve Bayes.

Tahapan penelitian meliputi identifikasi masalah, pengumpulan data, transformasi data, analisis menggunakan algoritma Naïve Bayes, perancangan sistem, pembangunan aplikasi, pengujian, dan implementasi. Perancangan sistem menggunakan pemodelan Unified Modeling Language (use case diagram, activity diagram, sequence diagram, class diagram, serta Entity Relationship Diagram). Sistem diimplementasikan berbasis web menggunakan framework CodeIgniter 4, bahasa pemrograman PHP, dan basis data MySQL. Pengujian sistem menggunakan metode Black Box Testing untuk memverifikasi fungsi autentikasi, pengelolaan data peserta, pengolahan data latih, proses klasifikasi, dan penyajian laporan. Evaluasi kinerja klasifikasi dilakukan dengan membandingkan keluaran sistem terhadap label historis pada 47 data uji, dan dilaporkan menggunakan confusion matrix beserta metrik akurasi, presisi, recall, F1-score, dan balanced accuracy pada kedua kelas target, mengingat

distribusi kelas pada dataset ini tidak seimbang (152 Cocok berbanding 34 Tidak Cocok pada data latih).

Hasil

Analisis Kebutuhan

Analisis kebutuhan bertolak dari pengamatan bahwa penentuan kecocokan calon peserta terhadap bidang pelatihan masih sepenuhnya bergantung pada pertimbangan petugas tanpa dasar perhitungan yang terdokumentasi, sehingga sulit dijelaskan secara kuantitatif ketika hasil keputusan dipertanyakan dan berpotensi menghasilkan keputusan berbeda antarpetugas. Sistem yang dirancang dimaksudkan untuk mengambil alih beban perhitungan yang selama ini dilakukan manual, tanpa menghilangkan peran petugas sebagai pengambil keputusan akhir. Kebutuhan data masukan mencakup sembilan atribut: status perkawinan, jenis kelamin, usia, pendidikan terakhir, pengalaman kerja/pelatihan, nilai TPA, nilai kejuruan, nilai wawancara, dan bidang pelatihan pilihan. Data administratif (NIK, nama, alamat) tidak dilibatkan dalam perhitungan.

Keluaran sistem berupa rekomendasi kategori kesesuaian (Cocok/Tidak Cocok), nilai probabilitas pendukung, serta laporan hasil klasifikasi. Terdapat dua peran pengguna: petugas administrasi (akses penuh pengelolaan data dan proses klasifikasi) dan Kepala BLK (memantau laporan dan memberikan catatan tanpa mengelola data). Sistem dibangun menggunakan PHP dengan framework CodeIgniter 4, basis data MySQL, dan berjalan pada spesifikasi perangkat keras standar (setara Intel Core i3, RAM minimal 4 GB), mengikuti arsitektur client-server.

Perhitungan Metode Naïve Bayes

Data mentah calon peserta dikonversi ke bentuk kategorikal menggunakan parameter ambang batas pada Tabel 1:

Tabel 1. Kategori dan Parameter Transformasi Data

No	Atribut	Kategori	Parameter
1	Nilai TPA	Tinggi / Rendah	≥ 75 = Tinggi; < 75 = Rendah
2	Nilai Kejuruan	Tinggi / Rendah	≥ 75 = Tinggi; < 75 = Rendah
3	Nilai Wawancara	Tinggi / Rendah	≥ 75 = Tinggi; < 75 = Rendah
4	Usia	<25 tahun / ≥25 tahun	Ambang batas 25 tahun
5	Pendidikan	Menengah / Tinggi	SMA/SMK = Menengah; Diploma/Sarjana = Tinggi

Sebagai gambaran, dua data mentah dan hasil konversinya ditunjukkan pada Tabel 2:

Tabel 2. Contoh Data Sebelum dan Sesudah Transformasi

No	Status	JK	Usia	Pendidikan	Pengalaman	TPA	Kejuruan	Wawancara	Pilihan BLK	Label
1	B	L	≥25	Menengah	Teknisi	Tinggi	Tinggi	Tinggi	Teknologi Informasi	—
2 (Peserta1)	S	P	≥25	Tinggi	Teknisi	Rendah	Tinggi	Rendah	Teknik & Industri	Tidak Cocok

Adapun rumus dasar perhitungannya adalah Probabilitas prior tiap kelas:

$$P(C_j) = \frac{n_{C_j}}{n} \tag{2}$$

Probabilitas likelihood tiap kriteria terhadap kelas:

$$P(x_i \mid C_j) = \frac{n_{x_i,C_j}}{n_{C_j}} \tag{3}$$

Probabilitas posterior sebagai dasar keputusan klasifikasi:

$$P(C_j \mid X) = P(C_j) \times \prod_{i=1}^{n} P(x_i \mid C_j) \tag{4}$$

Dengan data latih berjumlah 186 record (152 Cocok, 34 Tidak Cocok), diperoleh nilai prior:

$$P(Cocok) = \frac{152}{186} = 0{,}8172$$

$$P(Tidak\ Cocok) = \frac{34}{186} = 0{,}1828 \tag{5}$$

Contoh ilustrasi mekanisme perhitungan (bukan salah satu dari 47 data uji, semata menunjukkan cara kerja

rumus) menggunakan profil: Status (B), JK (L), Usia (≥25), Pendidikan (Menengah), Pengalaman (Teknisi), TPA (Tinggi), Kejuruan (Tinggi), Wawancara (Tinggi), Pilihan BLK (Teknologi Informasi):

V(Cocok) = 0,8172 × 0,4408 × 0,4868 × 0,7171 × 0,6250 × 0,1513 × 0,7105 × 0,5724 × 0,7895 × 0,2039
= 0,000778
V(Tidak Cocok) = 0,1828 × 0,2941 × 0,5294 × 0,7941 × 0,7059 × 0,1765 × 0,1471 × 0,2647 × 0,2647 × 0,2059
= 0,000006

Karena V(Cocok) = 0,000778 > V(Tidak Cocok) = 0,000006, profil ilustrasi ini diklasifikasikan Cocok.

Perhitungan berikutnya adalah data uji sesungguhnya, yaitu Peserta1 (baris pertama Tabel 5), dengan profil: Status (S), JK (P), Usia (≥25), Pendidikan (Tinggi), Pengalaman (Teknisi), TPA (Rendah), Kejuruan (Tinggi), Wawancara (Rendah), Pilihan BLK (Teknik dan Industri), Target Aktual: Tidak Cocok. Nilai likelihood yang menjadi sumber setiap faktor disajikan pada Tabel 3:

Tabel 3. Nilai Likelihood Sumber Perhitungan Peserta1

Atribut	Kategori	P(x|Cocok)	P(x|Tidak Cocok)
Status	S (Sudah Menikah)	0,5461 (83/152)	0,7059 (24/34)
Jenis Kelamin	P (Perempuan)	0,5132 (78/152)	0,4706 (16/34)
Usia	≥25	0,7171 (109/152)	0,7941 (27/34)
Pendidikan	Tinggi	0,3750 (57/152)	0,2941 (10/34)
Pengalaman	Teknisi	0,1513 (23/152)	0,1765 (6/34)
Nilai TPA	Rendah	0,2895 (44/152)	0,8529 (29/34)
Nilai Kejuruan	Tinggi	0,5724 (87/152)	0,2647 (9/34)
Nilai Wawancara	Rendah	0,2105 (32/152)	0,7353 (25/34)
Pilihan BLK	Teknik & Industri	0,1711 (26/152)	0,2353 (8/34)

V(Cocok) = 0,8172 × 0,5461 × 0,5132 × 0,7171 × 0,3750 × 0,1513 × 0,2895 × 0,5724 × 0,2105 × 0,1711
= 0,0000556

V(Tidak Cocok) = 0,1828 × 0,7059 × 0,4706 × 0,7941 × 0,2941 × 0,1765 × 0,8529 × 0,2647 × 0,7353 × 0,2353
= 0,0000978

Karena V(Cocok) = 0,0000556 < V(Tidak Cocok) = 0,0000978, Peserta1 diklasifikasikan Tidak Cocok, sesuai dengan target aktualnya. Perhitungan ini menggunakan likelihood tanpa Laplace smoothing dan dipertahankan untuk konsistensi dengan implementasi sistem yang dievaluasi pada 47 data hold-out.

$$P(x_i \mid C_j) = [n(x_i, C_j) + 1] / [n(C_j) + k] \quad (6)$$

Penerapan metode ini bertujuan mengatasi permasalahan zero-frequency sehingga kategori yang tidak ditemukan pada data latih tetap memiliki nilai probabilitas dan tidak menyebabkan hasil posterior menjadi nol. Pendekatan ini juga dapat meningkatkan kestabilan proses klasifikasi Naive Bayes dan pada kondisi tertentu berpotensi meningkatkan akurasi (Listiowarni, 2019; Rizky et al., 2024). Berdasarkan data latih, permasalahan zero-frequency hanya ditemukan pada atribut Status, yaitu kategori "Pernah Menikah" pada kelas Tidak Cocok dengan frekuensi 0 dari 34 data. Setelah dilakukan smoothing, nilai likelihood kategori tersebut dihitung kembali dan digunakan dalam proses klasifikasi. Hasil perhitungan likelihood yang telah disesuaikan disajikan pada Tabel 4.

Tabel 4. Likelihood Atribut Status Sebelum dan Sesudah Laplace Smoothing

Kategori Status	P(x|Cocok) tanpa smoothing	P(x|Cocok) dengan smoothing	P(x|Tidak Cocok) tanpa smoothing	P(x|Tidak Cocok) dengan smoothing
B (Belum Menikah)	0,4408 (67/152)	0,4387 (68/155)	0,2941 (10/34)	0,2973 (11/37)
S (Sudah Menikah)	0,5461 (83/152)	0,5419 (84/155)	0,7059 (24/34)	0,6757 (25/37)
P (Pernah Menikah)	0,0132 (2/152)	0,0194 (3/155)	0,0000 (0/34)	0,0270 (1/37)

Perbedaan paling menonjol terlihat pada kategori Pernah Menikah di kelas Tidak Cocok: nilai likelihood berubah dari 0,0000 (tanpa smoothing) menjadi 0,0270 (dengan smoothing), sehingga tidak lagi meniadakan seluruh nilai posterior secara paksa. Untuk atribut lain (Jenis Kelamin, Usia, Pendidikan, Pengalaman, Nilai TPA, Nilai Kejuruan, Nilai Wawancara, Pilihan BLK), tidak ditemukan frekuensi nol pada data latih, sehingga smoothing hanya menggeser nilainya sedikit tanpa mengubah urutan kategori dominan. Dengan likelihood yang telah di-smoothing, dua contoh perhitungan manual dihitung ulang sebagai berikut:

Ilustrasi (dengan smoothing): V(Cocok) = 0,000765; V(Tidak Cocok) = 0,0000072 → tetap Cocok. Peserta1 (dengan smoothing): V(Cocok) = 0,0000571; V(Tidak Cocok) = 0,0000936 → tetap Tidak Cocok.

Empat baris pada Tabel 5 (Peserta2, Peserta11, Peserta16, dan Peserta28) melaporkan V(Tidak Cocok) = 0,000000, yang kemungkinan merupakan artefak zero-frequency pada kombinasi atribut yang memuat kategori tanpa kemunculan pada kelas Tidak Cocok. Karena profil atribut individual keempat data uji tersebut tidak lagi tersedia, nilai tersebut tidak ditimpa dengan hasil smoothing yang tidak dapat diverifikasi. Peserta16 merupakan salah satu dari tiga kesalahan klasifikasi dengan margin sangat tipis (0,000002 berbanding 0,000000); smoothing berpotensi mengubah margin tersebut, tetapi arah klasifikasinya tidak dapat dipastikan tanpa data individu. Kondisi ini diperlakukan sebagai keterbatasan evaluasi yang perlu diverifikasi pada data periode berikutnya.

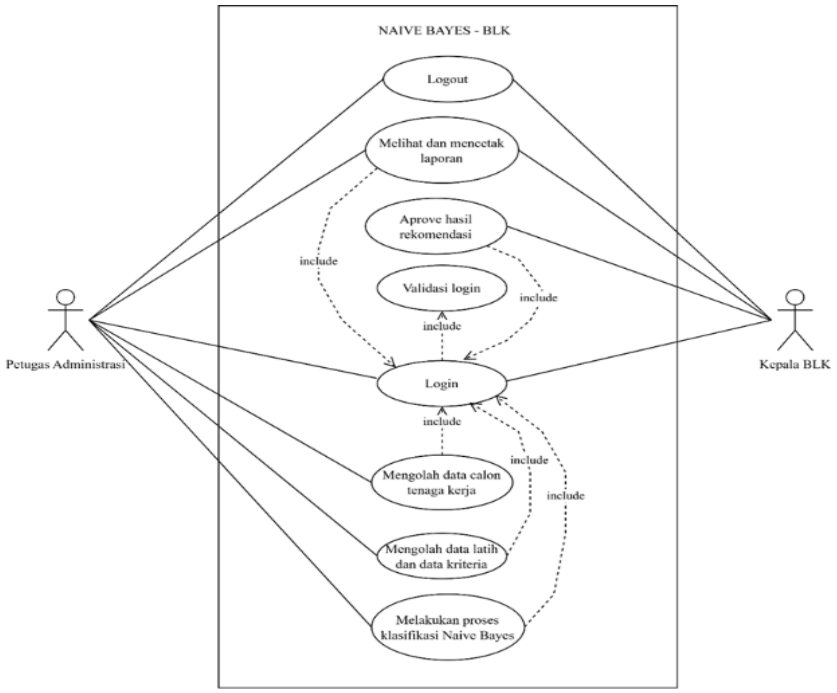
Hasil klasifikasi lengkap terhadap seluruh 47 data uji (dihitung tanpa smoothing, konsisten dengan sistem yang telah diimplementasikan dan diuji black box) disajikan pada Tabel 5, sebagaimana dijelaskan pada paragraf sebelumnya.

Tabel 5. Hasil Klasifikasi 47 Data Uji

No	Idpeserta	Nilai Posterior (Cocok)	Nilai Posterior (Tidak Cocok)	Prediksi Sistem	Data Aktual	Keterangan
1	Peserta1	0,000056	0,000098	Tidak Cocok	Tidak Cocok	Sesuai
2	Peserta2	0,000006	0,000000	Cocok	Cocok	Sesuai
3	Peserta3	0,0009819	0,000004	Cocok	Cocok	Sesuai
4	Peserta4	0,0000497	0,000127	Tidak Cocok	Tidak Cocok	Sesuai
5	Peserta5	0,000984	0,000027	Cocok	Cocok	Sesuai
6	Peserta6	0,000496	0,000069	Cocok	Cocok	Sesuai
7	Peserta7	0,000383	0,000113	Cocok	Cocok	Sesuai
8	Peserta8	0,000689	0,000005	Cocok	Cocok	Sesuai
9	Peserta9	0,000039	0,000153	Tidak Cocok	Tidak Cocok	Sesuai
10	Peserta10	0,000180	0,000012	Cocok	Cocok	Sesuai
11	Peserta11	0,000163	0,000000	Cocok	Cocok	Sesuai
12	Peserta12	0,000184	0,000001	Cocok	Cocok	Sesuai
13	Peserta13	0,000174	0,000019	Cocok	Cocok	Sesuai
14	Peserta14	0,000066	0,000978	Tidak Cocok	Tidak Cocok	Sesuai
15	Peserta15	0,000337	0,000057	Cocok	Cocok	Sesuai
16	Peserta16	0,000002	0,000000	Cocok	Tidak Cocok	Tidak Sesuai
17	Peserta17	0,000259	0,000132	Cocok	Cocok	Sesuai
18	Peserta 18	0,000226	0,000049	Cocok	Tidak Cocok	Tidak Sesuai
19	Peserta 19	0,000091	0,000356	Tidak Cocok	Tidak Cocok	Sesuai
20	Peserta 20	0,000032	0,000003	Cocok	Cocok	Sesuai
21	Peserta 21	0,000279	0,000074	Cocok	Cocok	Sesuai
22	Peserta 22	0,000512	0,000003	Cocok	Cocok	Sesuai
23	Peserta 23	0,001117	0,000008	Cocok	Cocok	Sesuai
24	Peserta 24	0,000451	0,000037	Cocok	Cocok	Sesuai
25	Peserta 25	0,000809	0,000016	Cocok	Cocok	Sesuai
26	Peserta 26	0,000895	0,000003	Cocok	Cocok	Sesuai
27	Peserta 27	0,000283	0,000015	Cocok	Cocok	Sesuai
28	Peserta 28	0,000002	0,000000	Cocok	Cocok	Sesuai
29	Peserta 29	0,000347	0,000084	Cocok	Cocok	Sesuai
30	Peserta 30	0,000114	0,000428	Tidak Cocok	Tidak Cocok	Sesuai
31	Peserta 31	0,001459	0,000017	Cocok	Cocok	Sesuai
32	Peserta 32	0,000116	0,000002	Cocok	Cocok	Sesuai
33	Peserta 33	0,000865	0,000017	Cocok	Cocok	Sesuai
34	Peserta 34	0,000958	0,000029	Cocok	Cocok	Sesuai
35	Peserta 35	0,000063	0,000011	Cocok	Cocok	Sesuai
36	Peserta 36	0,000633	0,000007	Cocok	Cocok	Sesuai
37	Peserta 37	0,000099	0,000535	Tidak Cocok	Tidak Cocok	Sesuai
38	Peserta 38	0,000059	0,000035	Cocok	Cocok	Sesuai
39	Peserta 39	0,000044	0,000018	Cocok	Tidak Cocok	Tidak Sesuai
40	Peserta 40	0,000734	0,000014	Cocok	Cocok	Sesuai
41	Peserta 41	0,000812	0,000022	Cocok	Cocok	Sesuai
42	Peserta 42	0,000482	0,000007	Cocok	Cocok	Sesuai
43	Peserta 43	0,000188	0,000001	Cocok	Cocok	Sesuai
44	Peserta 44	0,000181	0,000007	Cocok	Cocok	Sesuai
45	Peserta 45	0,000432	0,000017	Cocok	Cocok	Sesuai
46	Peserta 46	0,001025	0,000024	Cocok	Cocok	Sesuai
47	Peserta 47	0,000104	0,000008	Cocok	Cocok	Sesuai

Perancangan Sistem

Rancangan sistem disusun berdasarkan hasil analisis kebutuhan, dengan tujuan menerjemahkan kebutuhan fungsional ke dalam bentuk model yang dapat dipahami baik oleh pengembang maupun pengguna. Pemodelan sistem dilakukan menggunakan beberapa diagram Unified Modeling Language yang masing-masing menggambarkan aspek berbeda dari sistem yang dibangun (Wie & Siddik, 2022). Diagram use case digunakan sebagai titik awal perancangan karena mampu menunjukkan fungsi-fungsi yang tersedia dalam sistem beserta pihak yang berhak menjalankannya. Pada sistem ini terdapat dua aktor, yaitu petugas administrasi dan Kepala Balai Latihan Kerja. Petugas administrasi memiliki wewenang untuk masuk ke sistem, mengelola data calon tenaga kerja, menginput dan mengelola kriteria klasifikasi, menjalankan proses perhitungan Naive Bayes, serta melihat hasil rekomendasi. Kepala Balai Latihan Kerja memiliki akses untuk masuk ke sistem, meninjau laporan hasil rekomendasi, serta memberikan persetujuan atau catatan terhadap hasil klasifikasi.

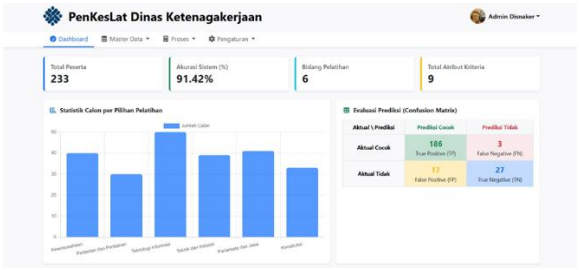


Gambar 1. Use Case Diagram

Perancangan dilanjutkan dengan diagram aktivitas untuk menjelaskan alur kerja tiap proses secara lebih rinci, mencakup alur login pengguna, alur pengelolaan data peserta, alur pengelolaan data latih, alur pengisian data uji, hingga alur inti sistem berupa proses klasifikasi yang menghasilkan laporan akurasi dan confusion matrix. Diagram sekuensial disusun untuk memperlihatkan urutan komunikasi antarobjek dalam sistem, sedangkan diagram kelas menggambarkan struktur statis sistem, meliputi entitas pengguna, peserta, data latih, data uji, dan hasil klasifikasi beserta relasi antarentitasnya. Struktur data yang dipetakan pada diagram kelas selanjutnya diterjemahkan ke dalam Entity Relationship Diagram sebagai dasar perancangan basis data secara fisik, yang menggambarkan hubungan antara tabel pengguna, tabel peserta, tabel data latih, tabel data uji, dan tabel hasil klasifikasi lengkap dengan atribut serta tipe datanya. Tabel data latih dan data uji dirancang memiliki struktur kolom yang identik, meliputi status perkawinan, jenis kelamin, usia, pendidikan, pengalaman, nilai tes potensi akademik, nilai tes kejuruan, nilai wawancara, pilihan bidang pelatihan, dan kolom label sebagai target klasifikasi, sehingga proses pembacaan data antara tahap pelatihan model dan tahap pengujian dapat dilakukan dengan format yang konsisten.

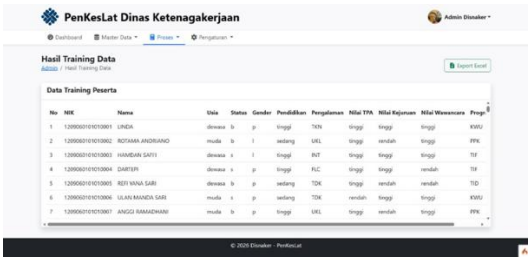
Implementasi Sistem

Tahap implementasi menerjemahkan seluruh rancangan yang telah disusun, mulai dari model use case, diagram aktivitas, struktur basis data, hingga logika perhitungan Naive Bayes, menjadi aplikasi berbasis web. Pembangunan sistem dilakukan menggunakan bahasa pemrograman PHP dengan framework CodeIgniter 4, basis data MySQL yang dikelola melalui XAMPP, serta Visual Studio Code sebagai lingkungan pengembangan. Struktur basis data mengikuti rancangan Entity Relationship Diagram pada tahap sebelumnya, mencakup tabel pengguna, tabel peserta, tabel data latih dan data uji, serta tabel hasil klasifikasi. Setelah berhasil masuk, pengguna diarahkan ke halaman dashboard sebagai pusat informasi utama, yang menampilkan ringkasan jumlah peserta pelatihan terdaftar, tingkat akurasi sistem, jumlah bidang pelatihan yang tersedia, serta jumlah atribut yang digunakan dalam klasifikasi, dilengkapi grafik statistik peserta dan visualisasi confusion matrix hasil evaluasi model. Tampilan dashboard dirancang berbeda antara peran admin dan Kepala Balai Latihan Kerja.



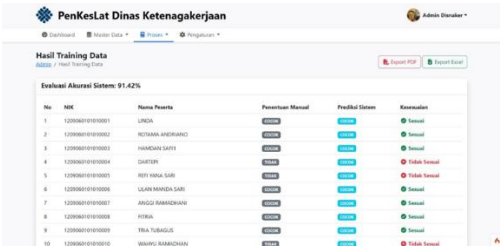
Gambar 2. Dashboard Page

Gambar 2 berasal dari sesi pengujian antarmuka yang berbeda dari evaluasi hold-out final. Angka 91,42% yang tampak pada tangkapan layar merupakan keluaran sesi tersebut, sedangkan kinerja model yang digunakan dalam analisis penelitian adalah 93,61% sebagaimana dilaporkan pada Tabel 7–8.



Gambar 3. Training Data Page

Menu data testing digunakan untuk memasukkan data calon peserta baru yang akan diuji kesesuaiannya. Setelah data uji dimasukkan, sistem secara otomatis menjalankan perhitungan posterior probability berdasarkan model yang telah terbentuk dari data latih, kemudian menampilkan hasil prediksi berdampingan dengan status kesesuaian antara prediksi sistem dan penentuan manual sebagai bahan verifikasi.



Gambar 4. Testing Data Page

Gambar 4 juga berasal dari sesi pengujian antarmuka yang berbeda. Angka 91,42% pada tangkapan layar ditampilkan sebagai bagian dari dokumentasi antarmuka, sedangkan evaluasi hold-out final yang menjadi dasar pelaporan kinerja model tetap 93,61% sebagaimana disajikan pada Tabel 7–8.

Selain ketiga halaman utama tersebut, sistem menyediakan halaman perhitungan yang menampilkan secara rinci nilai probabilitas prior dan likelihood dari setiap atribut, sehingga proses klasifikasi dapat ditelusuri dasar perhitungannya, serta halaman profil pengguna untuk mengelola informasi akun. Seluruh modul terhubung melalui basis data yang sama, sehingga perubahan pada satu modul akan langsung memengaruhi hasil perhitungan pada modul klasifikasi tanpa memerlukan proses tambahan dari pengguna

Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa seluruh fitur yang telah diimplementasikan berfungsi sesuai rancangan dan kebutuhan yang ditetapkan sebelumnya. Metode yang digunakan adalah black box testing, yaitu pendekatan pengujian yang menitikberatkan pada kesesuaian antara masukan yang diberikan dengan keluaran yang dihasilkan sistem tanpa menelusuri struktur kode program di baliknya. Pengujian dilakukan pada tujuh halaman utama sistem, yaitu halaman login, halaman data peserta, halaman kelola nilai, halaman proses Naive Bayes, halaman laporan data training, halaman ganti password, dan halaman dashboard. Hasil pengujian disajikan pada Tabel 6.

Tabel 6. Hasil Pengujian dengan Metode Black Box

No	Skenario Pengujian	Hasil yang Diharapkan	Hasil yang Diperoleh	Kesimpulan
1	Kolom *username* dan/atau *password* dikosongkan lalu klik masuk	Sistem menolak akses *login*	Sesuai harapan	Valid

No	Skenario Pengujian	Hasil yang Diharapkan	Hasil yang Diperoleh	Kesimpulan
2	Kolom username dan *password* diisi dengan data yang benar lalu klik masuk	Login berhasil dan pengguna masuk ke halaman *dashboard*	Sesuai harapan	Valid
3	Menambahkan data peserta	Data berhasil tersimpan dalam sistem	Sesuai harapan	Valid
4	Mengosongkan salah satu kolom saat *input*	Sistem menampilkan peringatan bahwa data harus diisi	Sesuai harapan	Valid
5	Mengubah data peserta	Data berhasil diperbarui	Sesuai harapan	Valid
6	Menghapus data peserta	Data berhasil dihapus dari sistem	Sesuai harapan	Valid
7	Menambahkan nilai peserta	Nilai berhasil tersimpan dalam sistem	Sesuai harapan	Valid
8	Mengosongkan salah satu nilai	Sistem menampilkan pesan peringatan	Sesuai harapan	Valid
9	Mengubah nilai yang sudah tersimpan	Data nilai berhasil diperbarui	Sesuai harapan	Valid
10	Klik tombol proses *Naive Bayes*	Sistem melakukan proses pengelompokan data peserta	Sesuai harapan	Valid
11	Menampilkan hasil perhitungan label cocok	Sistem menampilkan nilai perhitungan label cocok	Sesuai harapan	Valid
12	Menampilkan hasil perhitungan label tidak cocok	Sistem menampilkan nilai perhitungan label tidak cocok	Sesuai harapan	Valid
13	Membuka halaman laporan	Sistem menampilkan daftar hasil prediksi	Sesuai harapan	Valid
14	Menampilkan hasil prediksi sistem	Sistem menampilkan hasil prediksi secara lengkap	Sesuai harapan	Valid
15	Melakukan pencetakan laporan	Sistem menampilkan halaman cetak laporan	Sesuai harapan	Valid

Berdasarkan Tabel 6, seluruh skenario yang diujikan pada setiap halaman menunjukkan hasil yang sesuai dengan harapan, sehingga dapat disimpulkan bahwa sistem berjalan sesuai rancangan fungsional yang telah ditetapkan tanpa ditemukan kegagalan fitur yang berarti. Selain pengujian fungsional, dilakukan evaluasi kinerja model klasifikasi menggunakan 47 data uji yang belum pernah dilibatkan dalam pembentukan model. Hasil evaluasi dipetakan ke dalam confusion matrix pada Tabel 7.

Tabel 7. Confusion Matrix Hasil Pengujian Model

Data Aktual / Prediksi	Cocok	Tidak Cocok	Total
Cocok	37	0	37
Tidak Cocok	3	7	10
Total Prediksi	40	7	47

Karena distribusi kelas tidak seimbang (37 Cocok berbanding 10 Tidak Cocok pada data uji), metrik dilaporkan untuk kedua kelas beserta balanced accuracy, sebagaimana disajikan pada Tabel 8: Pada data tidak seimbang, evaluasi yang memperhatikan kinerja per kelas lebih informatif daripada hanya mengandalkan akurasi keseluruhan (Saito & Rehmsmeier, 2015; Chicco & Jurman, 2020).

Tabel 8. Metrik Evaluasi pada Kedua Kelas

Metrik	Kelas Cocok	Kelas Tidak Cocok
Precision	92,50% (37/40)	100% (7/7)
Recall	100% (37/37)	70% (7/10)
F1-score	96,10%	82,35%

Akurasi keseluruhan sistem adalah 93,61% (44/47), dan balanced accuracy (rata-rata recall kedua kelas) adalah 85,00%. Sebagai pembanding, baseline naif yang selalu memprediksi kelas mayoritas ('Cocok') akan mencapai akurasi 78,72% (37/47) pada data uji yang sama; model Naive Bayes yang dibangun (93,61%) mengungguli baseline tersebut, namun selisihnya perlu dibaca bersama metrik kelas minoritas di atas, bukan hanya akurasi keseluruhan.

Dari 47 data uji, 44 diklasifikasikan tepat dan 3 tidak sesuai, ketiganya berupa false positive: peserta yang aktualnya Tidak Cocok tetapi diprediksi Cocok. Ketiga kesalahan ini setara dengan 30% dari seluruh peserta yang aktualnya Tidak Cocok (recall kelas Tidak Cocok hanya 70%). Konsekuensi praktis kesalahan jenis ini penting dibahas secara eksplisit: seorang peserta yang sebenarnya kurang sesuai berpotensi tetap direkomendasikan mengikuti bidang pelatihan yang salah, yang dapat berujung pada pemborosan sumber daya pelatihan (kuota, instruktur, waktu) serta hasil belajar yang kurang optimal bagi peserta tersebut. Recall sempurna (100%) pada kelas Cocok tidak boleh dibaca sebagai indikasi performa sistem yang 'sempurna' secara umum, karena performa pada kelas Tidak Cocok jauh lebih rendah (recall 70%, F1 82,35%). Nilai akurasi 93,61% ini juga diperoleh dari

satu kali pembagian data (hold-out) yang proporsi kelasnya dijaga, sehingga berpotensi bervariasi apabila diuji ulang dengan skema validasi silang k-fold, dan sebaiknya dibaca sebagai indikasi awal, bukan estimasi kinerja final

Diskusi

Hasil pengujian menunjukkan bahwa algoritma Naïve Bayes dapat diterapkan untuk menghasilkan rekomendasi kesesuaian bidang pelatihan yang konsisten secara komputasional, dalam arti menerapkan kriteria yang sama pada setiap data tanpa variasi antarpetugas. Klaim ini perlu dibedakan dari klaim objektivitas substantif, karena sebagaimana dibahas pada bagian Metode, label yang dipelajari model berasal dari keputusan historis petugas yang tidak divalidasi secara independen. Sistem ini karenanya lebih tepat dipahami sebagai alat yang mereplikasi dan menstandardisasi pola keputusan historis, bukan sebagai sumber kebenaran baru mengenai kesesuaian peserta. Tingginya akurasi keseluruhan (93,61%) juga tidak dengan sendirinya membuktikan bahwa seluruh sembilan atribut yang digunakan memiliki hubungan yang kuat terhadap label target; penelitian ini tidak melakukan analisis feature importance atau ablation analysis, sehingga interpretasi yang didukung oleh bukti penelitian ini adalah bahwa penggunaan kesembilan atribut tersebut konsisten dengan kriteria yang disebutkan petugas dalam wawancara, tanpa bukti kuantitatif independen mengenai kontribusi masing-masing atribut.

Pembagian data menggunakan skema stratified hold-out dipilih sebagai keputusan desain metodologis untuk menjaga proporsi kelas pada data latih dan data uji, mengingat distribusi kelas pada dataset ini tidak seimbang. Penelitian ini tidak membandingkan skema ini secara empiris dengan pembagian acak biasa (random split), sehingga stratifikasi dipahami sebagai pilihan desain yang beralasan secara teoritis untuk mengurangi risiko bias evaluasi akibat ketimpangan kelas, namun besarnya pengaruh aktualnya terhadap performa pada dataset ini belum diukur secara langsung.

Dibandingkan dengan penelitian yang menerapkan Naïve Bayes pada penentuan penerima bantuan pendidikan (Priyanto et al., 2024) atau prediksi peluang kerja penyandang disabilitas (Yuliadarnita et al., 2025), penelitian ini menempatkan penerapan algoritma yang sama pada konteks operasional berbeda, yaitu seleksi peserta pelatihan kerja pada BLK pemerintah daerah, dengan penekanan pada dokumentasi praktik implementasi (sistem yang benar-benar dibangun dan diuji fungsinya) dibandingkan kontribusi metodologis baru pada algoritmanya.

Dari sisi implementasi praktis, sistem yang dikembangkan berpotensi mengurangi waktu pemrosesan administratif petugas dalam merekapitulasi dan membandingkan data peserta secara manual, karena proses perhitungan yang sebelumnya dilakukan satu per satu kini dapat dijalankan sistem secara otomatis. Namun demikian, penelitian ini belum melakukan pengukuran dampak implementasi yang terukur, seperti perbandingan waktu proses sebelum dan sesudah penggunaan sistem, tingkat penerimaan petugas melalui pengujian usability (misalnya System Usability Scale), maupun uji coba penggunaan langsung (pilot) pada periode seleksi berikutnya. Oleh karena bukti empiris mengenai dampak implementasi belum tersedia, hasil penelitian ini dibatasi pada potensi dukungan sistem, bukan dampak institusional yang telah terbukti. Penelitian lanjutan perlu mencakup evaluasi implementasi riil agar manfaat institusional sistem dapat diuji dengan data empiris.

Penelitian ini memiliki sejumlah keterbatasan yang perlu diperhatikan pembaca: (1) label target berasal dari keputusan historis petugas yang belum tervalidasi secara independen, sehingga model berisiko mereplikasi bias atau inkonsistensi yang mungkin ada pada data tersebut; (2) dua atribut sensitif (jenis kelamin, status perkawinan) digunakan tanpa dasar teoritis substantif dan belum dievaluasi potensi biasnya secara kuantitatif; (3) ambang batas kategorisasi data numerik bersifat tetap (bukan hasil analisis statistik data latih) dan belum diuji sensitivitasnya; (4) evaluasi model menggunakan skema hold-out satu kali, bukan validasi silang k-fold, karena keterbatasan ketersediaan data mentah; (5) evaluasi final 47 data uji masih merefleksikan implementasi tanpa Laplace smoothing, sementara smoothing baru dapat didemonstrasikan pada bagian yang dapat diverifikasi dari data agregat; (6) belum dilakukan analisis feature importance maupun perbandingan dengan algoritma klasifikasi lain (Decision Tree, Random Forest, K-Nearest Neighbor, Support Vector Machine) pada dataset yang sama; dan (7) belum ada evaluasi dampak implementasi riil (waktu proses, penerimaan pengguna, hasil pilot). Penelitian lanjutan disarankan menindaklanjuti seluruh poin tersebut, khususnya butir (1) dan (2) yang berkaitan langsung dengan validitas dan keadilan sistem sebelum diadopsi lebih luas pada layanan publik.

Kesimpulan

Penelitian ini menghasilkan purwarupa sistem pendukung keputusan berbasis Naïve Bayes untuk membantu penentuan kesesuaian bidang pelatihan calon tenaga kerja pada BLK. Pada 47 data uji, sistem mengklasifikasikan 44 data dengan benar dengan akurasi 93,61% dan balanced accuracy 85,00%, serta seluruh 15 skenario black box berjalan sesuai harapan. Hasil ini menunjukkan bahwa sistem berpotensi membantu konsistensi dan dokumentasi proses seleksi, tetapi tetap digunakan sebagai rekomendasi pendukung karena label target berasal dari keputusan historis petugas dan belum divalidasi sebagai ground truth independen.

Keterbatasan penelitian meliputi penggunaan satu skema hold-out, belum tersedianya validasi silang, penggunaan ambang kategorisasi tetap, belum dievaluasinya fairness pada atribut sensitif, dan belum adanya uji implementasi operasional. Penelitian berikutnya perlu memvalidasi label, menguji model tanpa atribut sensitif, menerapkan k-fold cross-validation dan Laplace smoothing secara konsisten, serta mengevaluasi usability dan dampak penggunaan sistem dalam proses seleksi BLK.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Dinas Ketenagakerjaan Kota Tanjungbalai, khususnya Balai Latihan Kerja (BLK), atas dukungan dan akses data selama pelaksanaan penelitian.

Deklarasi

Penggunaan Kecerdasan Artifisial

AI generatif digunakan secara terbatas untuk membantu penyuntingan bahasa, konsistensi format, serta pemeriksaan sitasi dan referensi. AI tidak digunakan untuk menghasilkan data atau menjalankan analisis utama; seluruh isi akhir tetap ditinjau dan menjadi tanggung jawab penulis.

Kontribusi Penulis

Nazwatul Husna: konseptualisasi, metodologi, kurasi data, analisis formal, dan penulisan draf awal. Novica Irawati: pengembangan perangkat lunak dan supervisi. Sahren: validasi, supervisi, serta tinjauan dan penyuntingan. Seluruh penulis telah membaca dan menyetujui naskah akhir.

Pendanaan

Penelitian ini tidak menerima pendanaan eksternal.

Konflik Kepentingan

Para penulis menyatakan tidak terdapat konflik kepentingan yang dapat memengaruhi pelaksanaan, interpretasi, maupun publikasi hasil penelitian.

Persetujuan Etik

Penelitian menggunakan data administratif historis yang diperoleh melalui izin resmi Dinas Ketenagakerjaan Kota Tanjungbalai. Persetujuan etik formal tidak diwajibkan berdasarkan ketentuan institusi yang berlaku; identitas peserta tidak ditampilkan dan kerahasiaan data dijaga dalam penyajian hasil.

Pernyataan Ketersediaan Data

Data individu tidak tersedia secara terbuka karena keterbatasan arsip dan kebijakan kerahasiaan instansi. Data agregat disajikan dalam artikel, sedangkan kode sumber dan dokumentasi teknis dapat diminta kepada penulis korespondensi dengan tetap memperhatikan izin Dinas Ketenagakerjaan Kota Tanjungbalai.

Daftar Pustaka

Apsari, R. M. (2024). Penerapan Metode Naïve Bayes dalam Memprediksi Prestasi Siswa. Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence), 4(2), 38–46. https://doi.org/10.55382/jurnalpustakaai.v3i3.760

Chicco, D., & Jurman, G. (2020). The Advantages of the Matthews Correlation Coefficient (MCC) over F1 Score and Accuracy in Binary Classification Evaluation. BMC Genomics, 21, 6. https://doi.org/10.1186/s12864-019-6413-7

Daud, D. R. F., Irawan, B., & Bahtiar, A. (2024). Penerapan Metode Naive Bayes pada Analisis Sentimen Aplikasi McDonalds di Google Play Store. JATI (Jurnal Mahasiswa Teknik Informatika), 8(1), 759–766. https://doi.org/10.36040/jati.v8i1.8784

Domingos, P., & Pazzani, M. (1997). On the Optimality of the Simple Bayesian Classifier under Zero-One Loss. Machine Learning, 29(2–3), 103–130. https://doi.org/10.1023/A:1007413511361

Farhan, S., Rahmadani, N., & Mardalius. (2026). Random Forest Based System for Predicting and Recommending Inmate Rehabilitation Programs. JURTEKSI (Jurnal Teknologi dan Sistem Informasi), 12(2), 263–270. https://doi.org/10.33330/jurteksi.v12i2.4432

Hand, D. J., & Yu, K. (2001). Idiot's Bayes—Not So Stupid After All? International Statistical Review, 69(3), 385–398. https://doi.org/10.1111/j.1751-5823.2001.tb00465.x

Listiowarni, I. (2019). Implementasi Naïve Bayessian dengan Laplacian Smoothing untuk Peminatan dan Lintas Minat Siswa SMAN 5 Pamekasan. Jurnal Sisfokom (Sistem Informasi dan Komputer), 8(2), 124–129. https://doi.org/10.32736/sisfokom.v8i2.652

Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A Survey on Bias and Fairness in Machine Learning. ACM Computing Surveys, 54(6), Article 115, 1–35. https://doi.org/10.1145/3457607

Muchtar, M., Pasrun, Y. P., Rasyid, R., Miftachurohmah, N., & Mardiawati, M. (2024). Penerapan Metode Naïve Bayes dalam Klasifikasi Kesegaran Ikan Berdasarkan Warna pada Citra Area Mata. Jurnal Informatika dan Teknik Elektro Terapan, 12(1), 611–617. https://doi.org/10.23960/jitet.v12i1.3879

Priyanto, I., Dewanti, E. M., Tundo, T., Nurdin, M., & Kasiono, R. (2024). Penerapan Algoritma Metode Naïve Bayes untuk Penentuan Penerimaan Bantuan Program Indonesia Pintar (PIP). Jurnal Manajemen Informatika Jayakarta, 4(2), 162–172. https://doi.org/10.52362/jmijayakarta.v4i2.1355

Riskawati, R., Fatihanursari, F., Iin, I., & Rinaldi, A. R. (2024). Penerapan Metode Naïve Bayes Classifier pada Analisis Sentimen Aplikasi GoPay. JATI (Jurnal Mahasiswa Teknik Informatika), 8(1), 346–353. https://doi.org/10.36040/jati.v8i1.8699

Rizky, Y. A., Aziz, A., & Harianto, W. (2024). Implementasi Naive Bayes dengan Menggunakan Metode Laplace Smoothing. RAINSTEK: Jurnal Terapan Sains dan Teknologi, 6(3), 164–172. https://doi.org/10.21067/jtst.v6i3.9132

Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. PLOS ONE, 10(3), e0118432. https://doi.org/10.1371/journal.pone.0118432

Varma, S., & Simon, R. (2006). Bias in Error Estimation When Using Cross-Validation for Model Selection. BMC Bioinformatics, 7, 91. https://doi.org/10.1186/1471-2105-7-91

Wie, J. V., & Siddik, M. (2022). Penerapan Metode Naïve Bayes dalam Mengklasifikasi Tingkat Obesitas pada Pria. JOISIE (Journal of Information Systems and Informatics Engineering), 6(2), 69–77. https://doi.org/10.35145/joisie.v6i2.2467

Yuliadarnita, Y., Ikram, R., & Toyib, R. (2025). Penerapan Metode Naïve Bayes dalam Memprediksi Peluang Kerja untuk Penyandang Disabilitas. Jurnal Media Infotama, 21(1), 168–174. https://doi.org/10.37676/jmi.v21i1.7577