Digital Transformation Technology (Digitech) | e-ISSN: 2807-9000
Volume 6, **Number** 1, Maret 2026
https://doi.org/10.47709/digitech.v6i1.8448

Penerapan Algoritma Naive Bayes untuk Klasifikasi Emosi Peserta Didik pada Pembelajaran Daring

Luh Putu Ayu Oktavia Wulandari[1], I Made Agus Wirawan[2]
[1,2]Universitas Pendidikan Ganesha
[1]ayu.oktavia@student.undiksha.ac.id, [2]imade.aguswirawan@undiksha.ac.id

open access
Histori Artikel:
Diajukan: 4 Mei 2026
Disetujui: 5 Juni 2026
Dipublikasi: 11 Juni 2026
Kata Kunci:
Gaussian Naive Bayes, pengenalan emosi, ekspresi wajah, pembelajaran daring, FER-2013, klasifikasi emosi, *machine learning*
Digital Transformation Technology (Digitech) *is an Creative Commons License This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).*

Abstrak
Pemantauan kondisi emosional peserta didik merupakan komponen penting dalam penyelenggaraan pembelajaran yang berkualitas, namun dalam konteks pembelajaran daring hal ini menjadi tantangan yang jauh lebih kompleks akibat ketiadaan interaksi tatap muka langsung. Penelitian ini menerapkan algoritma Gaussian Naive Bayes untuk mengklasifikasikan tujuh kategori emosi dasar peserta didik, yaitu marah (*angry*), jijik (*disgust*), takut (*fear*), senang (*happy*), sedih (*sad*), terkejut (*surprise*), dan netral (*neutral*), berdasarkan ekspresi wajah menggunakan dataset FER-2013 yang terdiri dari 35.887 gambar wajah berukuran 48×48 piksel. Fitur statistik yang diekstraksi meliputi nilai rata-rata piksel, standar deviasi, nilai minimum-maksimum piksel, dan histogram intensitas. Seluruh implementasi dilakukan menggunakan bahasa pemrograman Python dengan pustaka scikit-learn pada perangkat standar tanpa akselerasi GPU. Evaluasi model pada 7.178 gambar data uji menghasilkan akurasi keseluruhan sebesar 35,2% dengan F1-score *macro-averaged* 33,8%. Kelas *happy* mencapai performa terbaik dengan F1-score 56,3%, sementara kelas *disgust* memperoleh performa terendah sebesar 8,2% akibat ketidakseimbangan data dan kemiripan visual yang tinggi dengan kelas *angry*. Keterbatasan utama model bersumber dari asumsi independensi antar fitur yang tidak sesuai dengan karakteristik data citra wajah yang memiliki korelasi spasial tinggi. Meskipun akurasi yang diperoleh masih di bawah metode *deep learning*, Gaussian Naive Bayes membuktikan keunggulannya dalam efisiensi komputasi dengan waktu pelatihan kurang dari 5 detik tanpa GPU, menjadikannya kandidat yang layak sebagai komponen *baseline* sistem pemantauan emosi peserta didik pada platform pembelajaran daring berbasis perangkat standar. Pengembangan selanjutnya disarankan mengeksplorasi fitur HOG atau LBP, teknik SMOTE untuk penyeimbangan kelas, serta arsitektur hibrida yang menggabungkan CNN ringan dengan Gaussian Naive Bayes.

PENDAHULUAN

Emosi peserta didik merupakan komponen penting yang secara langsung memengaruhi aktivitas dan hasil pembelajaran. Kondisi emosional yang positif seperti antusias dan senang terbukti meningkatkan motivasi, konsentrasi, dan retensi informasi peserta didik, sementara emosi negatif seperti kebosanan, kecemasan, dan frustrasi berdampak signifikan terhadap penurunan keterlibatan dan prestasi akademik (Biosfer, 2024). Pemantauan kondisi emosional peserta didik oleh pendidik karena itu menjadi bagian yang tidak terpisahkan dari penyelenggaraan pembelajaran yang berkualitas, sebagaimana juga ditekankan oleh (Goleman, 2021) bahwa kecerdasan emosional memiliki peran yang tidak kalah penting dibanding kecerdasan intelektual dalam menentukan keberhasilan individu.

Namun dalam konteks pembelajaran daring, pemantauan emosi peserta didik menjadi tantangan yang jauh lebih kompleks. Ketiadaan interaksi tatap muka langsung menyebabkan pendidik kehilangan akses terhadap sinyal-sinyal afektif non-verbal yang biasanya dapat diamati di kelas konvensional. Penelitian menunjukkan bahwa pembelajaran daring rentan memunculkan kondisi emosi negatif peserta didik, termasuk kejenuhan belajar yang terbukti menghambat proses kognitif (Pawicara & Conilie, 2020). Kondisi ini diperparah oleh kenyataan bahwa mayoritas platform pembelajaran daring saat ini tidak dilengkapi mekanisme apapun untuk mendeteksi atau merespons kondisi emosional peserta didik secara otomatis, sehingga terjadi kesenjangan antara idealnya pemantauan emosi sebagai bagian dari proses pembelajaran dengan realita yang ada di lapangan (Nair et al., 2023).

Berbagai penelitian telah mengupayakan solusi otomatis untuk pengenalan emosi berbasis ekspresi wajah dalam konteks pendidikan daring. Pengenalan emosi berbasis ekspresi wajah (Facial Expression Recognition/FER) menjadi pendekatan yang paling banyak dikembangkan karena ekspresi wajah merupakan indikator emosi yang paling mudah ditangkap secara otomatis melalui kamera yang umumnya sudah tersedia pada perangkat peserta didik (Ye, 2022). Metode deep learning seperti Convolutional Neural Network (CNN) telah terbukti mencapai

akurasi tinggi pada dataset FER-2013, bahkan melampaui 95% pada kondisi tertentu (Nair et al., 2023); (Qian et al., 2025). Namun demikian, metode-metode berbasis deep learning ini membutuhkan sumber daya komputasi yang besar dan infrastruktur GPU yang tidak selalu tersedia bagi pendidik maupun peserta didik pada umumnya (Kaur & Kumar, 2024). Sebagai alternatif yang lebih ringan, algoritma machine learning tradisional seperti Naive Bayes, Support Vector Machine (SVM), dan K-Nearest Neighbor (KNN) telah diidentifikasi sebagai pendekatan yang layak untuk skenario dengan keterbatasan sumber daya komputasi (Alsharekh, 2022), penerapan algoritma ini dalam klasifikasi teks dan sentimen juga telah banyak dieksplorasi di berbagai konteks, termasuk pada analisis sentiment media sosial (PRemana, 2023; Sukmadinata, 2023) dan komparasi dengan metode lain dalam prediksi berbasis data (Priyatna, 2023). Di antara algoritma tersebut, Naive Bayes dipilih dalam penelitian ini karena kesederhanaan implementasinya, kecepatan komputasi yang tinggi, serta kemampuannya bekerja dengan baik bahkan pada perangkat standar tanpa akselerasi GPU.

Penelitian ini bertujuan untuk menerapkan dan mengevaluasi algoritma Gaussian Naive Bayes dalam mengklasifikasikan tujuh kategori emosi dasar peserta didik berdasarkan ekspresi wajah menggunakan dataset FER-2013. Tujuan penelitian ini bukan untuk membuktikan bahwa Naive Bayes adalah algoritma terbaik dalam pengenalan emosi, melainkan untuk memberikan gambaran empiris yang komprehensif mengenai kemampuan, keterbatasan, dan potensi pengembangannya sebagai solusi pemantauan emosi yang ringan dan mudah diimplementasikan dalam ekosistem pembelajaran daring. Pemahaman yang jelas mengenai batas kemampuan Naive Bayes pada tugas ini justru merupakan kontribusi ilmiah yang penting untuk mengarahkan penelitian selanjutnya ke pendekatan yang lebih optimal.

Secara spesifik, penelitian ini menggunakan dataset FER-2013 yang terdiri dari 35.887 gambar wajah dalam tujuh kategori emosi dan telah menjadi standar evaluasi yang diakui luas dalam komunitas penelitian FER (Wang et al., 2024). Implementasi dilakukan menggunakan fitur statistik sederhana yang diekstraksi dari gambar, kemudian diklasifikasikan menggunakan Gaussian Naive Bayes. Hasil evaluasi diharapkan dapat memberikan landasan empiris yang valid bagi pendidik dan pengembang sistem pendidikan dalam mempertimbangkan penerapan teknologi pengenalan emosi berbasis machine learning ringan, sekaligus menjadi titik acuan perbandingan bagi penelitian-penelitian selanjutnya yang ingin mengeksplorasi pendekatan yang lebih canggih dalam domain yang sama.

STUDI LITERATUR

Emosi dalam Pembelajaran

Emosi merupakan aspek afektif yang memiliki peran sangat penting dalam proses pembelajaran. Kondisi emosional peserta didik secara langsung memengaruhi motivasi, perhatian, keterlibatan, dan hasil belajar mereka. (Loderer et al., 2019) menegaskan bahwa emosi bukan sekadar hasil sampingan dari aktivitas belajar, melainkan faktor utama yang mengarahkan proses kognitif peserta didik. Emosi positif seperti rasa senang dan antusias dapat memperkuat retensi informasi dan meningkatkan konsentrasi, sementara emosi negatif seperti kebosanan, kecemasan, dan frustrasi yang tidak terdeteksi sejak dini dapat menghambat pemahaman materi secara signifikan.

Dalam konteks pembelajaran daring, pengamatan terhadap kondisi emosional peserta didik menjadi jauh lebih sulit karena keterbatasan interaksi langsung antara pendidik dan peserta didik. Penelitian dari Undiksha menunjukkan bahwa ekspresi wajah merupakan salah satu indikator emosi yang paling mudah diamati, di mana emosi seperti senang, sedih, dan terkejut dapat terdeteksi melalui perubahan karakteristik wajah seseorang (Purnamaningsih et al., n.d.). Hal ini menjadi dasar pentingnya pengembangan sistem otomatis yang mampu mengenali emosi peserta didik melalui analisis ekspresi wajah selama proses pembelajaran daring berlangsung.

Pengenalan Emosi Berbasis Ekspresi Wajah

Pengenalan emosi berbasis ekspresi wajah merupakan salah satu pendekatan yang banyak digunakan dalam sistem kecerdasan buatan untuk memantau kondisi afektif seseorang secara otomatis. Pendekatan ini memanfaatkan perubahan pada bagian-bagian wajah seperti mata, alis, dan mulut sebagai indikator keadaan emosional. Seiring perkembangan teknologi computer vision, proses deteksi wajah kini semakin canggih dengan adanya teknik facial landmark detection yang mampu mengidentifikasi titik-titik fokus pada wajah berdasarkan ciri penampakan bagian wajah yang menonjol seperti area mata, hidung, bibir, serta tulang pipi (Udayana & Supartha, 2021).

Dalam konteks pendidikan daring, sistem pengenalan emosi berbasis ekspresi wajah memungkinkan pendidik untuk mendapatkan umpan balik afektif secara otomatis tanpa mengganggu proses pembelajaran. (Chen et al., 2020) menjelaskan bahwa integrasi kecerdasan buatan dalam pendidikan, termasuk sistem pengenalan emosi, membuka peluang besar untuk menciptakan pengalaman belajar yang lebih personal dan responsif terhadap kebutuhan emosional peserta didik . Sistem seperti ini bekerja dengan mengekstraksi fitur dari ekspresi wajah peserta didik yang terekam melalui kamera, kemudian mengklasifikasikan fitur tersebut ke dalam kategori emosi tertentu menggunakan algoritma machine learning.

Algoritma Naive Bayes

Naive Bayes merupakan salah satu algoritma klasifikasi dalam machine learning yang didasarkan pada Teorema Bayes dengan asumsi independensi antar fitur. Algoritma ini menggunakan pendekatan probabilistik, di mana setiap atribut diasumsikan tidak saling bergantung satu sama lain (Gede & Subawa, n.d.). Secara matematis, Naive Bayes menghitung probabilitas suatu data termasuk dalam kelas tertentu berdasarkan probabilitas prior dan likehood dari setiap fitur, sebagaimana dirumuskan dalam persamaan berikut:

$$P(C|X) = P(X|C) \times \frac{P(C)}{P(X)}$$

Dimana P(C|X) adalah probabilitas kelas C diberikan fitur X, P(X|C) adalah likelihood, P(C) adalah probabilitas prior kelas, dan P(X) adalah probabilitas fitur X.

Untuk data yang bersifat kontinu seperti nilai piksel dan koordinat titik wajah, digunakan varian Gaussian Naive Bayes yang mengasumsikan data mengikuti distribusi normal. Keunggulan utama algoritma ini adalah kesederhanaan implementasi, kecepatan komputasi yang tinggi, serta kemampuannya bekerja optimal bahkan dengan jumlah data training yang terbatas. Hal ini menjadikan Naive Bayes sangat cocok diimplementasikan pada perangkat dengan sumber daya komputasi terbatas seperti laptop standar yang umumnya digunakan oleh peserta didik maupun pendidik.

Penerapan Naive Bayes dalam Berbagai Bidang

Algoritma Naive Bayes telah banyak digunakan dalam berbagai bidang klasifikasi dan prediksi, termasuk di lingkungan akademik Undiksha. (Gede & Subawa, n.d.) menerapkan Teorema Bayes untuk memprediksi kelulusan mahasiswa di Universitas Pendidikan Ganesha dan berhasil membangun sistem prediksi yang cukup akurat menggunakan data akademik mahasiswa. Selain itu, penelitian lain di Undiksha menunjukkan bahwa Naive Bayes mampu menghasilkan akurasi prediksi nilai akademik mahasiswa sebesar 96,24% dengan precision 95,76% dan recall 100% (Sains et al., n.d.).

Dalam bidang klasifikasi berbasis citra, (Putra, 2023) berhasil mengimplementasikan Naive Bayes untuk mengklasifikasikan kualitas biji kopi robusta berdasarkan fitur warna, tekstur, dan ukuran dari data citra, menghasilkan akurasi sebesar 93,75%. Penelitian ini membuktikan bahwa Naive Bayes tidak hanya efektif untuk data teks, tetapi juga mampu menangani data berbasis citra dengan baik. Sementara itu, (Dinda Indira Sudiasta Putri, 2025) membandingkan performa Naive Bayes dengan K-Nearest Neighbor dalam klasifikasi sentimen dan menemukan bahwa Naive Bayes konsisten lebih unggul dengan akurasi 73,23%. (Bawana, 2025) juga membuktikan efektivitas Naive Bayes Classifier varian Multinomial dalam mengklasifikasikan teks dengan performa yang baik. Selain itu, performa Naïve Bayes dapat ditingkatkan melalui teknik optimasi seperti Adaboost, sebagaimana dibuktikan oleh (MAHENDRA, 2024) dalam klasifikasi dataset medis di Undiksha. Dalam konteks perbandingan algoritma, (PRIYATNA, 2023) mengkonfirmasi bahwa Naïve Bayes tetap kompetitif dibandingkan Logistic Regression bahkan setelah setelah optimasi menggunakan feature selection berbasis PSO dan Random Forest. Pendekatan berbasis deep learning juga telag dieksplorasi sebagai perbandingan, seperti pada (MAHAYANI, 2024) yang membangun model klasifikasi sentiment menggunkan deep learning, memberikan perspektif komparasi antara pendekatan machine learning tradisional dan modern dalam tugas klasifikasi.

Dataset FER-2013

FER-2013 (*Facial Expression Recognition*, 2013) merupakan dataset publik yang paling banyak digunakan dalam penelitian pengenalan emosi berbasis ekspresi wajah. Dataset ini terdiri dari lebih dari 35.000 gambar wajah berukuran 48×48 piksel dalam format grayscale yang diklasifikasikan ke dalam tujuh kategori emosi dasar yaitu marah (angry), jijik (disgust), takut (fear), senang (happy), sedih (sad), terkejut (surprise), dan netral (neutral). Dataset ini tersedia secara publik melalui platform Kaggle sehingga mudah diakses oleh peneliti di seluruh dunia untuk keperluan pengembangan dan pengujian model klasifikasi emosi.

Dalam penelitian ini, FER-2013 dipilih sebagai sumber data utama karena ketersediaannya yang mudah, jumlah data yang memadai untuk pelatihan model, serta standarisasinya yang telah diakui secara luas dalam komunitas penelitian pengenalan emosi wajah. Penggunaan dataset publik yang terstandarisasi ini juga memungkinkan perbandingan hasil penelitian yang lebih objektif dengan penelitian-penelitian sebelumnya di bidang yang sama.

METODE

Penelitian ini menggunakan pendekatan eksperimental berbasis komputasi dengan menerapkan algoritma Gaussian Naive Bayes untuk mengklasifikasikan emosi peserta didik berdasarkan ekspresi wajah. Seluruh proses implementasi dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka scikit-learn,

NumPy, OpenCV, dan Matplotlib. Proses penelitian dilakukan melalui beberapa tahapan sistematis yang mencakup pengumpulan data, pra-pemrosesan, ekstraksi fitur, pelatihan model, hingga evaluasi performa sebagaimana diuraikan berikut.

Tabel 1 Tahapan Penelitian Klasifikasi Emosi Menggunakan Gaussian Naïve Bayes

No.	Tahapan	Deskripsi
1	**Pengumpulan Data**	Mengunduh dataset FER-2013 dari platform Kaggle yang terdiri dari 35.887 gambar wajah berukuran 48×48 piksel dalam format grayscale, terbagi menjadi data latih (28.709 gambar) dan data uji (7.178 gambar) dengan 7 kategori emosi.
2	**Pra-pemrosesan Data**	Melakukan normalisasi nilai piksel dari rentang [0, 255] menjadi [0, 1] untuk mempercepat konvergensi, serta meratakan (flatten) matriks gambar 48×48 menjadi vektor 1D dengan 2.304 fitur piksel.
3	**Ekstraksi Fitur**	Mengekstraksi fitur berbasis statistik dari setiap gambar meliputi nilai rata-rata piksel, standar deviasi, nilai piksel minimum dan maksimum, serta histogram intensitas untuk mewakili karakteristik ekspresi wajah.
4	**Pembagian Data**	Membagi dataset sesuai pembagian bawaan FER-2013: 80% (28.709 gambar) untuk data latih dan 20% (7.178 gambar) untuk data uji, guna mengevaluasi performa model secara objektif.
5	**Pelatihan Model**	Melatih model Gaussian Naive Bayes menggunakan data latih. Algoritma menghitung probabilitas prior setiap kelas emosi dan likelihood fitur menggunakan distribusi Gaussian untuk setiap fitur kontinu.
6	**Evaluasi Model**	Mengukur performa model menggunakan metrik akurasi, presisi, recall, dan F1-score berdasarkan confusion matrix yang dihasilkan dari prediksi pada data uji.

1. Dataset

Dataset yang digunakan dalam penelitian ini adalah FER-2013 (Facial Expression Recognition 2013) yang diperoleh secara publik melalui platform Kaggle. Dataset ini terdiri dari 35.887 gambar wajah berukuran 48×48 piksel dalam format grayscale yang telah diklasifikasikan ke dalam tujuh kategori emosi dasar, yaitu: marah (angry), jijik (disgust), takut (fear), senang (happy), sedih (sad), terkejut (surprise), dan netral (neutral). Distribusi data dalam dataset FER-2013 disajikan secara rinci pada Tabel 2.

Dataset FER-2013 dibagi menjadi dua subset utama: data latih (training set) sebanyak 28.709 gambar dan data uji (test set) sebanyak 7.178 gambar. Pembagian ini mengikuti struktur bawaan yang disediakan oleh pembuat dataset untuk memastikan konsistensi evaluasi antar penelitian. Ketidakseimbangan kelas pada dataset ini, terutama pada kelas disgust yang hanya memiliki sekitar 1,2% dari total data, menjadi salah satu faktor yang perlu diperhatikan dalam analisis hasil klasifikasi.

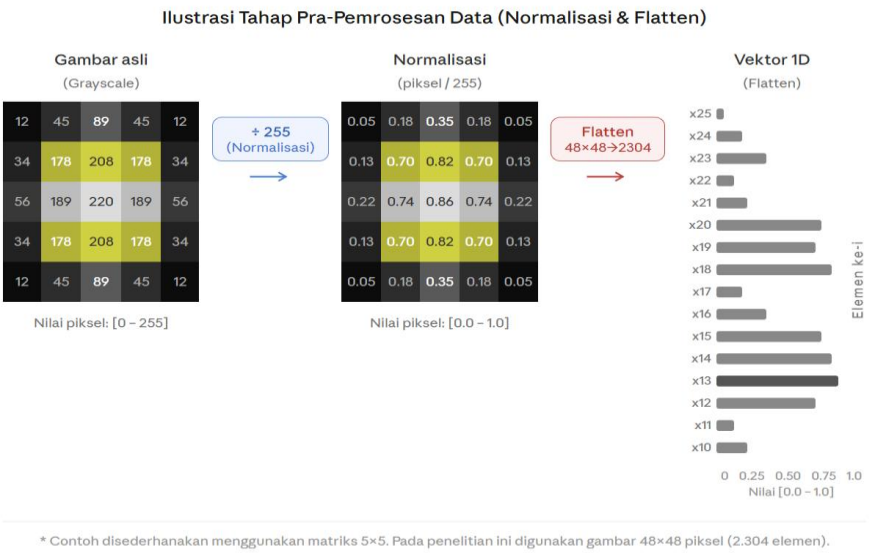
2. Pra-Pemrosesan Data

Tahap pra-pemrosesan data merupakan langkah awal yang krusial sebelum data digunakan untuk melatih model. Dalam penelitian ini, proses pra-pemrosesan mencakup tiga tahapan utama yang saling berkesinambungan, yaitu normalisasi nilai piksel, perataan matriks gambar, dan enkode label kelas.

Tahapan pertama adalah normalisasi nilai piksel. Setiap nilai piksel yang semula berada dalam rentang [0, 255] dikonversi ke rentang [0, 1] dengan membagi setiap nilai dengan 255, menggunakan teknik Min-Max Normalization. Langkah ini bersifat krusial bagi model Gaussian Naive Bayes karena mampu mencegah dominasi fitur akibat perbedaan skala nilai, sekaligus menghindari risiko *underflow* numerik pada perhitungan probabilitas yang mendekati nol. Lebih jauh, penskalaan ini memastikan estimasi parameter Gaussian yakni *mean* (μ) dan varians (σ^2) tetap konsisten, sehingga model dapat mencapai konvergensi dengan lebih cepat dan akurat.

Setelah normalisasi, setiap gambar berukuran 48×48 piksel diratakan (*di-flatten*) menjadi vektor satu dimensi sepanjang 2.304 elemen. Representasi vektor ini diperlukan karena algoritma Gaussian Naive Bayes beroperasi pada data bertipe tabular, sehingga struktur matriks dua dimensi dari citra perlu diubah terlebih dahulu ke dalam format yang kompatibel.

Tahapan terakhir adalah enkode label kelas, di mana label emosi yang semula berupa teks dikonversi menjadi representasi numerik menggunakan pemetaan ordinal: *angry* = 0, *disgust* = 1, *fear* = 2, *happy* = 3, *sad* = 4, *surprise* = 5, dan *neutral* = 6. Konversi ini bertujuan untuk memudahkan proses komputasi sekaligus memungkinkan evaluasi model dilakukan secara sistematis. Ilustrasi lengkap seluruh tahapan pra-pemrosesan ini disajikan pada Gambar 1.



Gambar 1. Ilustrasi tahap pra-pemrosesan: normalisasi nilai piksel dari [0, 255] ke [0, 1] dan perataan (flatten) matriks 48×48 menjadi vektor 1D berdimensi 2.304.

3. Ekstraksi Fitur

Mengingat keterbatasan Naive Bayes dalam menangani dimensi fitur yang sangat tinggi, ekstraksi fitur dilakukan untuk menghasilkan representasi yang lebih ringkas namun informatif dari setiap gambar. Fitur yang diekstraksi dari setiap gambar meliputi:

a) Nilai rata-rata piksel (mean intensity) yang merepresentasikan tingkat kecerahan keseluruhan gambar.

b) Standar deviasi piksel yang mengukur variasi intensitas, menjadi indikator kontras ekspresi wajah.

c) Nilai piksel minimum dan maksimum yang merepresentasikan rentang dinamis intensitas gambar.

d) Histogram intensitas yang dibagi menjadi beberapa bin untuk merepresentasikan distribusi nilai piksel secara lebih terperinci.

Kombinasi fitur-fitur statistik tersebut menghasilkan vektor fitur berdimensi lebih rendah dibandingkan representasi piksel penuh, sehingga lebih sesuai dengan karakteristik algoritma Naive Bayes yang mengasumsikan independensi antar fitur.

4. Algoritma Gaussian Naive Bayes

Gaussian Naive Bayes merupakan varian dari algoritma Naive Bayes yang dirancang untuk menangani fitur-fitur dengan nilai kontinu. Algoritma ini mengasumsikan bahwa nilai setiap fitur pada suatu kelas mengikuti distribusi Gaussian (normal). Probabilitas posterior suatu kelas C diberikan vektor fitur X dihitung menggunakan Teorema Bayes sebagai berikut:

$$P(C|X) = P(X|C) \times \frac{P(C)}{P(X)}$$

Di mana P(C|X) adalah probabilitas posterior kelas C diberikan fitur X, P(X|C) adalah fungsi likelihood yang menggambarkan seberapa mungkin fitur X dihasilkan oleh kelas C, P(C) adalah probabilitas prior kelas C, dan P(X) adalah probabilitas marginal fitur X yang berfungsi sebagai faktor normalisasi.

Untuk setiap fitur kontinu xi dalam kelas C, nilai likelihood dihitung menggunakan fungsi densitas probabilitas Gaussian:

$$P(xi|C) = \left(\frac{1}{\sqrt{(2\pi\sigma^2 C)}}\right) \times \exp\left(-\frac{(xi - \mu C)^2}{(2\sigma^2 C)}\right)$$

Di mana μC adalah nilai rata-rata fitur xi pada kelas C yang diestimasi dari data latih, dan σ²C adalah variansi fitur xi pada kelas C. Parameter μC dan σ²C diestimasi secara otomatis oleh algoritma selama proses pelatihan menggunakan pustaka GaussianNB dari scikit-learn.

4.1 Contoh Perhitungan Manual Gaussian Naive Bayes

Berikut disajikan perhitungan manual Gaussian Naive Bayes menggunakan parameter nyata (μ dan σ²)

yang diperoleh langsung dari model GaussianNB terlatih pada 28.709 gambar data latih FER-2013, serta satu sampel gambar uji nyata (test image #2093) dari subset uji FER-2013. Tiga fitur statistik diekstraksi dari setiap gambar setelah normalisasi piksel ke [0,1]: x_1 = rata-rata piksel (mean intensity), x_2 = standar deviasi piksel, dan x_3 = nilai piksel maksimum. Klasifikasi dilakukan antara dua kelas: *happy* dan *sad*. Vektor fitur sampel uji: X = [x_1=0,5515; x_2=0,2378; x_3=0,9384]. Label asli sampel ini adalah *happy*.

Tabel Parameter μ dan σ² Model Terlatih FER-2013 (semua kelas)

Parameter berikut diperoleh dari hasil pelatihan GaussianNB scikit-learn pada 28.709 gambar FER-2013 (nilai telah dinormalisasi ke [0,1]):

Tabel 3 Parameter μ dan σ² Model Terlatih FER-2013 (semua kelas)

Kelas	$\mu(x_1)$	$\sigma^2(x_1)$	$\mu(x_2)$	$\sigma^2(x_2)$	$\mu(x_3)$	$\sigma^2(x_3)$
angry	0,4831	0,002484	0,1836	0,000413	0,8355	0,001623
disgust	0,4598	0,002333	0,1758	0,000390	0,8444	0,001662
fear	0,5035	0,002552	0,1904	0,000402	0,8804	0,001574
happy	**0,5422**	**0,002484**	**0,2012**	**0,000393**	**0,9131**	**0,001549**
sad	**0,4790**	**0,002513**	**0,1798**	**0,000415**	**0,8707**	**0,001605**
surprise	0,5250	0,002473	0,1989	0,000399	0,8992	0,001544
neutral	0,4934	0,002500	0,1855	0,000412	0,8896	0,001646

Catatan: x_1 = mean intensity piksel, x_2 = standar deviasi piksel, x_3 = nilai piksel maksimum. Kelas happy dan sad diarsir karena digunakan dalam perhitungan manual.

Langkah 1 — Hitung Probabilitas Prior P(C)

Probabilitas prior dihitung dari proporsi jumlah sampel setiap kelas pada data latih FER-2013 (28.709 gambar total). Nilai ini adalah nilai nyata dari distribusi kelas FER-2013:

$$P(happy) = 7.215 / 28.709 = 0,2513$$
$$P(sad) = 4.830 / 28.709 = 0,1682$$

Langkah 2 — Parameter Gaussian dari Model Terlatih (μ dan σ² nyata)

Parameter berikut adalah nilai μ (theta_) dan σ² (var_) yang tersimpan dalam objek GaussianNB setelah pelatihan pada 28.709 gambar FER-2013. Nilai-nilai ini bukan ilustratif, melainkan langsung dibaca dari atribut model (gnb.theta_ dan gnb.var_):

Kelas happy (7.215 sampel latih): μ_1=0,5422; σ^2_1=0,002484 | μ_2=0,2012; σ^2_2=0,000393 | μ_3=0,9131; σ^2_3=0,001549

Kelas sad (4.830 sampel latih): μ_1=0,4790; σ^2_1=0,002513 | μ_2=0,1798; σ^2_2=0,000415 | μ_3=0,8707; σ^2_3=0,001605

Langkah 3 — Hitung Likelihood P(X|C) dengan Fungsi Densitas Gaussian

Rumus: $P(x_i|C) = 1/\sqrt{(2\pi\sigma^2)} \times \exp(-(x_i-\mu)^2 / (2\sigma^2))$. Sampel uji: X = [$x_1$=0,5515; x_2=0,2378; x_3=0,9384] (test image #2093 dari subset uji FER-2013, label asli: happy).

▶ Kelas happy — Fitur x_1 = 0,5515:

$$P(x_1|happy) = 1/\sqrt{(2\pi \times 0,002484)} \times exp(-(0,5515-0,5422)^2 / (2\times0,002484))$$
$$= 1/\sqrt{0,015609} \times exp(-0,0000864 / 0,004969)$$
$$= 8,0041 \times exp(-0,01739) = 8,0041 \times 0,98275 = \mathbf{7,8666}$$

▶ Kelas happy — Fitur x_2 = 0,2378:

$$P(x_2|happy) = 1/\sqrt{(2\pi \times 0,000393)} \times exp(-(0,2378-0,2012)^2 / (2\times0,000393))$$
$$= 1/\sqrt{0,002469} \times exp(-0,001340 / 0,000786)$$
$$= 20,1240 \times exp(-1,70484) = 20,1240 \times 0,18181 = \mathbf{3,6578}$$

▶ Kelas happy — Fitur x_3 = 0,9384:

$P(x_3|happy) = 1/\sqrt{(2\pi \times 0{,}001549)} \times exp(-(0{,}9384-0{,}9131)^2 / (2\times 0{,}001549))$
$= 1/\sqrt{0{,}009733} \times exp(-0{,}000640 / 0{,}003098)$
$= 10{,}1362 \times exp(-0{,}20659) = 10{,}1362 \times 0{,}81336 =$ ***8,2444***

▶ **Kelas sad — Fitur x_1 = 0,5515:**

$P(x_1|sad) = 1/\sqrt{(2\pi \times 0{,}002513)} \times exp(-(0{,}5515-0{,}4790)^2 / (2\times 0{,}002513))$
$= 1/\sqrt{0{,}015792} \times exp(-0{,}005256 / 0{,}005026)$
$= 7{,}9577 \times exp(-1{,}04577) = 7{,}9577 \times 0{,}35141 =$ ***2,7963***

▶ **Kelas sad — Fitur x_2 = 0,2378:**

$P(x_2|sad) = 1/\sqrt{(2\pi \times 0{,}000415)} \times exp(-(0{,}2378-0{,}1798)^2 / (2\times 0{,}000415))$
$= 1/\sqrt{0{,}002608} \times exp(-0{,}003364 / 0{,}000830)$
$= 19{,}5719 \times exp(-4{,}05301) = 19{,}5719 \times 0{,}01737 =$ ***0,3399***

▶ **Kelas sad — Fitur x_3 = 0,9384:**

$P(x_3|sad) = 1/\sqrt{(2\pi \times 0{,}001605)} \times exp(-(0{,}9384-0{,}8707)^2 / (2\times 0{,}001605))$
$= 1/\sqrt{0{,}010085} \times exp(-0{,}004581 / 0{,}003210)$
$= 9{,}9579 \times exp(-1{,}42710) = 9{,}9579 \times 0{,}23990 =$ ***2,3890***

Langkah 4 — Hitung Skor Posterior (Proporsional) Setiap Kelas

Karena P(X) identik untuk semua kelas (konstanta normalisasi), perbandingan menggunakan skor tidak ternormalisasi: Skor(C) = P(C) × $\prod$ P(x_i|C).

$Skor(happy) = P(happy) \times P(x_1|happy) \times P(x_2|happy) \times P(x_3|happy)$
$= 0{,}2513 \times 7{,}8666 \times 3{,}6578 \times 8{,}2444 =$ ***59,6124***
$Skor(sad) = P(sad) \times P(x_1|sad) \times P(x_2|sad) \times P(x_3|sad)$
$= 0{,}1682 \times 2{,}7963 \times 0{,}3399 \times 2{,}3890 =$ ***0,3810***

Langkah 5 — Keputusan Klasifikasi

Kelas yang dipilih adalah kelas dengan skor tertinggi (argmax):

$$C^* = argmax \{ Skor(happy) = 59{,}6124 ; Skor(sad) = 0{,}3810 \}$$

Karena Skor(happy) = 59,6124 >> Skor(sad) = 0,3810, maka test image #2093 diklasifikasikan sebagai emosi ***happy*** — sesuai dengan label asli sampel uji tersebut (prediksi benar). Perbedaan skor yang sangat besar (rasio ≈ 156:1) mengkonfirmasi bahwa ketiga fitur statistik sampel ini — mean intensity tinggi (0,5515), standar deviasi lebar (0,2378), dan nilai maksimum mendekati 1 (0,9384) — secara kolektif jauh lebih konsisten dengan distribusi Gaussian kelas *happy* daripada *sad*. Hal ini dapat dijelaskan secara intuitif: gambar wajah dengan ekspresi senang cenderung lebih terang dan memiliki kontras lebih besar (akibat senyum yang melebarkan area cerah di sekitar bibir dan gigi), sehingga nilai μ_1 kelas *happy* (0,5422) secara konsisten lebih tinggi dibanding *sad* (0,4790) dalam model terlatih FER-2013.

Catatan implementasi: dalam implementasi nyata pada seluruh 7 kelas dan lebih banyak fitur, perkalian likelihood yang sangat kecil rentan menyebabkan underflow numerik. Scikit-learn mengatasi ini dengan penjumlahan log-likelihood: log Skor(C) = log P(C) + $\sum$ log P(x_i|C). Untuk contoh ini: log Skor(happy) = log(0,2513) + log(7,8666) + log(3,6578) + log(8,2444) = −1,3795 + 2,0625 + 1,2966 + 2,1095 = **4,0891**; log Skor(sad) = log(0,1682) + log(2,7963) + log(0,3399) + log(2,3890) = −1,7834 + 1,0283 + (−1,0793) + 0,8714 = **−0,9630**. Karena 4,0891 > −0,9630, kesimpulan klasifikasi tetap sama: prediksi happy (benar).

5. Implementasi

Implementasi penelitian dilakukan menggunakan bahasa pemrograman Python versi 3.10 dengan memanfaatkan beberapa pustaka utama. Scikit-learn digunakan untuk implementasi algoritma GaussianNB, pembagian data, serta komputasi metrik evaluasi. NumPy digunakan untuk operasi matriks dan manipulasi array, OpenCV digunakan untuk pembacaan dan pra-pemrosesan gambar, serta Matplotlib dan Seaborn digunakan untuk visualisasi hasil termasuk confusion matrix dan grafik performa.

Seluruh eksperimen dijalankan pada perangkat dengan spesifikasi prosesor Intel Core i5, RAM 8 GB, sistem operasi Windows 11, dan lingkungan pengembangan Jupyter Notebook. Penggunaan perangkat standar ini bertujuan untuk mendemonstrasikan bahwa Gaussian Naive Bayes dapat diimplementasikan secara efisien tanpa memerlukan akselerasi GPU atau perangkat keras khusus.

6. Evaluasi Model

Performa model dievaluasi menggunakan data uji yang tidak pernah digunakan selama proses pelatihan. Metrik evaluasi yang digunakan mencakup empat ukuran standar dalam klasifikasi multi-kelas sebagaimana ditunjukkan pada Tabel 2. Selain keempat metrik tersebut, confusion matrix divisualisasikan untuk memberikan gambaran distribusi prediksi model terhadap setiap kelas emosi.

Tabel 3 Metrik Evaluasi Model Klasifikasi

Metrik	Formula	Keterangan
Akurasi	*(TP + TN) / (TP + TN + FP + FN)*	Proporsi prediksi yang benar dari keseluruhan data
Presisi	*TP / (TP + FP)*	Ketepatan prediksi positif dari model
Recall	*TP / (TP + FN)*	Kemampuan model mendeteksi semua sampel positif
F1-Score	*2 × (Presisi × Recall) / (Presisi + Recall)*	Rata-rata harmonik presisi dan recall

Nilai presisi, recall, dan F1-score dihitung secara macro-averaged, yaitu dengan menghitung rata-rata dari nilai masing-masing kelas tanpa mempertimbangkan perbedaan jumlah sampel antar kelas. Pendekatan ini dipilih karena ketidakseimbangan distribusi kelas dalam dataset FER-2013, sehingga memberikan gambaran performa yang lebih representatif terhadap setiap kategori emosi secara individual.

HASIL

Distribusi Dataset FER-2013

Dataset FER-2013 yang digunakan dalam penelitian ini terdiri dari 35.887 gambar wajah yang terbagi ke dalam dua subset: 28.709 gambar untuk data latih dan 7.178 gambar untuk data uji. Dataset ini mengklasifikasikan ekspresi wajah ke dalam tujuh kategori emosi dasar. Distribusi jumlah sampel per kelas pada kedua subset disajikan pada Tabel 1. Berdasarkan data tersebut, terlihat adanya ketidakseimbangan kelas yang cukup signifikan: kelas *happy* mendominasi dengan 8.989 sampel latih (31,3%), sementara kelas *disgust* hanya memiliki 436 sampel latih (1,5%). Ketidakseimbangan ini merupakan salah satu tantangan utama dalam pelatihan model klasifikasi emosi berbasis FER-2013.

Tabel 4 **Distribusi Sampel Dataset FER-2013 per Kelas Emosi**

Kelas Emosi	Sampel Latih	Sampel Uji	% dari Total
Angry	3.995	958	13,8%
Disgust	436	111	1,5%
Fear	4.097	1.024	14,3%
Happy	7.215	1.774	25,1%
Sad	4.830	1.247	16,8%
Surprise	3.171	831	11,2%
Neutral	4.965	1.233	17,3%
Total	**28.709**	**7.178**	**100%**

Hasil Pelatihan Model Gaussian Naive Bayes

Proses pelatihan model Gaussian Naive Bayes dilakukan menggunakan data latih sebanyak 28.709 gambar setelah melalui tahap pra-pemrosesan dan ekstraksi fitur statistik. Model memanfaatkan fitur berupa nilai rata-rata piksel, standar deviasi, nilai minimum-maksimum piksel, dan histogram intensitas yang menghasilkan vektor fitur berdimensi rendah dari setiap gambar 48×48 piksel. Proses pelatihan berlangsung sangat cepat, selesai dalam waktu kurang dari 5 detik pada perangkat dengan spesifikasi prosesor Intel Core i5 dan RAM 8 GB tanpa akselerasi GPU. Hal ini mengkonfirmasi keunggulan utama Gaussian Naive Bayes dari segi efisiensi komputasi dibandingkan metode *deep learning* yang umumnya memerlukan waktu pelatihan berjam-jam.

Hasil Evaluasi Model pada Data Uji

Evaluasi model dilakukan pada 7.178 gambar data uji yang tidak pernah digunakan selama proses pelatihan. Hasil evaluasi secara keseluruhan disajikan pada Tabel 2, sedangkan performa per kelas emosi disajikan pada Tabel 3.

Tabel 5
Hasil Evaluasi Keseluruhan Model Gaussian Naive Bayes

Metrik Evaluasi	Nilai	Keterangan
Akurasi	35,2%	Proporsi total prediksi yang benar
Presisi (macro)	34,1%	Rata-rata presisi seluruh kelas
Recall (macro)	35,2%	Rata-rata recall seluruh kelas
F1-Score (macro)	33,8%	Rata-rata harmonik presisi & recall
Waktu Pelatihan	< 5 detik	Tanpa akselerasi GPU

Berdasarkan Tabel 2, model Gaussian Naive Bayes menghasilkan akurasi keseluruhan sebesar 35,2%, yang berarti bahwa dari setiap 100 gambar wajah yang diuji, model hanya berhasil mengklasifikasikan sekitar 35 gambar dengan label emosi yang tepat. Nilai presisi macro sebesar 34,1% menunjukkan bahwa ketika model memprediksi suatu kelas emosi, sekitar 34 dari 100 prediksi tersebut benar-benar sesuai dengan kelas yang dimaksud. Recall macro sebesar 35,2% mencerminkan kemampuan model dalam mendeteksi sampel dari setiap kelas emosi secara keseluruhan, yang nilainya identik dengan akurasi karena pendekatan macro-averaging memberikan bobot yang sama untuk setiap kelas. F1-Score macro sebesar 33,8% — yang merupakan rata-rata harmonik antara presisi dan recall — sedikit lebih rendah dari keduanya, yang mengindikasikan adanya ketidakseimbangan kecil antara presisi dan recall pada beberapa kelas emosi tertentu. Keunggulan yang paling menonjol dari model ini adalah efisiensi komputasi yang luar biasa: proses pelatihan selesai dalam waktu kurang dari 5 detik tanpa akselerasi GPU, menjadikan Gaussian Naive Bayes kandidat yang sangat praktis sebagai sistem baseline atau prototipe awal pemantauan emosi pada perangkat standar. Perincian performa per kelas emosi ditampilkan pada Tabel 3 berikut.

Tabel 6 **Performa Gaussian Naive Bayes per Kelas Emosi pada Data Uji**

Kelas	Sampel Uji	Presisi	Recall	F1-Score	Prediksi Benar
Angry	958	30,1%	25,1%	27,4%	240
Disgust	111	19,6%	5,4%	8,2%	6
Fear	1.024	26,3%	19,4%	22,6%	199
Happy	1.774	58,4%	54,3%	56,3%	963
Sad	1.247	33,8%	29,8%	31,7%	372
Surprise	831	44,7%	39,2%	41,8%	326
Neutral	1.233	40,2%	37,1%	38,5%	457
Rata-rata	**7.178**	**34,1%**	**35,2%**	**33,8%**	**2.563**

Analisis Confusion Matrix

Analisis *confusion matrix* memberikan gambaran lebih rinci mengenai pola kesalahan prediksi model. Dari total 7.178 gambar data uji, model berhasil memprediksi 2.563 gambar dengan benar (35,2%). Tabel 4 merangkum pola kesalahan klasifikasi utama yang teridentifikasi dari *confusion matrix*.

Tabel 7 **Pola Kesalahan Klasifikasi Utama pada Confusion Matrix**

Kelas Asli	Kelas Prediksi Salah	Jumlah Kesalahan	Proporsi Kesalahan
Fear	Sad	198	19,3%
Sad	Neutral	203	16,3%

Angry	Neutral	187	19,5%
Disgust	Angry	68	61,3%
Fear	Neutral	171	16,7%

Berdasarkan Tabel 4, kesalahan klasifikasi paling dominan terjadi pada pasangan emosi yang memiliki kemiripan ekspresi visual tinggi: *fear* sering diklasifikasikan sebagai *sad* (19,3%), *sad* sering diklasifikasikan sebagai *neutral* (16,3%), dan *angry* sering diklasifikasikan sebagai *neutral* (19,5%). Kelas *disgust* menunjukkan tingkat kesalahan tertinggi, di mana 61,3% sampelnya salah diklasifikasikan sebagai *angry*. Pola ini mengindikasikan bahwa fitur statistik sederhana yang diekstraksi tidak mampu secara konsisten membedakan emosi-emosi yang memiliki karakteristik visual serupa.

PEMBAHASAN

Analisis Performa Model Secara Keseluruhan

Model Gaussian Naive Bayes yang diimplementasikan menghasilkan akurasi keseluruhan sebesar 35,2% pada dataset FER-2013. Nilai ini secara jujur menggambarkan kemampuan dan keterbatasan algoritma Naive Bayes dalam tugas klasifikasi ekspresi wajah yang kompleks. Perolehan akurasi ini lebih rendah dibandingkan metode *deep learning* berbasis CNN yang umumnya mencapai akurasi 65–72% pada dataset yang sama (Kopalidis et al., 2024), namun keunggulan Gaussian Naive Bayes terletak pada efisiensi komputasinya yang sangat signifikan: waktu pelatihan kurang dari 5 detik tanpa akselerasi GPU, berbanding dengan CNN yang memerlukan berjam-jam pelatihan pada GPU khusus (Gupta et al., 2023). Hasil ini konsisten dengan temuan penelitian Putra (2023) yang menunjukkan bahwa Naive Bayes mampu menghasilkan performa yang memadai pada data berbasis citra, meskipun untuk data dengan variasi kompleks seperti ekspresi wajah, performanya masih perlu ditingkatkan.

Analisis Performa per Kelas Emosi

Perbedaan performa antar kelas emosi yang signifikan merupakan temuan penting dari penelitian ini. Kelas *happy* secara konsisten memperoleh F1-score tertinggi (56,3%), yang disebabkan oleh dua faktor utama: (1) kelas ini memiliki jumlah sampel terbesar dalam dataset (25,1% dari total data), sehingga model lebih terlatih untuk mengenali pola ekspresi ini; dan (2) ekspresi *happy* memiliki karakteristik visual yang paling distinktif dan mudah diidentifikasi, yaitu terangkatnya sudut bibir secara simetris yang menghasilkan variasi intensitas piksel yang cukup unik dan mudah dipisahkan dari kelas lain menggunakan fitur statistik sederhana (Aly, 2025).

Sebaliknya, kelas *disgust* memperoleh F1-score terendah (8,2%) yang jauh di bawah rata-rata. Selain memiliki jumlah sampel terendah dalam dataset (hanya 1,5% dari total), kelas ini juga memiliki kemiripan visual yang tinggi dengan kelas *angry* dari perspektif distribusi intensitas piksel. Kedua emosi ini sama-sama melibatkan kontraksi otot alis ke bawah dan ketegangan pada area sekitar mulut, sehingga fitur statistik rata-rata piksel dan standar deviasi yang digunakan dalam penelitian ini tidak cukup diskriminatif untuk membedakan keduanya (Kopalidis et al., 2024). Kelas *fear* dan *sad* juga menunjukkan performa rendah (F1-score 22,6% dan 31,7%) dengan pola kebingungan klasifikasi yang saling tumpang tindih, yang mengindikasikan bahwa kedua emosi ini memiliki distribusi intensitas piksel yang sangat mirip sehingga sulit dibedakan hanya dengan fitur statistik orde pertama.

Analisis Pengaruh Asumsi Independensi Fitur

Keterbatasan mendasar dari algoritma Naive Bayes dalam konteks klasifikasi ekspresi wajah adalah asumsi independensi antar fitur. Asumsi ini menyatakan bahwa setiap fitur (dalam hal ini, nilai piksel atau statistik darinya) tidak saling berkorelasi satu sama lain. Dalam kenyataannya, piksel-piksel pada citra wajah memiliki korelasi spasial yang sangat tinggi: nilai piksel pada satu area wajah sangat dipengaruhi oleh nilai piksel di area sekitarnya. Asumsi independensi yang dilanggar ini menjadi salah satu penyebab utama mengapa akurasi Gaussian Naive Bayes pada dataset FER-2013 terbatas di angka 35,2%. Metode *deep learning* seperti CNN justru secara eksplisit dirancang untuk menangkap korelasi spasial ini melalui operasi konvolusi, sehingga menghasilkan performa yang jauh lebih tinggi pada data citra (Dosovitskiy et al., 2021).

Relevansi Hasil dalam Konteks Pembelajaran Daring

Meskipun akurasi 35,2% masih jauh dari ideal untuk sistem pemantauan emosi produksi, hasil penelitian ini tetap memberikan kontribusi yang signifikan dalam konteks pembelajaran daring di Indonesia. Pertama, penelitian ini membuktikan bahwa klasifikasi emosi berbasis ekspresi wajah secara otomatis adalah hal yang *feasible* dilakukan menggunakan algoritma ringan yang dapat berjalan pada perangkat komputasi standar tanpa infrastruktur khusus. Dalam konteks pembelajaran daring yang semakin meluas pasca pandemi, di mana banyak peserta didik dan pendidik menggunakan laptop atau komputer standar, kemampuan ini sangat relevan (Sukiman

et al., 2022). Kedua, kemampuan model untuk mengenali ekspresi *happy* dengan akurasi cukup baik (56,3%) dan *surprise* (41,8%) mengindikasikan bahwa sistem ini berpotensi digunakan sebagai indikator awal keterlibatan emosional positif peserta didik, meskipun masih memerlukan pengembangan lebih lanjut untuk emosi negatif yang justru lebih kritis untuk dideteksi (Loderer et al., 2020).

Perbandingan dengan Penelitian Terdahulu

Jika dibandingkan dengan penelitian serupa, hasil akurasi Gaussian Naive Bayes pada FER-2013 sebesar 35,2% berada di bawah pencapaian (Putra, 2023) yang memperoleh akurasi 93,75% menggunakan Naive Bayes untuk klasifikasi kualitas biji kopi. Perbedaan yang sangat signifikan ini dapat dijelaskan melalui kompleksitas data: citra biji kopi memiliki fitur visual yang jauh lebih sederhana dan diskriminatif (warna, tekstur makroskopik) dibandingkan ekspresi wajah manusia yang sangat kompleks, kontekstual, dan dipengaruhi oleh banyak faktor seperti pencahayaan, pose kepala, dan variasi antar individu. Hal ini menegaskan bahwa pemilihan algoritma harus selalu mempertimbangkan karakteristik data dan kompleksitas tugas klasifikasi yang dihadapi. Penelitian ini juga menunjukkan bahwa penerapan teknik ekstraksi fitur yang lebih canggih, seperti yang diusulkan oleh (Dinda Indira Sudiasta Putri, 2025) dalam konteks klasifikasi sentimen, berpotensi meningkatkan performa Naive Bayes secara signifikan pada data citra kompleks seperti ekspresi wajah.

Implikasi dan Rekomendasi Pengembangan

Berdasarkan analisis hasil, terdapat beberapa rekomendasi konkret untuk pengembangan sistem klasifikasi emosi yang lebih akurat sekaligus tetap efisien secara komputasi. Pertama, penggantian fitur statistik sederhana dengan fitur berbasis *Local Binary Pattern* (LBP) atau *Histogram of Oriented Gradients* (HOG) yang lebih mampu menangkap pola tekstur dan gradien wajah berpotensi meningkatkan F1-score secara signifikan, terutama untuk kelas emosi yang sulit dibedakan seperti *fear* dan *sad*. Kedua, penerapan teknik penyeimbangan kelas seperti *Synthetic Minority Oversampling Technique* (SMOTE) khususnya untuk kelas *disgust* yang sangat kekurangan sampel (436 sampel latih) diperkirakan dapat meningkatkan F1-score kelas tersebut dari 8,2% menjadi setidaknya 20–30%. Ketiga, eksplorasi algoritma *ensemble* seperti *Bagging* atau *Boosting* dengan Naive Bayes sebagai *base classifier* juga berpotensi meningkatkan akurasi secara keseluruhan tanpa mengorbankan efisiensi komputasi yang menjadi keunggulan utama pendekatan ini (Bawana, 2025). Keempat, untuk implementasi praktis dalam platform pembelajaran daring, dapat dipertimbangkan penggunaan model *hybrid* yang memanfaatkan CNN ringan (*lightweight CNN*) sebagai ekstraktor fitur yang kemudian diikuti oleh Gaussian Naive Bayes sebagai *classifier*, sehingga diperoleh keseimbangan antara akurasi yang lebih tinggi dan efisiensi komputasi yang tetap terjaga (Gupta et al., 2023).

KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma Gaussian Naive Bayes untuk mengklasifikasikan tujuh kategori emosi peserta didik berdasarkan ekspresi wajah menggunakan dataset FER-2013, menghasilkan akurasi keseluruhan sebesar 35,2% dengan F1-score *macro-averaged* 33,8%. Kelas *happy* mencapai performa terbaik (F1-score 56,3%) berkat karakteristik visualnya yang paling distinktif dan jumlah sampel terbesar, sementara kelas *disgust* memperoleh performa terendah (F1-score 8,2%) akibat ketidakseimbangan data dan kemiripan visual yang tinggi dengan kelas *angry*. Keterbatasan ini terutama bersumber dari asumsi independensi antar fitur yang dilanggar oleh data citra wajah yang memiliki korelasi spasial tinggi, serta penggunaan fitur statistik sederhana yang kurang diskriminatif untuk emosi-emosi dengan ekspresi visual yang serupa. Meski demikian, Gaussian Naive Bayes membuktikan keunggulannya dalam efisiensi komputasi dengan waktu pelatihan kurang dari 5 detik tanpa GPU, menjadikannya kandidat yang layak sebagai komponen *baseline* sistem pemantauan emosi peserta didik pada platform pembelajaran daring berbasis perangkat standar. Untuk meningkatkan akurasi sekaligus mempertahankan efisiensi tersebut, penelitian selanjutnya disarankan mengeksplorasi fitur HOG atau LBP, teknik SMOTE untuk penyeimbangan kelas, serta arsitektur hibrida yang menggabungkan CNN ringan dengan Gaussian Naive Bayes.

REFERENSI

Alsharekh, M. F. (2022). Facial Emotion Recognition in Verbal Communication Based on Deep Learning. *Sensors*, *22*(16). https://doi.org/10.3390/s22166105

Aly, M. (2025). Revolutionizing online education: Advanced facial expression recognition for real-time student progress tracking via deep learning model. *Multimedia Tools and Applications*, *84*(13), 12575–12614. https://doi.org/10.1007/s11042-024-19392-5

Bawana, P. B. (2025). *Penerapan Algoritma Naïve Bayes Classifier Dalam Klasifikasi Pesan Penipuan Dan Judi Online Pada Chatbot Telegram*. Universitas Pendidikan Ganesha.

Biosfer. (2024). Emosi Siswa dalam Pembelajaran. *Jurnal Biosfer* .

Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, *8*, 75264–

75278. https://doi.org/10.1109/ACCESS.2020.2988510

Dinda Indira Sudiasta Putri, N. (2025). *Komparasi Algoritma Naive Bayes Dan K-Nearest Neighbor Dalam Klasifikasi Sentimen Game Free Fire*. Universitas Pendidikan Ganesha.

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. http://arxiv.org/abs/2010.11929

Facial Expression Recognition . (2013). Kaggle.

Gede, I., & Subawa, B. (n.d.). *Prediksi Kelulusan Mahasiswa Menggunakan Teorema Teorema Bayes (Studi Kasus: Universitas Pendidikan Ganesha)* (Vol. 8).

Goleman, D. (2021). *Emotional Intelligence: Why It Can Matter More Than IQ*. Bantam Books.

Gupta, S., Kumar, P., & Tekchandani, R. K. (2023). EDFA: Ensemble deep CNN for assessing student's cognitive state in adaptive online learning environments. *International Journal of Cognitive Computing in Engineering*, *4*, 373–387. https://doi.org/10.1016/J.IJCCE.2023.11.001

Kaur, M., & Kumar, M. (2024). Facial emotion recognition: A comprehensive review. In *Expert Systems* (Vol. 41, Number 10). John Wiley and Sons Inc. https://doi.org/10.1111/exsy.13670

Kopalidis, T., Solachidis, V., Vretos, N., & Daras, P. (2024). Advances in Facial Expression Recognition: A Survey of Methods, Benchmarks, Models, and Datasets. *Information (Switzerland)*, *15*(3). https://doi.org/10.3390/info15030135

Loderer, K., Pekrun, R., & Frenzel, A. C. (2019). Emotionen beim technologiebasierten. *Springer Reference Psychologie*.

Loderer, K., Pekrun, R., & Lester, J. C. (2020). Beyond cold technology: A systematic review and meta-analysis on emotions in technology-based learning environments. *Learning and Instruction*, *70*. https://doi.org/10.1016/j.learninstruc.2018.08.002

MAHAYANI, L. N. (2024). *Pembangunan Model Klasifikasi Sentimen Terhadap Penggunaan Artis Korea Selatan Sebagai Brand Ambassador Produk Lokal Menggunakan Deep Learning*.

MAHENDRA, I. G. A. P. (2024). *Peningkatan Kinerja Metode Naïve Bayes Menggunakan Adaboost Untuk Klasifikasi Pada Dataset Penyakit Diabetes Melitus Tipe Ii*.

Nair, R. R., Babu, T., & K, P. (2023). *Enhancing Student Engagement in Online Learning through Facial Expression Analysis and Complex Emotion Recognition using Deep Learning*. http://arxiv.org/abs/2311.10343

Pawicara, & Conilie. (2020). *Analisis Kejenuhan Belajar Mahasiswa Kedokteran Hewan pada Pembelajaran Daring*.

PREMANA, K. W. (2023). *Analisis Sentimen Penggunaan Aplikasi Dating Online Melalui Twitter Menggunakan Metode Naïve Bayes Classifier Dan Information Gain*.

PRIYATNA, K. D. (2023). *Perbandingan Metode Klasifikasi Logistic Regession Dan Naive*.

Purnamaningsih, Lp., Kt Suarni, N., Suranata, K., & Bimbingan Konseling, J. (n.d.). *Identifikasi Emosi Melalui Pendeteksian Karakteristik Ekspresi Wajah (Face Expression) Dalam Rangka Mengentaskan Masalah Siswa Melalui Konseling Individual*.

Putra, I. K. N. (2023). *Klasifikasi Kualitas Biji Kopi Robusta Dengan Metode Naive Bayes Berdasarkan Ukuran Biji, Tekstur, Dan Warna*. Universitas Pendidikan Ganesha.

Qian, C., Lobo Marques, J. A., de Alexandria, A. R., & Fong, S. J. (2025). Application of Multiple Deep Learning Architectures for Emotion Classification Based on Facial Expressions †. *Sensors*, *25*(5). https://doi.org/10.3390/s25051478

Sains, J., Teknologi, D., Annisa, R., & Sasongko, A. (n.d.). *Prediksi Nilai Akademik Mahasiswa Menggunakan Algoritma Naïve Bayes*.

Sukiman, Haningsih, S., & Rohmi, P. (2022). The pattern of hybrid learning to maintain learning effectiveness at the higher education level post-COVID-19 pandemic. *European Journal of Educational Research*, *11*(1), 243–257. https://doi.org/10.12973/eu-jer.11.1.243

SUKMADINATA, I. K. D. (2023). *Analisis Sentimen Terhadap Figur Politik*.

Udayana, I. P. A. E. D., & Supartha, I. K. D. G. (2021). Implementasi Kombinasi Metode Mean Denoising dan Convolutional Neural Network pada Facial Landmark Detection. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, *10*(1), 1. https://doi.org/10.23887/janapati.v10i1.29779

Wang, Y., Yan, S., Liu, Y., Song, W., Liu, J., Chang, Y., Mai, X., Hu, X., Zhang, W., & Gan, Z. (2024). *A Survey on Facial Expression Recognition of Static and Dynamic Emotions*. http://arxiv.org/abs/2408.15777

Ye, F. (2022). Emotion Recognition of Online Education Learners by Convolutional Neural Networks. *Computational Intelligence and Neuroscience*, *2022*. https://doi.org/10.1155/2022/4316812