

Optimasi Deteksi Retakan Jalan Menggunakan Filter Sobel dan Klasifikasi Gaussian Naïve Bayes

Fakhar Muhammad Hidayat ^{(1)*}, Cahyo Crysdian ⁽²⁾, Tri Mukti Lestari ⁽³⁾

Departemen Teknik Informatika, UIN Maulana Malik Ibrahim, Malang, Indonesia
e-mail : fakhar.muhammad.hidayat@gmail.com, {cahyo,trimuktilestari}@ti.uin-malang.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 22 Desember 2025, direvisi 2 Mei 2026, diterima 12 Mei 2026, dan dipublikasikan 25 Mei 2026.

Abstract

Manual identification of road damage using simple measuring tools is considered inefficient, subjective, and time-consuming, hindering the infrastructure repair process. This study aims to optimize automatic road crack detection by combining edge detection for feature extraction and Gaussian Naive Bayes (GNB) classification. This research utilizes the Road Surface Classification Dataset (RSCD), consisting of 1000 concrete road images with balanced class proportions. The research process includes image acquisition, segmentation, and preprocessing using the Sobel filter to extract edge features and erosion to refine crack representation. Statistical features in the form of black pixel count and edge length are extracted as model inputs. Experiments were conducted using three data split scenarios (70:30, 80:20, 90:10) validated with the K-Fold Cross Validation method. The test results show that the 90:10 data split scenario yields the most optimal and stable performance, achieving 88% accuracy, 91.67% precision, 84.62% recall, and an F1-Score of 88%. This study optimises the balance between computational efficiency and detection accuracy through a lightweight hybrid approach that integrates edge-based feature extraction with probabilistic classification.

Keywords: Road Crack Detection, Gaussian Naïve Bayes, Sobel Filter, Image Classification, Image Processing

Abstrak

Identifikasi kerusakan jalan secara manual menggunakan alat ukur sederhana dinilai kurang efisien, subjektif, dan membutuhkan waktu lama sehingga dapat menghambat proses perbaikan infrastruktur. Penelitian ini bertujuan untuk mengoptimalkan deteksi retakan jalan secara otomatis dengan menggabungkan deteksi tepi untuk ekstraksi fitur dan klasifikasi menggunakan *Gaussian Naive Bayes* (GNB). Penelitian ini memanfaatkan *Road Surface Classification Dataset* (RSCD) yang terdiri dari 1000 citra jalan beton dengan proporsi kelas yang seimbang. Proses penelitian meliputi akuisisi citra, segmentasi, preprocessing menggunakan filter *Sobel* untuk mengekstraksi fitur tepi dan erosi untuk menyempurnakan representasi retakan. Fitur statistik berupa jumlah piksel hitam dan panjang tepi diekstraksi sebagai *input* untuk model. Uji coba dilakukan menggunakan tiga skenario pembagian data (70:30, 80:20, 90:10) yang divalidasi dengan metode *K-Fold Cross Validation*. Hasil pengujian menunjukkan bahwa skenario pembagian data 90:10 memberikan performa paling optimal dan stabil dengan akurasi mencapai 88%, presisi 91,67%, *recall* 84,62%, dan *F1-Score* 88%. Penelitian ini mengoptimalkan keseimbangan antara efisiensi komputasi dan akurasi deteksi melalui pendekatan hibrida ringan yang mengintegrasikan ekstraksi fitur berbasis deteksi tepi dengan klasifikasi probabilistik.

Kata Kunci: Deteksi Retakan Jalan, Gaussian Naïve Bayes, Filter Sobel, Klasifikasi Citra, Pengolahan Citra

1. PENDAHULUAN

Kualitas jalan yang baik merupakan salah satu faktor penting untuk menjamin keamanan dan kenyamanan dalam transportasi umum. Kerusakan di permukaan jalan, seperti munculnya retakan sering kali menjadi tanda awal dari kerusakan yang lebih serius. Kualitas jalan yang buruk juga dapat menyebabkan ketidaknyamanan bagi penggunaannya dan meningkatkan bahaya keselamatan (Bhatt et al., 2017). Selain itu, retakan kecil dapat cepat berubah menjadi lubang



berbahaya karena faktor lingkungan seperti air hujan yang meresap (Zou et al., 2019). Tindakan preventif seperti deteksi dini sangat penting dalam perbaikan dan pemeliharaan infrastruktur.

Pada umumnya, pemeriksaan kondisi jalan di Indonesia masih mengandalkan survei manual dengan perangkat sederhana. Metode tradisional ini dianggap tidak efisien karena tergantung pada penilaian subyektif dari pengamat, waktu yang lama, dan memiliki batasan untuk memantau area yang luas. Ketergantungan pada pemeriksaan manual sering kali menyebabkan lambatnya penemuan kerusakan, sehingga mengganggu proses perbaikan dan meningkatkan risiko bagi pengguna jalan (Xu et al., 2022). Oleh karena itu, deteksi kerusakan jalan sangat penting agar proses perbaikan dan pemeliharaan jalan dapat dilakukan dengan segera (Kusumaningrum et al., 2022).

Dalam beberapa tahun terakhir, penelitian mengenai deteksi retakan otomatis telah berkembang pesat dengan bantuan teknologi *deep learning*. Penelitian terbaru menggunakan desain jaringan saraf seperti *U-Net* yang diintegrasikan dengan *EfficientNet encoder* untuk memperkaya kumpulan fitur untuk deteksi retakan jalan yang lebih rinci, mendalam, dan akurat (Chakurkar et al., 2024). Hasil penelitian menunjukkan keberhasilan metode ini dengan tingkat akurasi mencapai 97.49% dan Mean Intersection over Union (MIU/IoU) sebesar 74,9%. Penelitian lainnya oleh (Xu et al., 2024) dengan metode LETNet (*Locally Enhanced Transformer Network*) yang mampu menangkap fitur global dengan modul peningkatan lokal dapat mencapai IoU sebesar 89,91% dan recall sebesar 89,49%. Meskipun algoritma *deep learning* memberikan performa superior dalam ekstraksi fitur dan klasifikasi citra, pendekatan tersebut memerlukan sumber daya komputasi yang tinggi dan dataset yang besar untuk pelatihan data (Cha et al., 2017). Tingginya beban operasional tersebut membatasi implementasi praktis *deep learning*, terutama pada lingkungan dengan sumber daya terbatas. Oleh karena itu, diperlukan sebuah pendekatan hibrida yang mengintegrasikan algoritma deteksi tepi tradisional dengan model klasifikasi ringan, guna mencapai efisiensi komputasi yang tinggi dengan tetap mempertahankan akurasi deteksi.

Berbagai metode hibrida yang menggabungkan deteksi tepi tradisional dan model klasifikasi sebenarnya telah banyak diusulkan. Pada tahapan ekstraksi fitur, Metode konvensional seperti Canny sering digunakan aplikasi yang membutuhkan deteksi tepi dengan presisi tinggi dan tingkat kesalahan rendah (Grace et al., 2025). Namun disisi lain, Penelitian terbaru secara empiris membuktikan bahwa Canny sebagai preprocessing justru dapat menurunkan performa klasifikasi pada beberapa model dan menyebabkan ledakan kebutuhan memori komputasi hingga berpuluh-puluh kali lipat (Bhat & Szczuko, 2025). Beban komputasi ini disebabkan oleh peningkatan eksponensial pada kombinasi fitur yang harus diproses model seiring bertambahnya ukuran data secara masif. Hal ini menjadikan detektor tepi yang kompleks kurang efisien jika diterapkan pada sistem yang menuntut pemrosesan cepat dengan sumber daya terbatas

Tantangan efisiensi serupa juga ditemukan pada tahapan klasifikasi. Berdasarkan literatur, SVM dan KNN memiliki keterbatasan operasional untuk kasus ini. Penelitian mencatat bahwa model SVM dasar sangat rentan mengalami over-fitting pada klasifikasi citra, sehingga memaksa sistem untuk menerapkan teknik validasi silang (cross-validation) yang pada akhirnya melipatgandakan beban komputasi pelatihan (Moghaddam et al., 2020). Selain itu, penelitian lainnya menunjukkan bahwa KNN yang bekerja tanpa model dan murni berbasis memori, memiliki performa yang sangat tidak stabil dan sensitif terhadap rasio data latih, dengan akurasi yang dapat anjlok hingga di bawah 60% jika rasionya tidak ideal (Damanik et al., 2023). Keterbatasan performa juga terjadi di pendekatan *ensemble* pada algoritma *Random Forest*. Penelitian membuktikan secara empiris bahwa algoritma *Random Forest* (RF) gagal beroperasi optimal jika hanya diberikan fitur tunggal dari deteksi tepi konvensional (seperti Sobel atau Canny) dengan akurasi klasifikasi yang turun drastis ke kisaran 47% hingga 52% (Kurniati & Pramana, 2023). Secara keseluruhan, dibutuhkan pendekatan alternatif yang lebih ringan dan stabil secara statistik untuk mengatasi kekurangan komputasi dari penelitian sebelumnya.

Penelitian ini akan menggunakan kombinasi metode deteksi tepi Sobel untuk ekstraksi fitur dan Gaussian Naïve Bayes (GNB) sebagai model klasifikasi. Penggunaan Sobel yang dipadukan

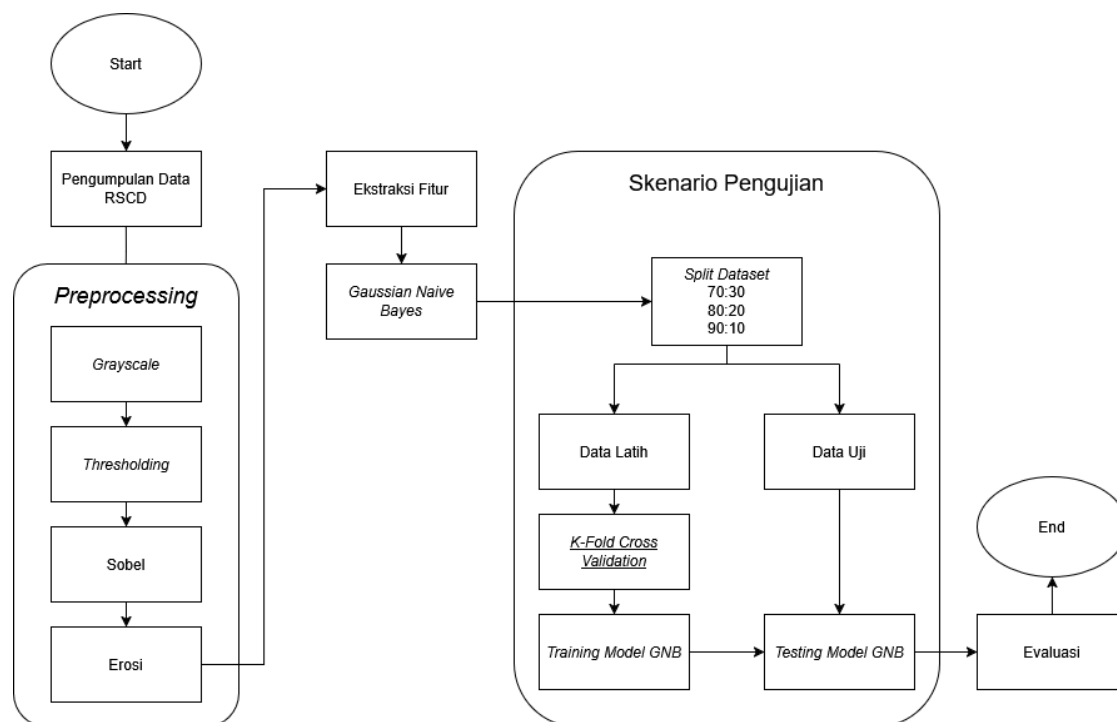


dengan operasi morfologi digunakan untuk mengambil fitur geometris dari retakan dan mengurangi noise yang tidak relevan. Di sisi lain, GNB dipilih sebagai pengklasifikasian karena kemampuannya yang dirancang untuk menangani data kontinu dengan asumsi distribusi Gaussian (Islam et al., 2022). Karakteristik tersebut relevan karena fitur pada citra yang dihasilkan dianggap sebagai data kontinu karena memiliki rentang distribusi yang besar. Berbeda dengan algoritma yang lebih kompleks, GNB memiliki keunggulan karena pelatihannya bersifat non-iteratif. Model ini hanya membutuhkan satu kali pemrosesan data untuk menghitung parameter statistik distribusinya. Selain itu, metode GNB juga memiliki kelebihan karena tidak memerlukan banyak data dan mudah diimplementasikan dengan akurasi yang cukup baik (Surya & Yamasari, 2024)

Secara lebih rinci, penelitian ini bertujuan untuk mengukur kinerja gabungan metode konvolusi dan GNB dalam mendeteksi retakan pada gambar jalan beton. Objek penelitian dilakukan dengan menggunakan Dataset Klasifikasi Permukaan Jalan (RSCD) melalui berbagai skenario pembagian data untuk menemukan konfigurasi model yang paling efektif. Dengan demikian, hasil dari penelitian ini diharapkan dapat mencapai akurasi yang tinggi dan bermanfaat untuk mendeteksi retakan jalan sehingga dapat mempermudah dalam mencatat informasi terkait kerusakan jalan.

2. METODE PENELITIAN

Desain alur penelitian merupakan rangkaian proses penelitian dari awal hingga akhir agar penelitian menjadi lebih terarah dan sistematis. Penelitian ini dimulai dari tahap pengumpulan data. Kemudian data akan diolah dalam tahap *preprocessing* yang dimulai dari mengubah citra menjadi keabuan (*grayscale*) hingga operasi morfologi (*erosi*). Selanjutnya, proses ekstraksi fitur dilakukan untuk mengambil citra biner berdasarkan dua fitur, yaitu banyak piksel dan panjang tepi hitam. Kedua fitur tersebut menjadi *input* pada metode *Gaussian Naive Bayes* (GNB) yang akan melalui skenario pengujian dan evaluasi. Tahap alur penelitian dijelaskan pada Gambar 1.




Gambar 1 Desain Alur Penelitian



2.1 Pengumpulan Data

Data utama yang dipergunakan dalam studi ini berasal dari Road Surface Classification Dataset (RSCD) yang dirilis oleh (Zhao et al., 2023). Dataset terdiri dari 1000 gambar permukaan jalan beton yang diambil di Beijing dengan berbagai kondisi pencahayaan dan tekstur. Setiap ukuran gambar dipotong menjadi 360×240 pixel dan diberi label secara manual berdasarkan klasifikasi yang mempertimbangkan tiga properti dasar jalan, yaitu tingkat gesekan, material, dan ketidakrataan. Penelitian ini menggunakan dataset RSCD yang diklasifikasikan dengan dua kategori, yaitu jalan beton halus pada cuaca kering dan jalan beton sedikit tidak rata pada cuaca kering. Gambar tersebut kemudian dilabeli ulang menjadi dua kelas untuk tujuan klasifikasi, yaitu kelas retak dan kelas normal. Kumpulan data ditunjukkan pada Gambar 2.



Gambar 2 Contoh Dataset

2.2 Preprocessing

Langkah-langkah preprocessing gambar dilakukan untuk menonjolkan ciri retakan dan mengurangi noise yang tidak relevan. Proses dimulai dengan konversi citra berwarna *Red Green Blue* (RGB) menjadi *grayscale*. Tujuan dari langkah ini adalah untuk menyederhanakan data gambar untuk mengurangi ruang penyimpanan dan biaya komputasi (Khudhair et al., 2017). Persamaan matematis yang umum digunakan untuk mendapatkan nilai derajat keabuan (Y) dari komponen merah (R), hijau (G), dan biru (B) diformulasikan pada Pers. (1). Melalui perhitungan linear ini, setiap piksel yang direpresentasikan oleh vektor tiga dimensi ditransformasikan menjadi skalar satu dimensi yang merepresentasikan tingkat kecerahan dengan rentang nilai integer 0 (hitam) hingga 255 (Anh and Tam, 2022).

$$Y = 0.299 \cdot R + 0.587 \cdot G + 0.114 \cdot B \quad (1)$$

Kemudian, proses segmentasi dilakukan dengan teknik *inverse binary thresholding* yang bertujuan untuk memisahkan objek retakan dari permukaan aspal berdasarkan perbedaan intensitas piksel (Dong, 2025) Tingkat kecerahan piksel yang berada di bawah ambang batas akan tetap dianggap hitam (0), sedangkan piksel yang lain akan diubah menjadi putih (255). Hasil dari langkah ini adalah gambar biner dengan area retakan telah dipisahkan secara kasar dari latar belakangnya.

Gambar biner yang dihasilkan dari segmentasi kemudian diproses dengan filter Sobel ukuran 3×3 untuk mendeteksi tepi retakan baik secara vertikal maupun horizontal. Operasi Sobel dipilih karena perhitungannya yang relatif sederhana namun mampu mendeteksi perubahan gradien tepi secara signifikan (Supiyandi et al., 2024). Sobel bekerja dengan menggerakkan dua matriks kernel pada setiap pixel di seluruh matriks pada citra. Keduanya akan menilai perubahan yang tajam dalam intensitas seiring dengan arah sumbu x dan y . Hasil dari kedua proses ini kemudian digabungkan untuk menciptakan kekuatan gradien total yang menunjukkan kekuatan tepi di



setiap piksel. Rumus dari tiap kernel dan gradien total dari Sobel ditunjukkan pada Pers. (2) sampai (4).

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2)$$

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (3)$$

$$|G| = \sqrt{G_x + G_y} \quad (4)$$

Sebagai langkah terakhir, operasi morfologi erosi diterapkan dengan elemen struktural matriks 3×3. Operasi ini berguna untuk mengurangi noise dan struktur kecil yang tidak diperlukan (Fahmi et al., 2023). Operasi erosi dilakukan pada citra biner dengan tepi retakan yang direpresentasikan sebagai piksel putih (foreground) untuk menghilangkan noise, sebelum akhirnya divisualisasikan kembali sebagai piksel hitam. Prinsip dasar pengurangan ukuran didasari oleh teori himpunan, dengan piksel pada koordinat hanya akan tetap bernilai 1 (putih) jika elemen struktural yang diletakkan pada tempat tersebut sepenuhnya ada di dalam himpunan objek (Ma et al., 2020). Dengan cara ini, gangguan yang tidak dapat menampung kernel sepenuhnya akan diubah menjadi hitam, sementara struktur utama retakan yang lebih tebal dan penting akan tetap dipertahankan meskipun sedikit berkurang. Hasil akhirnya adalah gambar biner yang lebih bersih dan siap untuk diproses di tahap ekstraksi fitur.

2.3 Ekstraksi Fitur

Setelah gambar dibersihkan dari noise, langkah selanjutnya adalah mengekstraksi fitur untuk mengubah data gambar menjadi bentuk angka yang bisa dipahami oleh model klasifikasi. Dua fitur bentuk utama diambil dari gambar biner, yaitu jumlah piksel hitam dan panjang tepi. Luas retakan dihitung dengan total penjumlahan piksel objek retakan, sedangkan panjang retakan direpresentasikan oleh jumlah piksel pada kerangka hasil penipisan morfologi (Oliveira et al., 2013). Secara teknis, untuk menghitung fitur panjang retakan yang akurat, metode penjumlahan piksel biasa tidak dapat diterapkan karena ketebalan retakan yang bervariasi sehingga memerlukan proses tambahan. Skeletonisasi mengupas kontur objek secara berulang hingga mencapai lebar satu piksel pada sumbu tengahnya (Fereidoon et al., 2016). Sehingga panjang retakan yang tebal berkurang menjadi garis kerangka setipis 1 piksel. Panjang retakan kemudian dihitung dengan menjumlahkan total piksel yang membentuk garis kerangka tersebut.

Pentingnya pemilihan fitur ini didasarkan pada signifikansi teknisnya dalam penilaian kondisi jalan. Karakteristik retakan seperti jenis, jumlah, dan lebar dapat menjadi indikator awal tingkat kerusakan dan kemampuan struktur beton dalam menopang beban (Mohan & Poobal, 2018). Oleh karena itu, fitur panjang dan luas retakan akan menjadi input numerik yang merepresentasikan karakteristik setiap gambar yang akan diproses oleh model klasifikasi Gaussian Naive Bayes.

2.4 Gaussian Naïve Bayes

Klasifikasi pola retakan dilakukan dengan menggunakan algoritma *Gaussian Naive Bayes* (GNB), yang merupakan metode berbasis probabilitas berdasarkan teorema Bayes untuk memprediksi kemungkinan kejadian di masa depan dengan mengacu pada pola data sebelumnya (Hasanah et al., 2022). Varian ini dipilih karena sifatnya yang dioptimalkan untuk menangani data yang memiliki nilai fitur kontinu, dengan asumsi bahwa data tersebut mengikuti distribusi normal atau Gaussian.



Dalam model ini, diasumsikan bahwa setiap fitur saling independen dalam memengaruhi prediksi target. Karakteristik distribusi statistik dari setiap kategori dijelaskan oleh dua parameter utama, yaitu rata-rata (μ) yang menunjukkan kecenderungan pusat dan deviasi standar (σ) yang mengukur sebaran data yang membentuk pola lonceng yang simetris. Persamaan rumus distribusi *Gaussian* ditunjukkan pada Pers. (5).

$$f(x) = \frac{1}{\sqrt{2\sigma\pi}} \exp^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (5)$$

Dalam pelaksanaan penelitian ini, GNB diterapkan untuk membedakan kondisi permukaan jalan menjadi dua kategori yaitu retak atau normal. Hal tersebut dilakukan dengan cara memproses data numerik yang diperoleh dari tahap pengambilan fitur. Dua fitur utama yang digunakan sebagai prediktor adalah jumlah piksel hitam dan panjang piksel hitam yang menggambarkan bentuk retakan. Selama fase pelatihan, sistem melakukan perhitungan rata-rata dan deviasi standar dari kedua fitur tersebut secara terpisah untuk setiap kategori. Data statistik ini menjadi parameter penting untuk membuat model distribusi probabilitas yang dapat mengenali ciri khas unik dari tekstur retakan dibandingkan dengan permukaan jalan yang utuh.

Proses klasifikasi akhir dilakukan melalui tiga tahap perhitungan probabilitas yang berurutan, yaitu prior, likelihood, dan posterior. Tahap pertama adalah menghitung probabilitas awal, yaitu peluang dasar munculnya kategori retak atau normal berdasarkan proporsi jumlah sampel dalam dataset sebelum fitur diamati. Nilai ini dihitung dengan membagi jumlah sampel dari setiap kelas dengan jumlah total sampel. Rumus dari probabilitas prior ditunjukkan pada Pers. (6).

$$\pi(\mu) = \sum_{j=1}^n \frac{x_j}{n} \quad (6)$$

Tahap kedua merupakan perhitungan *likelihood* yang menilai seberapa besar kemungkinan nilai fitur dari data uji berasal dari distribusi normal untuk masing-masing kategori menggunakan fungsi densitas probabilitas. *Likelihood* dihitung menggunakan distribusi *Gaussian* seperti pada Pers. (7).

$$L(\mu) = \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_v}} \exp\left(-\frac{1}{2}\left(\frac{x_j - \mu}{\sigma_v}\right)^2\right) \quad (7)$$

Tahap terakhir melibatkan penentuan probabilitas *posterior*, yang menggabungkan nilai prior dan likelihood untuk menghasilkan skor kepercayaan akhir, yaitu kelas dengan nilai posterior tertinggi ditetapkan sebagai hasil prediksi yang valid untuk gambar tersebut. Rumus probabilitas *posterior* menggunakan teorema *Bayes* seperti pada Pers. (8).

$$g(\mu|x) = \pi(\mu)L(\mu) = \sum_{j=1}^n \frac{x_j}{n} \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_v}} \exp\left(-\frac{1}{2}\left(\frac{x_j - \mu}{\sigma_v}\right)^2\right) \quad (8)$$

2.5 Skenario Pengujian

Penelitian ini membuat rencana pengujian eksperimen dengan tiga jenis pembagian data (split data) yang menggunakan rasio data latih dan data uji masing-masing 70:30, 80:20, dan 90:10. Tiga skenario tersebut dilakukan untuk mencari performa terbaik dari model (Mustolih et al., 2023). Pembagian ini dilakukan untuk menjaga keseimbangan proporsi kelas agar tidak terjadi bias pada performa karena ketidakseimbangan data dapat menyebabkan penurunan performa pada kelas minoritas (Fitriani et al., 2021). Dengan adanya perbedaan skenario ini akan ditemukan perbedaan hasil prediksi, sehingga dapat dipilih skenario dengan hasil terbaik.

Dalam memastikan model tetap stabil selama pelatihan, metode *K-Fold Cross Validation* diterapkan pada data latih. Nilai umum yang sering digunakan dalam k adalah 5 dan 10 (Anjas



and Idham, 2024). Pada penelitian ini akan dilakukan parameter *tuning* dengan membandingkan stabilitas antara $k=5$ dan $k=10$. Melalui hasil perbandingan *tuning* parameter, penelitian ini menggunakan $k=5$ (5-Fold) karena terbukti menghasilkan deviasi standar performa yang lebih rendah dan evaluasi yang lebih kuat dibandingkan dengan $k=10$. Proses 5 folds terdiri dari membagi kumpulan data latih menjadi lima bagian yang memiliki ukuran yang sama. Dalam setiap putarannya, sebuah model dilatih dengan menggunakan kombinasi dari 4/5 bagian tersebut, sementara satu bagian digunakan sebagai kumpulan data untuk memvalidasi dan menilai kinerja model.

2.6 Evaluasi

Kinerja klasifikasi model dievaluasi secara kuantitatif dengan menggunakan *confusion matrix* yang membandingkan hasil prediksi dengan label yang sebenarnya. Evaluasi model mencakup *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan elemen-elemen tersebut, terdapat empat metrik evaluasi yang dijadikan indikator performa model, yaitu: akurasi, presisi, *recall* dan *F1-Score* (Susanto & Cahyana, 2025). Akurasi berfungsi untuk menilai ketepatan secara keseluruhan, sedangkan presisi untuk menilai keakuratan prediksi positif. Selain itu, *recall* digunakan untuk mengukur kemampuan model dalam mendeteksi retakan. Terakhir, *F1-Score* berfungsi sebagai ukuran keseimbangan antara presisi dan *recall*. Rumus persamaan dari metrik evaluasi dituliskan pada Pers. (9) sampai (12).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

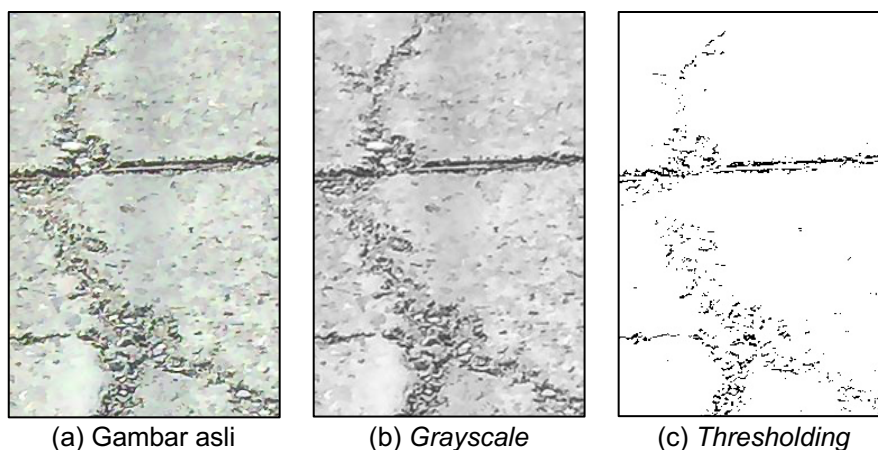
$$Recall = \frac{TP}{TP + FN} \quad (11)$$

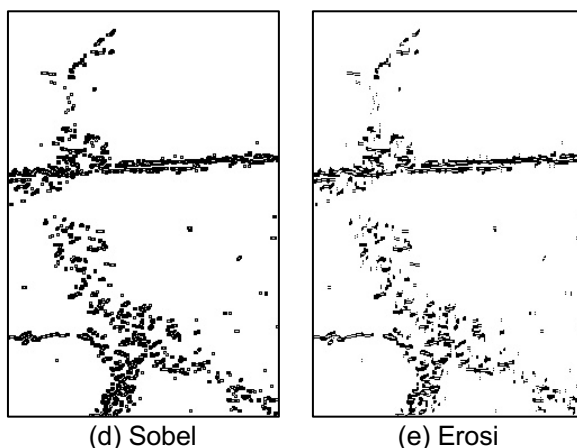
$$F1Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (12)$$

3. HASIL DAN PEMBAHASAN

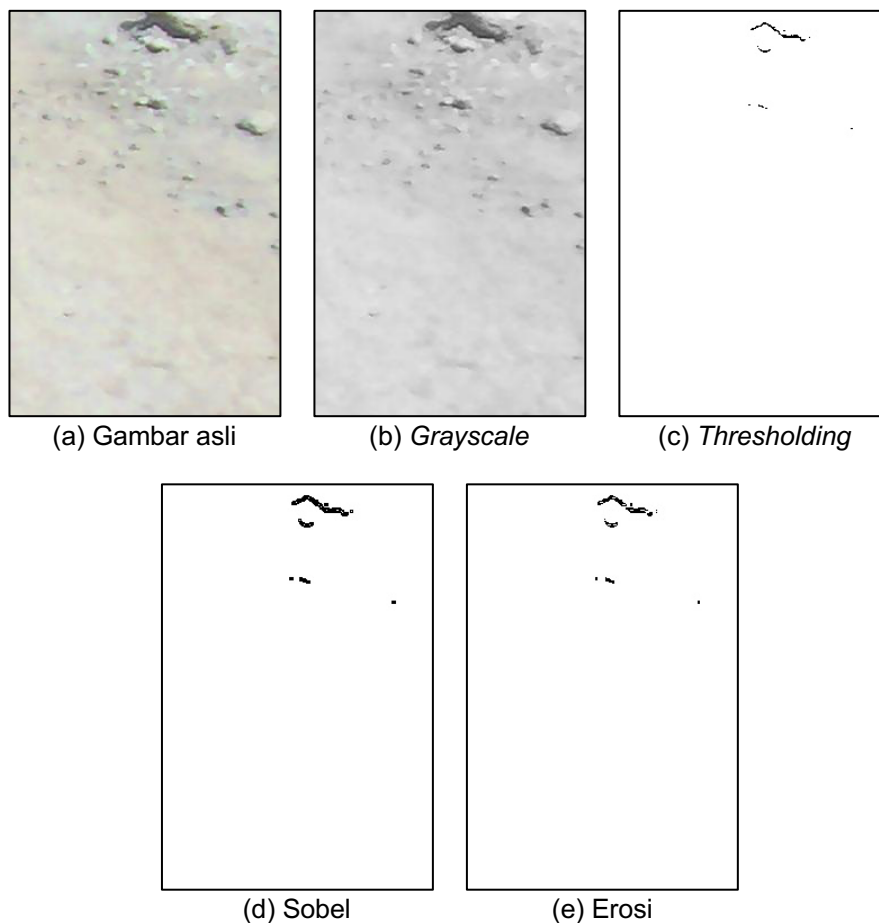
3.1 Hasil *Preprocessing* dan Ekstraksi Fitur

Proses *preprocessing* kelas retas dan kelas normal dimulai dari mengubah citra asli menjadi citra *grayscale* hingga tahap erosi. Citra hasil *preprocessing* selanjutnya akan melalui ekstraksi fitur untuk menghitung banyak piksel hitam dan panjang tepi hitam. Hasil gambar *preprocessing* ditunjukkan pada Gambar 3 dan 4.





Gambar 3 Hasil Preprocessing Kelas Retak



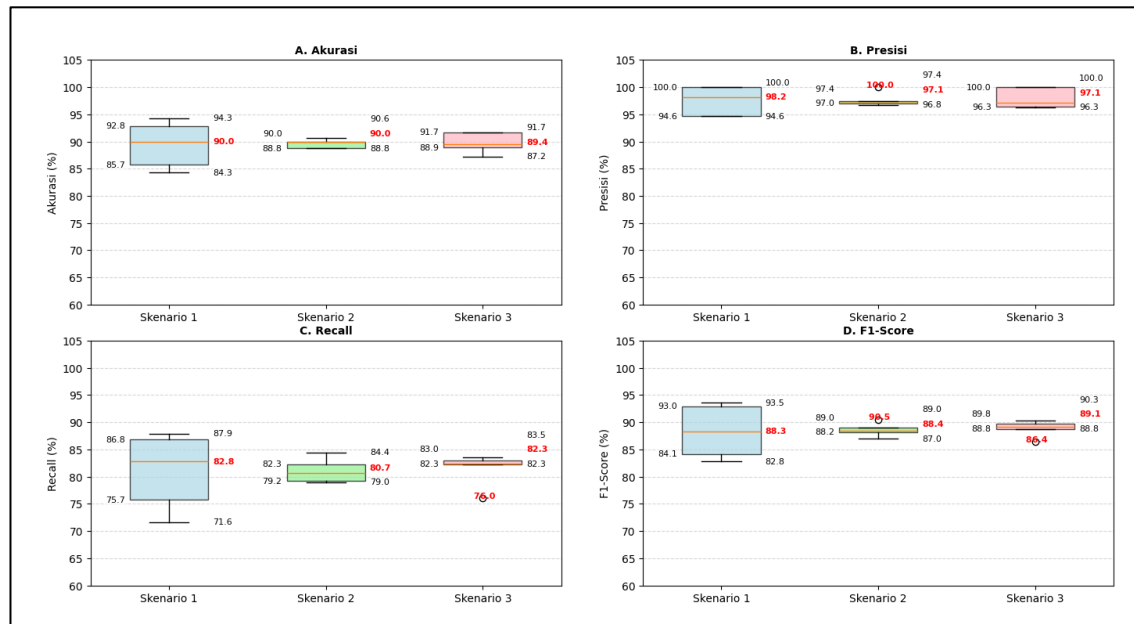
Gambar 4 Hasil Preprocessing Kelas Normal

3.2 Hasil Uji Coba

Evaluasi performa model dilakukan melalui dua tahapan analisis yang saling melengkapi. Tahap pertama adalah tinjauan stabilitas menggunakan K-Fold Cross Validation untuk melihat konsistensi model selama proses pelatihan. Tahap kedua adalah pengujian akhir pada data uji untuk mengukur kemampuan generalisasi model dalam mendeteksi retakan pada citra baru. Pendekatan dua tahap ini bertujuan untuk menghindari bias kesimpulan yang hanya didasarkan



pada satu kali pengujian. Analisis distribusi performa antar skenario divisualisasikan menggunakan diagram boxplot pada Gambar 5.



Gambar 5 Boxplot Distribusi K-Fold Cross Validation

Distribusi statistik kinerja dari setiap skenario diperlihatkan dalam bentuk diagram *boxplot* Gambar 5. Pada Skenario 1 menunjukkan sebaran data (*Interquartile Range*) yang paling lebar di seluruh metrik, khususnya pada *Recall* (71.6% - 87.9%). Hal ini menandakan performa model masih cukup fluktuatif dan kurang stabil. Sebaliknya, penambahan porsi data latih pada Skenario 2 dan Skenario 3 membuat dimensi kotak memendek secara drastis membuktikan adanya lonjakan stabilitas model yang signifikan dalam mempertahankan konsistensi klasifikasi. Metrik presisi konsisten menjadi keunggulan absolut dengan nilai median yang selalu bertahan di atas 97% pada ketiga skenario mengonfirmasi minimnya *False Positive* atau salah deteksi terlepas dari rasio datanya.

Secara keseluruhan, Skenario 2 merupakan titik keseimbangan paling optimal. Skenario ini menawarkan stabilitas sebaran yang sangat rapat dengan median akurasi 90.0% dan *F1-Score* 88.4% tanpa memunculkan *outlier* bawah seperti yang terlihat pada metrik *Recall* (76.0%) dan *F1-Score* 86.4% di Skenario 3. Stabilitas model yang telah teruji secara internal melalui *K-Fold Cross Validation* ini menjadi fondasi yang kuat sebelum model dihadapkan pada pengujian sesungguhnya. Untuk membuktikan keandalan tersebut secara objektif, model yang telah dilatih kemudian dievaluasi menggunakan data uji yang sepenuhnya terisolasi menggunakan matriks konfusi. Pengujian akhir dilakukan pada himpunan data uji untuk memvalidasi stabilitas performa. Hasil komparasi metrik performa (akurasi, presisi, recall, dan *F1-Score*) disajikan pada Tabel 1.

Tabel 1 Metrik Evaluasi Berbagai Skenario

Split Dataset	Akurasi	Presisi	Recall	F1-Score
70:30	89.00%	96.80%	80.67%	88.00%
80:20	88.50%	96.39%	80.00%	87.43%
90:10	85.00%	90.70%	78.00%	83.87%

Pada pengujian skenario pertama dengan pembagian rasio dataset 70:30, model klasifikasi menunjukkan performa yang paling optimal dan superior dibandingkan skenario lainnya. Hasil evaluasi mencatatkan tingkat akurasi sebesar 89,00% dengan perolehan presisi yang sangat tinggi, yaitu mencapai 96,80%. Tingginya nilai metrik presisi ini merupakan indikator krusial yang



mengonfirmasi bahwa model memiliki tingkat kesalahan deteksi palsu (*False Positive*) yang sangat minim. Hal ini didukung dengan nilai *Recall* sebesar 80,67% dan *F1-Score* 88,00%, skenario ini membuktikan bahwa arsitektur *Gaussian Naive Bayes* (GNB) mampu mengenali pola ekstraksi fitur Sobel secara cerdas dan efisien tanpa membutuhkan porsi data latih yang terlalu masif.

Skenario pengujian kedua dilakukan dengan rasio dataset 80:20. Performa klasifikasi model menunjukkan sedikit penurunan numerik, namun secara keseluruhan tetap mempertahankan ketangguhan yang sangat solid. Pada skenario ini, model menghasilkan tingkat akurasi sebesar 88,50% dan presisi yang masih bertahan di angka 96,39%. Sementara itu, kemampuan model dalam mengenali seluruh data positif (*Recall*) berada di angka 80,00%, menghasilkan nilai keseimbangan *F1-Score* sebesar 87,43%. Hasil pada rasio 80:20 ini sejalan dengan temuan titik stabilitas pada pengujian validasi internal sebelumnya, yang mengindikasikan bahwa penambahan porsi data latih sebesar 10% tidak memicu terjadinya *overfitting*, melainkan menjaga model tetap pada kemampuan generalisasi klasifikasi yang konsisten.

Terakhir pengujian skenario ketiga dengan rasio 90:10, mengalami penurunan metrik evaluasi yang cukup tajam dan menjadi yang terendah di antara semua pengujian. Tingkat akurasi turun menjadi 85,00%, diiringi dengan penurunan presisi menjadi 90,70%, *Recall* 78,00%, serta *F1-Score* 83,87%. Penurunan drastis performa ini dipicu oleh porsi data uji yang terlalu sempit (10%), sehingga metrik evaluasi menjadi sangat sensitif; proporsi kesalahan prediksi yang kecil saja akan langsung menggerus persentase performa secara signifikan. Secara keseluruhan, tren penurunan dari ketiga skenario ini menyimpulkan bahwa model usulan Sobel dan GNB mencapai efisiensi pembelajaran puncaknya pada rasio 70:30. Hal ini membuktikan bahwa arsitektur hibrida Sobel dan GNB mampu mencapai puncak kapasitas pembelajarannya secara efisien tanpa harus menambahkan porsi data latih secara berlebihan yang justru mengorbankan stabilitas pengujian akibat menyempitnya porsi data uji.

3.3 Studi Ablasi

Guna memahami kontribusi spesifik dari setiap tahapan prapemrosesan terhadap kinerja model, penelitian ini melakukan studi ablasi menggunakan skenario pembagian data latih dan uji sebesar 70:30 yang sebelumnya telah terbukti menghasilkan performa paling optimal pada pengujian matriks konfusi dengan hasil pada Tabel 2.

Tabel 2 Hasil Evaluasi Studi Ablasi

Skenario Ablasi	Deskripsi Alur Preprocessing	Akurasi	Presisi	Recall	F1-Score
Ablasi 1	Grayscale – Thresholding – Ekstraksi Fitur - GNB (tanpa sobel dan erosi)	89.67%	94.74%	84.00%	89.05%
Ablasi 2	Grayscale – Thresholding – Sobel - Ekstraksi Fitur – GNB (tanpa erosi)	88.33%	96.00%	80.00%	87.27%
Model Usulan	Grayscale – Thresholding – Sobel – Erosi - Ekstraksi Fitur – GNB	89.00%	96.80%	80.67%	88.00%

Skenario Ablasi 1 mengevaluasi model hanya dengan menggunakan *Thresholding* murni, tanpa melibatkan deteksi tepi Sobel dan operasi morfologi Erosi. Hasil pengujian menunjukkan bahwa skenario dasar ini menghasilkan akurasi yang secara numerik cukup tinggi (89,67%), namun memiliki tingkat presisi terendah (94,74%) di antara semua skenario. Secara teoretis, tingginya angka pada *baseline* ini merupakan anomali yang lahir dari kelemahan *Thresholding* murni yang hanya memisahkan citra berdasarkan intensitas gelap dan terang. Akibatnya, model menjadi terlalu sensitif dan rentan menghasilkan *False Positive*, yaitu *noise* non-struktural seperti noda aspal basah, bekas ban, atau bayangan sering kali disalahartikan sebagai retakan jalan.



Pada skenario Ablasi 2, metode deteksi tepi Sobel mulai diintegrasikan ke dalam *pipeline* prapemrosesan untuk mengatasi kelemahan *baseline*, namun masih tanpa disertai operasi Erosi. Penambahan filter Sobel secara fundamental mengubah fokus algoritma, dari sekadar mendeteksi sekumpulan area gelap menjadi mengenali struktur gradien tepi yang merupakan karakteristik fisik utama dari sebuah retakan. Pergeseran fokus ke arah struktural ini terbukti efektif menekan angka *False Positive*, yang ditandai dengan peningkatan nilai Presisi menjadi 96,00%. Meskipun metrik akurasi mengalami sedikit koreksi ke angka 88,33% akibat masih bersisanya *noise* tepi kasar peninggalan Sobel yang belum dibersihkan, skenario ini memvalidasi bahwa deteksi tepi merupakan tahapan esensial untuk menggeser kemampuan model agar tidak mudah tertipu oleh diskolorasi permukaan aspal.

Tahapan terakhir adalah evaluasi pada model usulan yang diimplementasikan secara komprehensif dengan menambahkan operasi erosi setelah sobel. Operasi erosi bekerja secara efektif mereduksi *noise* titik-titik kecil dan menipiskan tepi *foreground* yang tidak relevan, sehingga parameter fitur yang akan diekstrak menjadi sangat representatif. Integrasi ini mengalami peningkatan hasil dengan presisi melonjak ke titik tertingginya pada angka 96,80%, diiringi dengan pemulihan nilai akurasi ke angka 89,00%. Sebagai kesimpulan, studi ablasi ini menegaskan sebuah *trade-off* yang krusial; meskipun Ablasi 1 mengindikasikan nilai Akurasi yang sekilas lebih tinggi (selisih 0,67%), model usulan memberikan arsitektur yang jauh lebih andal dan fungsional untuk inspeksi jalan di dunia nyata. Tingkat presisi yang superior membuktikan bahwa sistem tidak hanya sekadar menebak area gelap, melainkan secara selektif memastikan bahwa objek yang dideteksi memiliki struktur yang valid sebagai sebuah retakan.

3.4 Perbandingan Kinerja Model

Untuk memvalidasi tingkat efektivitas dan keandalan arsitektur hibrida yang diusulkan, kinerja model Sobel dan *Gaussian Naïve Bayes* (GNB) perlu dievaluasi secara komparatif terhadap berbagai metode klasifikasi dari penelitian-penelitian sebelumnya. Evaluasi komparatif ini tidak hanya menitikberatkan pada perolehan metrik performa akhir seperti akurasi dan presisi, tetapi juga mempertimbangkan rasio pembagian data latih dan uji sebagai indikator krusial dalam mengukur efisiensi komputasi pembelajaran model. Ringkasan perbandingan kinerja antara metode usulan dengan berbagai pendekatan lain seperti pendekatan konvensional, *ensemble*, hingga *Deep Learning* yang disajikan secara komprehensif pada Tabel 3.

Tabel 3 Perbandingan Kinerja Berbagai Metode

Referensi	Objek Penelitian	Metode	Rasio Split	Hasil
(Damanik et al 2023)	Identifikasi Tipe Mobil	Sobel + KNN	90:10	Akurasi 80%, Presisi 85.71%, Recall 80%
(Kurniati & Pramana 2023)	Identifikasi Objek Kompleks	Sobel + Random Forest	N/A	Akurasi 52%, Presisi 56%, Recall 56%, dan F1-Score 56%
(Moghaddam et al 2020)	Retakan Dinding	Sobel + SVM	80:20	Akurasi 98.26%
(Yi et al, 2024)	Retakan Jalan	YOLOv8-LF	90:10	Presisi 84.5%
Model Usulan	Retakan Jalan	Sobel + GNB	70:30	Akurasi 88%, Presisi 96.8%, Recall 80.67%, F1 Score 88%

Berdasarkan Tabel 3, metode usulan Sobel dan Gaussian Naïve Bayes (GNB) menunjukkan keunggulan yang sangat kompetitif, terutama dari segi efisiensi data latih dan presisi deteksi. Jika dibandingkan dengan pendekatan *Deep Learning* mutakhir seperti YOLOv8-LF (Yi et al., 2024), metode usulan mampu mencapai tingkat presisi yang jauh melampaui metode tersebut (96,8% berbanding 84,5%). Selain itu, model YOLOv8-LF membutuhkan porsi data latih yang masif dengan rasio 90:10, sementara arsitektur GNB model mampu mencapai titik optimalnya hanya



dengan 70% data latih. Hal ini menunjukkan bahwa pendekatan probabilistik dapat menekan *False Positive* dengan sangat efektif tanpa memerlukan data yang besar.

Pada ranah klasifikasi konvensional, metode usulan juga mengungguli pengklasifikasi berbasis memori dan *ensemble*. Metode Sobel dan KNN hanya mampu menyentuh akurasi 80% meskipun menggunakan porsi data latih 90% (Damanik et al., 2023). Sementara itu, penerapan Sobel dengan *Random Forest* pada objek kompleks justru terpuruk dengan akurasi dan metrik keseluruhan di angka 52% hingga 56% (Kurniati & Pramana, 2023). Di sisi lain, meskipun metode Sobel dan SVM pada deteksi retakan dinding mencapai akurasi tertinggi sebesar 98,26% dengan rasio 80:20, tingginya angka tersebut harus dikompensasi dengan tambahan komputasi *cross-validation* karena memiliki kerentanan terhadap *over-fitting* seperti yang telah dibahas sebelumnya (Moghaddam et al., 2020). Dengan demikian, arsitektur hibrida Sobel dan GNB pada penelitian ini terbukti menawarkan keseimbangan (*trade-off*) terbaik antara efisiensi komputasi, kemandirian data, dan keandalan deteksi retakan jalan beton.

4. KESIMPULAN

Penelitian ini berhasil mengatasi keterbatasan efisiensi dan beban komputasi pada deteksi retakan jalan dengan mengintegrasikan deteksi tepi Sobel dan algoritma probabilistik *Gaussian Naïve Bayes* (GNB) sebagai model klasifikasi. Evaluasi komparatif pada berbagai skenario pembagian data menunjukkan bahwa hasil pembelajaran paling optimal tercapai pada rasio 70:30. Pada konfigurasi tersebut, model menghasilkan akurasi sebesar 88,00%, presisi 96,80%, *Recall* 80,67%, dan F1-Score 88,00%. Tingginya nilai presisi ini mengonfirmasi ketahanan model yang luar biasa dalam menekan kesalahan deteksi palsu (*false positive*). Hasil ini memperkuat bahwa algoritma GNB dengan deteksi tepi tradisional dapat memberikan kinerja yang optimal dan komputasi efisien untuk deteksi retakan jalan. Sebagai langkah penyempurnaan, penelitian ke depan dapat mengeksplorasi penggabungan fitur tekstur, seperti *Gray-Level Co-occurrence Matrix* (GLCM) untuk memperkuat Sobel dalam satu ruang fitur guna menangkap pola retakan yang lebih kompleks. Selain itu, pengujian model pada dataset citra dengan kondisi lingkungan yang lebih ekstrem sangat direkomendasikan untuk validasi dan meningkatkan ketahanan sistem di lingkungan dunia nyata.

DAFTAR PUSTAKA

- Anh, T., & Tam, M. (2022). *Stripping resistance evaluation of bead coating via Hamburg wheel tracking test and image analysis* *함부르크휠 시험과 이미지 분석을 통한 비드코트 탈리 저항성 평가*. 24(6), 47–52.
- Anjas, M. (2024). *Optimization of Classification Algorithms Performance with k-Fold Cross Validation*. 2.
- Bhat, S., & Szczuko, P. (2025). *Impact of canny edge detection preprocessing on performance of machine learning models for Parkinson 's disease classification*. 1–39.
- Bhatt, U., Mani, S., Xi, E., & Kolter, J. Z. (2017). *Intelligent Pothole Detection and Road Condition Assessment*. September. <http://arxiv.org/abs/1710.02595>
- Cha, Y. J., Choi, W., & Büyüköztürk, O. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361–378. <https://doi.org/10.1111/mice.12263>
- Chakurkar, P. S., Vora, D., Patil, S., & Kotecha, K. (2024). Automated crack localization for road safety using contextual u-net with spatial-channel feature integration. *MethodsX*, 13(March), 102796. <https://doi.org/10.1016/j.mex.2024.102796>
- Dong, L. (2025). *A Local Thresholding Algorithm for Image Segmentation by Using Gradient Orientation Histogram*. c.
- Fahmi, M., Yudhana, A., & Sunardi, S. (2023). Image Processing Using Morphology on Support Vector Machine Classification Model for Waste Image. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 22(3), 553–566. <https://doi.org/10.30812/matrik.v22i3.2819>
- Fereidoon, H. Z., Nejad, M., & Fahimifar, A. (2016). Image Based Techniques for Crack



- Detection , Classification and Quantification in Asphalt Pavement : A Review. *Archives of Computational Methods in Engineering*, 424. <https://doi.org/10.1007/s11831-016-9194-z>
- Fitriani, R. D., Yasin, H., & Tarno, T. (2021). PENANGANAN KLASIFIKASI KELAS DATA TIDAK SEIMBANG DENGAN RANDOM OVERSAMPLING PADA NAIVE BAYES (Studi Kasus: Status Peserta KB IUD di Kabupaten Kendal). *Jurnal Gaussian*, 10(1), 11–20. <https://doi.org/10.14710/j.gauss.v10i1.30243>
- Grace, O. E., C, A. D., & N, O. J. (2025). *Exploring the Effectiveness of Sobel , Canny , and Prewitt Edge Detection Algorithms on Digital Images*.
- Hasanah, Q., Oktavianto, H., & Rahayu, Y. D. (2022). Analisis Algoritma Gaussian Naive Bayes Terhadap Klasifikasi Data Pasien Penderita Gagal Jantung Gaussian Naive Bayes Algorithm Analysis Of Data Classification Of Heart Failure Patiens. *Jurnal Smart Teknologi*, 3(4), 2774–1702. <http://jurnal.unmuhjember.ac.id/index.php/JST>
- Islam, R., Devnath, M. K., Samad, M. D., & Jaffrey Al Kadry, S. M. (2022). GGNB: Graph-based Gaussian naive Bayes intrusion detection system for CAN bus. *Vehicular Communications*, 33(November). <https://doi.org/10.1016/j.vehcom.2021.100442>
- Khudhair, Zaid N., Ahmed Nidhal, Nidhal K. El Abbadi, Farhan Mohamed, Tanzila Saba, Faten S. Alamri, A. R. (2017). Color to Grayscale Image Conversion Based on Singular Value Decomposition. *IEEE Access*, xx. <https://doi.org/n: DOI 10.1109/ACCESS.2023.3279734>
- Kurniati, F. T., & Pramana, D. (2023). *Identifikasi Objek Menggunakan Random Forest dan Multi-Fitur*. 130–136.
- Kusumaningrum, J., Madenda, S., Karmilasari, & Nahdalina. (2022). Detection and Classification of Road Damage Based on Image Morphology and K-NN Method (K Nearest Neighbour). *International Journal of Engineering and Advanced Technology*, 11(5), 86–90. <https://doi.org/10.35940/ijeat.e3543.0611522>
- Ma, S., Khalil, A., Hajjdiab, H., & Eleuch, H. (2020). *Quantum Dilation and Erosion*. 1–13. <https://doi.org/10.3390/app10114040>
- Moghaddam, M. Z., Umili, G., Messina, V., Bonetto, S., Ferrero, A. M., Bollini, G., & Gandreau, D. (2020). *applied sciences An SVM-Based Scheme for Automatic Identification of Architectural Line Features and Cracks*.
- Mohan, A., & Poobal, S. (2018). Crack detection using image processing: A critical review and analysis. *Alexandria Engineering Journal*, 57(2), 787–798. <https://doi.org/10.1016/j.aej.2017.01.020>
- Mustolih, A., Arsi, P., Subarkah, P., Purwokerto, U. A., Info, A., Mining, D., Classifier, N. B., & Analysis, S. (2023). *Sentiment Analysis Motorku X using Applications Naive Bayes Classifier Method*. 6(2), 231–242.
- Oliveira, H., Correia, P. L., & Member, S. (2013). *and Characterization*. 14(1), 155–168.
- Damanik, S. T., Setiawan, A., Simanjuntak, T., & Tumanggor, A. (2023). *Analisis Deteksi Tepi untuk Mengidentifikasi Jenis Mobil*. 14(1), 103–109.
- Supiyandi Supiyandi, Trisatin Panggabean, Nuzul Ramadhan, Sri Ratna Dewi, & Salsabila Yusra. (2024). Deteksi Tepi Sederhana Pada Citra Menggunakan Operator Sobel. *Repeater: Publikasi Teknik Informatika Dan Jaringan*, 2(3), 43–56. <https://doi.org/10.62951/repeater.v2i3.90>
- Surya, A. A., & Yamasari, Y. (2024). Penerapan Algoritma Naive Bayes (NB) untuk Klasifikasi Penyakit Jantung. *Journal of Informatics and Computer Science (JINACS)*, 5(03), 447–455. <https://doi.org/10.26740/jinacs.v5n03.p447-455>
- Susanto, E. R., & Cahyana, A. (2025). Penerapan Algoritma XGBoost untuk Prediksi Diabetes: Analisis Confusion Matrix dan ROC Curve. *Fountain of Informatics Journal*, 10(1), 40–50. <https://doi.org/10.21111/fij.v10i1.14311>
- Tong Zhao, Junxiang He, Jingcheng Lv, Delei Min, Y. W. (2023). A Comprehensive Implementation of Road Surface Classification for Vehicle Driving Assistance: Dataset, Models, and Deployment. *IEEE Transactions on Intelligent Transportation Systems*, 24, 8361–8370. <https://doi.org/10.1109/TITS.2023.3264588>
- Xu, Y., Xia, Y., Zhao, Q., Yang, K., & Li, Q. (2024). A Road Crack Segmentation Method Based on Transformer and Multi-Scale Feature Fusion. *Electronics (Switzerland)*, 13(12), 1–21. <https://doi.org/10.3390/electronics13122257>
- Xu, Z., Guan, H., Kang, J., Lei, X., Ma, L., Yu, Y., Chen, Y., & Li, J. (2022). Pavement crack



detection from CCD images with a locally enhanced transformer network. *International Journal of Applied Earth Observation and Geoinformation*, 110(May), 102825. <https://doi.org/10.1016/j.jag.2022.102825>

Yi, B., Long, Q., Liu, H., Gong, Z., & Yu, J. (2024). A lightweight ground crack rapid detection method based on semantic enhancement. *Heliyon*, 10(14), e34782. <https://doi.org/10.1016/j.heliyon.2024.e34782>

Zou, Q., Zhang, Z., Li, Q., Qi, X., Wang, Q., & Wang, S. (2019). DeepCrack: Learning hierarchical convolutional features for crack detection. *IEEE Transactions on Image Processing*, 28(3), 1498–1512. <https://doi.org/10.1109/TIP.2018.2878966>

