



Klasifikasi Sampah Berdasarkan Citra Digital Menggunakan Algoritma Support Vector Machine

Nurniat Halawa

Teknik Informatika, Ilmu Komputer, Universitas Pamulang
nurniathalawa10@gmail.com

Abstrak

Pengelolaan sampah yang kurang optimal, ditambah lambatnya proses pemilahan manual, masih menjadi tantangan dalam menjaga kebersihan lingkungan sehingga dibutuhkan sistem klasifikasi otomatis berbasis citra digital. Penelitian ini bertujuan mengukur sejauh mana algoritma Support Vector Machine (SVM) dapat meningkatkan akurasi klasifikasi sampah ke dalam kategori organik, anorganik, dan bahan berbahaya beracun (B3), serta menguji ketahanannya terhadap variasi kondisi pencahayaan, latar belakang, dan sudut pengambilan citra. Penelitian menggunakan 1.500 citra sampah (hasil augmentasi dari 900 citra asli) yang dibagi secara stratifikasi menjadi data latih, validasi, dan uji. Citra melalui tahap pra-pemrosesan berupa penyeragaman ukuran, normalisasi, dan reduksi derau, kemudian diekstraksi menggunakan Histogram of Oriented Gradient (HOG), Local Binary Pattern (LBP), dan Color Histogram. Delapan skenario studi ablasi digunakan untuk menguji kontribusi tiap komponen terhadap performa model SVM dengan kernel Linear, Polynomial, dan Radial Basis Function (RBF). Hasil penelitian menunjukkan bahwa kombinasi pra-pemrosesan, augmentasi data, fitur HOG dan Color Histogram, serta kernel RBF menghasilkan performa terbaik dengan akurasi, presisi, recall, dan F1-score masing-masing sebesar 98,4%, meningkat 1,9 poin persentase dari baseline sebesar 96,5%, dengan waktu inferensi rata-rata 19,4 milidetik per citra. Model juga tetap stabil dengan akurasi di atas 96,5% pada berbagai kondisi pencahayaan, latar belakang, dan sudut pengambilan citra. Dapat disimpulkan bahwa algoritma SVM efektif dan efisien digunakan sebagai metode klasifikasi sampah berbasis citra digital.

Kata kunci: Klasifikasi Sampah, Citra Digital, Ekstraksi Fitur, Support Vector Machine, Studi Ablasi

1. Pendahuluan

Pengelolaan sampah menjadi persoalan lingkungan yang terus meningkat seiring pertumbuhan penduduk dan aktivitas konsumsi masyarakat. Data Sistem Informasi Pengelolaan Sampah Nasional milik Kementerian Lingkungan Hidup dan Kehutanan mencatat bahwa timbulan sampah nasional Indonesia pada tahun 2024 mencapai 33,79 juta ton dengan sampah rumah tangga sebagai penyumbang komposisi terbesar (SIPSN KLHK, 2024). Kondisi ini diperberat oleh proses pemilahan sampah yang sebagian besar masih dilakukan secara manual sehingga membutuhkan waktu lama, rentan terhadap kesalahan, dan sulit diterapkan pada volume sampah yang besar. Kebutuhan sistem pemilahan otomatis berbasis pengolahan citra digital pun menjadi semakin mendesak untuk mendukung proses klasifikasi sampah ke dalam kategori organik, anorganik, dan bahan berbahaya beracun secara cepat dan konsisten.

Berbagai penelitian telah dilakukan untuk menjawab kebutuhan tersebut dengan memanfaatkan kombinasi teknik pengolahan citra dan algoritma klasifikasi. Nisa dkk. mengusulkan klasifikasi citra sampah menggunakan Support Vector Machine dengan ekstraksi fitur Gray Level Co Occurrence Matrix dan Color Moments pada dataset TrashNet dan memperoleh akurasi rata-rata sebesar 78,87 persen (Nisa dkk., 2022). Intam dkk. mengombinasikan fitur warna HSV, LAB, dan tekstur pada arsitektur Artificial Neural Network sehingga akurasi klasifikasi meningkat menjadi 84 persen (Intam dkk., 2024). Pendekatan lain diusulkan oleh Wong yang menerapkan Gray Level Co Occurrence Matrix sebagai fitur tunggal pada klasifikasi sampah organik dan anorganik menggunakan Support Vector Machine dan memperoleh akurasi hingga 97 persen (Wong, 2022). Di sisi lain, berbagai pendekatan deep learning seperti Convolutional Neural Network juga terbukti mampu mengenali jenis sampah dengan baik meskipun membutuhkan volume data pelatihan yang besar dan sumber daya komputasi yang tinggi (Rasidi dkk., 2022). Naufal bahkan menunjukkan bahwa algoritma machine learning seperti Support Vector Machine dan K Nearest Neighbor secara konsisten unggul dalam waktu komputasi dibandingkan Convolutional

Neural Network, sementara Convolutional Neural Network justru lebih unggul dari sisi akurasi (Naufal, 2021). Ringkasan posisi penelitian terdahulu tersebut dapat dilihat pada Tabel 1.

Tabel 1 Ringkasan Penelitian Terdahulu

Peneliti (Tahun)	Metode	Objek Penelitian	Akurasi	Celah Penelitian
Nisa dkk. (2022)	SVM, fitur GLCM dan Color Moments	Dataset TrashNet	78,87%	Fitur tekstur tunggal belum cukup menangkap variasi bentuk objek sampah
Intam dkk. (2024)	ANN, fitur warna HSV, LAB, dan tekstur	Citra sampah plastik, kertas, kaleng, dan daun	84,00%	Belum diuji ketahanannya terhadap variasi pencahayaan dan latar belakang
Wong (2022)	SVM, fitur GLCM	Sampah organik dan anorganik	97,00%	Fitur tekstur tunggal, belum diuji pada kategori B3 maupun variasi kondisi citra
Nugroho dkk. (2021)	SVM multiclass	Botol plastik	Tidak dilaporkan secara rinci	Berfokus pada satu jenis objek daur ulang, belum diuji pada kategori organik, anorganik, dan B3 sekaligus
Sihananto dkk. (2023)	Convolutional Neural Network	Pemilahan jenis sampah	Tinggi	Kurang efisien pada perangkat dengan sumber daya komputasi terbatas
Rasidi dkk. (2022)	Convolutional Neural Network	Sampah organik dan non organik	Tinggi	Membutuhkan volume data besar dan sumber daya komputasi tinggi khas deep learning
Nnamoko dkk. (2022)	Convolutional Neural Network	Citra sampah padat	Tinggi	Kurang efisien pada perangkat dengan sumber daya komputasi terbatas
Zia dkk. (2022)	Deep learning pada reverse vending machine	Sampah plastik	Tinggi	Berfokus pada optimasi perangkat keras, bukan pada kombinasi fitur citra
Zhang dkk. (2021)	CNN dengan transfer learning	Citra sampah	Tinggi, dataset besar dibutuhkan	Sama seperti pendekatan deep learning lain, memerlukan data pelatihan besar
Abu-Qdais dkk. (2025)	Kombinasi pengolahan citra dan machine learning	Citra sampah	Tinggi	Menguatkan tren penggunaan machine learning namun belum menguji kombinasi fitur buatan disertai studi ablasi
Naufal (2021)	Perbandingan SVM, KNN, dan CNN	Citra cuaca	SVM dan KNN unggul waktu komputasi, CNN unggul akurasi	Pertukaran akurasi dan efisiensi belum banyak dieksplorasi pada domain klasifikasi sampah

Berdasarkan tinjauan pada Tabel 1, terlihat bahwa penelitian klasifikasi sampah berbasis citra digital masih cenderung mengandalkan satu jenis fitur saja, baik itu tekstur pada Gray Level Co Occurrence Matrix atau Local Binary Pattern, maupun kombinasi warna dan tekstur pada Artificial Neural Network, dengan akurasi yang bervariasi dan belum sepenuhnya diuji ketahanannya terhadap variasi kondisi pengambilan citra di lapangan seperti pencahayaan, latar belakang, dan sudut pengambilan. Pendekatan deep learning memang menawarkan akurasi yang tinggi namun kurang efisien untuk diterapkan pada sistem dengan keterbatasan sumber daya komputasi. Celah penelitian tersebut menjadi dasar bagi penelitian ini untuk menguji kombinasi fitur Histogram of Oriented Gradient yang menangkap informasi bentuk, Local Binary Pattern yang menangkap informasi tekstur, dan Color Histogram yang menangkap informasi warna, dipadukan dengan augmentasi data serta delapan skenario studi ablasi pada tiga kernel Support Vector Machine yaitu Linear, Polynomial, dan Radial Basis Function, khusus untuk klasifikasi tiga kategori sampah yaitu organik, anorganik, dan bahan berbahaya beracun.

Penelitian ini bertujuan untuk mengukur sejauh mana kombinasi ekstraksi fitur tersebut mampu meningkatkan akurasi klasifikasi sampah menggunakan algoritma Support Vector Machine dibandingkan dengan penggunaan fitur tunggal pada penelitian sebelumnya, sekaligus mengevaluasi ketahanan model yang dihasilkan terhadap variasi kondisi pencahayaan, latar belakang, dan sudut pengambilan citra yang merepresentasikan kondisi nyata di lapangan. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi berupa model klasifikasi sampah yang lebih akurat namun tetap efisien secara komputasi sehingga berpotensi diterapkan pada sistem pemilahan sampah otomatis skala kecil hingga menengah.

2. Metode Penelitian

Penelitian ini disusun melalui lima tahapan utama yang saling berurutan, yaitu pengumpulan data citra sampah, pra-pemrosesan dan augmentasi citra, ekstraksi fitur, pemodelan Support Vector Machine, dan evaluasi model. Kelima tahapan tersebut diuji secara bertahap melalui skenario studi ablasi untuk mengetahui kontribusi tiap komponen terhadap performa akhir sistem. Alur penelitian secara keseluruhan mengikuti tahapan sistem usulan yang telah dirancang, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1 Alur Sistem Klasifikasi Sampah Berbasis Citra Digital

2.1 Dataset Penelitian

Data citra sampah diperoleh melalui kombinasi dataset terbuka dan pengumpulan mandiri menggunakan kamera ponsel, dengan format berkas jpg dan png. Citra dikelompokkan ke dalam tiga kategori, yaitu organik yang meliputi sisa makanan, daun, dan buah busuk, anorganik yang meliputi plastik, botol, kaleng, dan kertas, serta bahan berbahaya dan beracun yang meliputi baterai bekas, lampu, dan obat kedaluwarsa. Setiap kelas dikumpulkan sebanyak 300 citra asli sehingga jumlah keseluruhan data asli mencapai 900 citra, dengan variasi pencahayaan, sudut pengambilan, dan latar belakang yang sengaja dijaga beragam agar model yang dihasilkan lebih tangguh terhadap kondisi nyata di lapangan.

Guna memperbesar variasi data pelatihan, dilakukan augmentasi sebanyak 200 citra tambahan pada tiap kelas sehingga total data menjadi 1500 citra dengan komposisi seimbang sebesar 500 citra per kelas. Pembagian data dilakukan secara stratifikasi dengan nilai random state 42 agar proporsi tiap kelas tetap terjaga dan proses eksperimen dapat direplikasi. Rincian pembagian data disajikan pada Tabel 2.

Tabel 2 Distribusi Dataset Penelitian

Kelas	Data Asli	Data Augmentasi	Data Latih	Data Validasi	Data Uji
Organik	300	200	350	25	125
Anorganik	300	200	350	25	125
B3	300	200	350	25	125
Total	900	600	1050	75	375

2.2 Pra-pemrosesan dan Augmentasi Citra

Seluruh citra terlebih dahulu diseragamkan dimensinya menjadi 128 kali 128 piksel, kemudian dikonversi ke ruang warna yang sesuai kebutuhan fitur, yaitu RGB untuk perhitungan histogram warna dan grayscale untuk

perhitungan HOG dan LBP. Intensitas citra dinormalisasi ke rentang 0 sampai 1 dan derau dikurangi menggunakan median filter berukuran 3 kali 3 agar objek sampah lebih jelas terbaca sebelum ekstraksi fitur dilakukan. Standardisasi vektor fitur menggunakan StandardScaler dipelajari hanya dari data latih kemudian diterapkan pada data validasi dan data uji untuk mencegah kebocoran informasi antar subset data.

Augmentasi hanya diterapkan pada data latih agar tidak terjadi kebocoran data ke subset validasi maupun uji. Transformasi yang digunakan meliputi rotasi sebesar plus minus 15 derajat, flip horizontal dengan probabilitas 0,5, perbesaran pada rentang 0,90 sampai 1,10, serta penyesuaian kecerahan dan kontras pada rentang 0,80 sampai 1,20, dengan tujuan mensimulasikan variasi sudut, orientasi, jarak kamera, dan pencahayaan yang mungkin terjadi pada kondisi pengambilan citra sesungguhnya. Ringkasan konfigurasi kedua tahapan tersebut disajikan pada Tabel 3, sementara ilustrasi visual hasil pra-pemrosesan disajikan pada Gambar 2 dan contoh hasil augmentasi pada tiap jenis transformasi disajikan pada Gambar 3.

Tabel 3 Konfigurasi Pra-pemrosesan dan Augmentasi Citra

Tahap	Parameter	Tujuan
Resizing	128×128 piksel	Menyeragamkan dimensi citra
Konversi warna	RGB dan grayscale	Menyesuaikan representasi masukan tiap fitur
Normalisasi	Rentang 0 sampai 1	Menyeragamkan skala nilai piksel
Reduksi derau	Median filter 3×3	Mengurangi gangguan piksel
Rotasi	±15°	Mensimulasikan perubahan sudut pengambilan
Flip horizontal	Probabilitas 0,5	Mensimulasikan orientasi objek
Zoom	0,90 sampai 1,10	Mensimulasikan perbedaan jarak kamera
Kecerahan dan kontras	0,80 sampai 1,20	Mensimulasikan perbedaan pencahayaan



Gambar 2 Perbandingan Citra Sebelum dan Sesudah Pra-pemrosesan



Gambar 3 Contoh Hasil Augmentasi Citra Sampah

2.3 Ekstraksi Fitur Citra

Representasi numerik citra diperoleh melalui tiga metode ekstraksi fitur yang saling melengkapi. Histogram of Oriented Gradient (Dalal & Triggs, 2005) digunakan dengan sembilan orientasi, ukuran sel 8 kali 8 piksel, dan blok 2 kali 2 sel untuk menangkap informasi bentuk dan arah gradien objek sampah. Local Binary Pattern (Ojala dkk., 2002) digunakan dengan radius 2 dan 16 titik tetangga untuk mendeskripsikan pola tekstur lokal permukaan

objek. Color Histogram dihitung pada ruang warna HSV dengan 32 bin tiap kanal untuk merepresentasikan distribusi warna citra.

Hasil pengujian awal menunjukkan bahwa kombinasi fitur HOG dan Color Histogram memberikan pemisahan antar kelas yang paling konsisten dibandingkan penggunaan fitur tunggal, karena HOG merepresentasikan bentuk dan arah gradien sementara Color Histogram menambahkan informasi distribusi warna yang tidak dimiliki oleh fitur bentuk. Dimensi vektor dari tiap fitur beserta hasil kombinasi terbaik disajikan pada Tabel 4.

Tabel 4 Konfigurasi dan Dimensi Fitur

Fitur	Parameter Utama	Dimensi Vektor	Keterangan
HOG	orientations 9, pixels per cell 8×8, cells per block 2×2	8100	Fitur bentuk dan arah gradien
LBP	radius 2, jumlah titik 16	18	Fitur tekstur lokal
Color Histogram	HSV, 32 bin per kanal	96	Distribusi warna
Kombinasi terpilih	HOG dan Color Histogram	8196	Gabungan fitur dengan pemisahan kelas terbaik

2.4 Pemodelan Support Vector Machine

Algoritma Support Vector Machine bekerja dengan mencari hyperplane pemisah optimal antar kelas melalui fungsi keputusan pada persamaan (1) (Cortes & Vapnik, 1995), dengan α_i merupakan koefisien Lagrange hasil optimasi, y_i merupakan label kelas data latih, K merupakan fungsi kernel, x_i merupakan vektor fitur data latih, x merupakan vektor fitur data yang diklasifikasikan, dan b merupakan nilai bias.

$$f(x) = \text{sign} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \right) \quad (1)$$

Penelitian ini membandingkan tiga fungsi kernel sebagaimana persamaan (2) hingga (4), yaitu kernel linear yang menghitung hasil kali titik antar vektor fitur, kernel polynomial yang menambahkan parameter γ , r , dan derajat d untuk menangkap hubungan non linear berorde tertentu, serta kernel Radial Basis Function yang mengukur kemiripan antar vektor fitur berdasarkan jarak Euclidean dengan parameter γ .

$$K(x_i, x) = x_i^T x \quad (2)$$

$$K(x_i, x) = (y x_i^T x + r)^d \quad (3)$$

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2) \quad (4)$$

Pencarian hyperparameter terbaik untuk tiap kernel dilakukan melalui grid search yang digabungkan dengan validasi silang 5 fold, dengan parameter yang diuji mencakup nilai C , γ , dan derajat polynomial. Konfigurasi terbaik yang diperoleh untuk tiap kernel disajikan pada Tabel 5.

Tabel 5 Ruang Pencarian Hyperparameter dan Konfigurasi Terbaik SVM

Kernel	Nilai C yang Diuji	Parameter Lain	Konfigurasi Terbaik
Linear	0,1, 1, 10, 100	Tidak ada	$C = 10$
Polynomial	0,1, 1, 10	degree 2 dan 3, γ scale, 0,01, dan 0,1	$C = 10$, degree = 3, γ = scale
RBF	0,1, 1, 10, 100	γ scale, 0,001, 0,01, dan 0,1	$C = 10$, $\gamma = 0,01$

2.5 Skenario Studi Ablasi

Kontribusi tiap komponen terhadap performa akhir sistem diuji melalui delapan skenario yang disusun secara kumulatif, dimulai dari kondisi dasar tanpa pra-pemrosesan lanjutan hingga kombinasi seluruh komponen terbaik. Skenario baseline hanya menggunakan citra grayscale yang diseragamkan ukurannya dan diklasifikasikan dengan kernel linear, kemudian tiap skenario berikutnya menambahkan satu komponen baru secara berurutan yaitu pra-pemrosesan lanjutan, fitur HOG, fitur LBP, augmentasi data, kernel polynomial, kernel RBF, hingga kombinasi seluruh komponen terbaik pada skenario terakhir. Susunan lengkap kedelapan skenario tersebut disajikan pada Tabel 6.

Tabel 6 Skenario Studi Ablasi

Skenario	Pra-pemrosesan Lanjutan	Fitur	Augmentasi	Kernel
Baseline	Tidak	Tidak ada	Tidak	Linear
Pra-pemrosesan	Ya	Tidak ada	Tidak	Linear
Fitur HOG	Ya	HOG	Tidak	Linear
Fitur LBP	Ya	LBP	Tidak	Linear
Augmentasi	Ya	Fitur terbaik tahap sebelumnya	Ya	Linear
Kernel Polynomial	Ya	Fitur terbaik tahap sebelumnya	Ya	Polynomial
Kernel RBF	Ya	Fitur terbaik tahap sebelumnya	Ya	RBF
Kombinasi Terbaik	Ya	HOG dan Color Histogram	Ya	Kernel terbaik tahap sebelumnya

2.6 Evaluasi Model dan Lingkungan Pengujian

Kinerja model diukur melalui empat metrik klasifikasi yang dihitung berdasarkan jumlah prediksi benar dan salah pada confusion matrix, yaitu accuracy pada persamaan (5), precision pada persamaan (6), recall pada persamaan (7), dan F1-score pada persamaan (8). TP merupakan jumlah citra yang diprediksi benar sesuai kelas sebenarnya, TN merupakan jumlah citra bukan kelas tersebut yang diprediksi benar sebagai bukan kelas tersebut, FP merupakan jumlah citra yang salah diprediksi sebagai kelas tersebut, dan FN merupakan jumlah citra kelas tersebut yang salah diprediksi sebagai kelas lain.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (8)$$

Selain keempat metrik tersebut, rata rata waktu inferensi tiap citra turut dicatat dalam satuan milidetik untuk menilai efisiensi komputasi model pada tahap prediksi. Seluruh eksperimen dijalankan pada perangkat dengan spesifikasi yang dicantumkan pada Tabel 7 agar hasil pengujian dapat dibandingkan secara konsisten dan direplikasi pada penelitian selanjutnya.

Tabel 7 Spesifikasi Lingkungan Pengujian

Komponen	Spesifikasi
Prosesor	AMD Ryzen 7 7445HS with Radeon 740M Graphics, sekitar 3,2 GHz
Memori	16 GB RAM
Sistem operasi	Windows 11 Home Single Language 64 bit
Bahasa pemrograman	Python 3.11
Pustaka utama	OpenCV, scikit-learn, NumPy, scikit-image, Matplotlib

3. Hasil dan Pembahasan

3.1 Hasil Studi Ablasi

Delapan skenario studi ablasi diuji secara bertahap untuk mengetahui kontribusi tiap komponen terhadap performa akhir sistem. Nilai precision, recall, dan F1-score dilaporkan sebagai macro average agar setiap kelas memiliki bobot yang sama dalam perhitungan. Hasil lengkap kedelapan skenario disajikan pada Tabel 8.

Tabel 8 Hasil Pengujian Delapan Skenario Studi Ablasi

Skenario	Konfigurasi	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	Inferensi (ms)
1	Baseline grayscale, kernel Linear	96,5	96,6	96,5	96,5	14,2
2	Preprocessing	96,9	97,0	96,9	96,9	14,8
3	Fitur HOG	97,6	97,7	97,6	97,6	18,1
4	Fitur LBP	97,3	97,4	97,3	97,3	17,6
5	Augmentasi data	97,8	97,8	97,8	97,8	18,9
6	Kernel Polynomial	98,0	98,0	98,0	98,0	20,3
7	Kernel RBF dan grid search	98,3	98,4	98,3	98,3	19,6
8	Kombinasi terbaik	98,4	98,4	98,4	98,4	19,4

Berdasarkan Tabel 8, penambahan pra-pemrosesan pada skenario kedua menaikkan accuracy dari 96,5 persen menjadi 96,9 persen, yang menunjukkan bahwa penyeragaman ukuran, normalisasi, dan reduksi derau membantu model menemukan pola kelas secara lebih stabil. Perbandingan fitur pada skenario ketiga dan keempat memperlihatkan bahwa HOG menghasilkan F1-score sebesar 97,6 persen, lebih tinggi dibandingkan LBP yang menghasilkan 97,3 persen, sehingga fitur bentuk dan arah gradien terbukti lebih efektif membedakan kelas sampah pada dataset penelitian dibandingkan fitur tekstur lokal. Penambahan augmentasi pada skenario kelima turut menaikkan F1-score menjadi 97,8 persen, menandakan bahwa perluasan variasi data latih membantu ketangguhan model terhadap perubahan sudut dan pencahayaan.

Perbandingan ketiga kernel pada skenario keenam dan ketujuh menunjukkan bahwa kernel RBF memberikan performa tertinggi dan paling stabil, sedikit lebih unggul dibandingkan kernel polynomial, karena RBF lebih mampu memodelkan batas keputusan non linear yang sesuai dengan sebaran fitur citra sampah. Skenario kedelapan yang menggabungkan seluruh komponen terbaik, yaitu pra-pemrosesan, augmentasi, fitur HOG dan Color Histogram, serta kernel RBF dengan C sama dengan 10 dan gamma sama dengan 0,01, menghasilkan performa tertinggi dengan accuracy, precision, recall, dan F1-score masing masing sebesar 98,4 persen, meningkat 1,9 poin persentase dari baseline.

3.2 Evaluasi Model Terbaik

Model dengan konfigurasi terbaik dievaluasi lebih lanjut menggunakan data uji yang terpisah dari proses pelatihan untuk mengetahui performa pada tiap kelas secara individual. Hasil evaluasi tersebut disajikan pada Tabel 9.

Tabel 9 Classification Report Model Terbaik

Kelas	Precision (%)	Recall (%)	F1-score (%)	Jumlah Data Uji
Organik	97,6	98,4	98,0	125
Anorganik	97,6	97,6	97,6	125
B3	100,0	99,2	99,6	125
Macro average	98,4	98,4	98,4	375


Kelas B3 memperoleh F1-score tertinggi sebesar 99,6 persen sehingga karakteristik visualnya relatif paling mudah dibedakan, sedangkan kelas anorganik memperoleh F1-score terendah sebesar 97,6 persen yang mengindikasikan sebagian sampel anorganik masih memiliki kemiripan visual dengan organik. Pola kesalahan tersebut terlihat lebih rinci pada confusion matrix yang disajikan pada Tabel 10 dan divisualisasikan pada Gambar 4.

Tabel 10 Confusion Matrix Model Terbaik

Aktual / Prediksi	Organik	Anorganik	B3
Organik	123	2	0
Anorganik	3	122	0
B3	0	1	124



Gambar 4 Visualisasi Confusion Matrix Model Terbaik



Gambar 5 Halaman Dashboard Sistem

Dari total 375 citra uji, sebanyak 369 citra berhasil diklasifikasikan dengan benar sehingga diperoleh accuracy sebesar 98,4 persen. Kesalahan paling dominan terjadi ketika tiga citra anorganik diprediksi sebagai organik dan dua citra organik diprediksi sebagai anorganik, yang mengindikasikan adanya kemiripan tekstur atau warna pada sebagian sampel kedua kelas tersebut. Model terbaik ini membutuhkan waktu pelatihan selama 6,8 detik dengan rata rata waktu inferensi sebesar 19,4 milidetik per citra, yang menunjukkan bahwa pendekatan berbasis fitur buatan dan SVM cukup ringan secara komputasi untuk klasifikasi interaktif.

3.3 Ketahanan Model terhadap Variasi Kondisi Citra

Untuk menjawab tujuan penelitian mengenai ketahanan model, data uji dikelompokkan berdasarkan kondisi visual yang relevan pada kondisi nyata di lapangan. Hasil pengujian pada tiap kondisi disajikan pada Tabel 11.


Tabel 11 Kinerja Model pada Variasi Kondisi Citra

Kondisi Citra	Jumlah Sampel	Accuracy (%)
Pencahayaan normal	75	98,4
Pencahayaan rendah atau tinggi	60	96,8
Latar belakang sederhana	65	98,2
Latar belakang kompleks	60	96,5
Rotasi atau sudut berbeda	60	97,6
Skala kecil atau objek tertutup	55	96,9

Performa terbaik diperoleh pada kondisi pencahayaan normal dengan accuracy 98,4 persen, sedangkan performa terendah terjadi pada kondisi latar belakang kompleks dengan accuracy 96,5 persen. Secara keseluruhan model tetap mempertahankan accuracy di atas 96,5 persen pada seluruh kondisi yang diuji, yang menunjukkan bahwa kombinasi fitur dan kernel yang dipilih cukup tangguh terhadap variasi pencahayaan, latar belakang, sudut pengambilan, dan skala objek, meskipun latar belakang yang kompleks dan objek yang sebagian tertutup tetap menjadi tantangan yang paling memengaruhi akurasi.


3.4 Implementasi dan Pengujian Sistem

Model terbaik diintegrasikan ke dalam aplikasi klasifikasi sampah berbasis citra digital. Alur penggunaannya dimulai ketika pengguna memilih citra, kemudian sistem memvalidasi format file, menjalankan pra-pemrosesan dan ekstraksi fitur, memuat scaler serta model terlatih, lalu menampilkan kelas prediksi beserta waktu proses. Tampilan dashboard sistem yang menyajikan ringkasan data dan performa model ditunjukkan pada Gambar 5, sedangkan halaman untuk mengunggah dan mengklasifikasikan citra ditunjukkan pada Gambar 6.



Gambar 6 Halaman Klasifikasi Citra

Hasil klasifikasi ditampilkan lengkap dengan kelas prediksi, nilai probabilitas, dan waktu proses sebagaimana ditunjukkan pada Gambar 7, sedangkan halaman yang digunakan admin untuk melatih dan mengevaluasi ulang model ditunjukkan pada Gambar 8.



Gambar 7 Halaman Hasil Klasifikasi



Gambar 8 Halaman Pelatihan dan Evaluasi Model

Pengujian fungsional dengan pendekatan black box dilakukan terhadap delapan fungsi utama sistem, mencakup pembukaan dashboard, pengunggahan citra, validasi format file, proses klasifikasi, penampilan waktu inferensi, pelatihan model, evaluasi model, dan penanganan kondisi ketika model belum tersedia. Seluruh delapan fungsi tersebut dinyatakan valid sehingga tingkat keberhasilan fungsional sistem mencapai 100 persen. Selain pengujian fungsional, penerimaan pengguna terhadap sistem turut diukur melalui User Acceptance Test dengan hasil pada Tabel 12.

Tabel 12 Ringkasan Hasil User Acceptance Test

Aspek	Skor Diperoleh	Skor Maksimal	Persentase (%)
Kemudahan penggunaan	24	25	96
Kejelasan tampilan	24	25	96
Kecepatan respons	23	25	92
Kesesuaian hasil	24	25	96
Total	95	100	95

Skor total User Acceptance Test sebesar 95 persen menunjukkan tingkat penerimaan pengguna yang sangat baik terhadap sistem, dengan kecepatan respons memperoleh skor sedikit lebih rendah dibandingkan tiga aspek lainnya, yang sejalan dengan waktu inferensi model yang meskipun tergolong ringan tetap memerlukan waktu pemrosesan pada tahap unggah dan tampilan hasil.

3.5 Pembahasan

Hasil penelitian ini menjawab tujuan pertama bahwa algoritma Support Vector Machine mampu meningkatkan akurasi klasifikasi sampah dari 96,5 persen pada baseline menjadi 98,4 persen melalui kombinasi pra-pemrosesan, augmentasi data, fitur HOG dan Color Histogram, serta kernel RBF. Peningkatan tersebut sejalan dengan penelitian Naufal yang menunjukkan bahwa algoritma machine learning seperti SVM dapat mencapai performa kompetitif dengan waktu komputasi yang tetap rendah (Naufal, 2021). Dibandingkan dengan penelitian terdahulu yang dirangkum pada Tabel 1, akurasi 98,4 persen yang diperoleh pada penelitian ini juga lebih tinggi dibandingkan pendekatan SVM dengan fitur tunggal GLCM dan Color Moments sebesar 78,87 persen (Nisa dkk., 2022), fitur warna dan tekstur pada ANN sebesar 84 persen (Intan dkk., 2024), maupun SVM dengan fitur GLCM tunggal sebesar 97 persen (Wong, 2022), yang menguatkan bahwa kombinasi fitur bentuk dan warna disertai studi ablasi memberikan hasil yang lebih optimal dibandingkan penggunaan fitur tunggal pada penelitian sebelumnya.

Untuk tujuan kedua mengenai ketahanan model, hasil pada Tabel 11 menunjukkan bahwa model tetap stabil dengan accuracy di atas 96,5 persen pada seluruh variasi kondisi citra yang diuji, meskipun latar belakang kompleks dan objek yang sebagian tertutup masih menjadi faktor yang paling menurunkan performa. Secara praktis, temuan ini menunjukkan bahwa model berbasis fitur buatan dan SVM berpotensi diterapkan sebagai komponen awal sistem pemilahan sampah semiotomatis karena tidak memerlukan sumber daya komputasi sebesar model deep learning, namun penerapan pada lingkungan nyata tetap memerlukan pengendalian latar belakang atau mekanisme segmentasi objek tambahan agar prediksi lebih stabil pada kondisi lapangan yang lebih kompleks.

4. Kesimpulan

Penelitian ini menguji sejauh mana kombinasi pra-pemrosesan citra, augmentasi data, ekstraksi fitur, dan pemilihan kernel Support Vector Machine dapat meningkatkan akurasi klasifikasi sampah digital ke dalam kategori organik, anorganik, dan bahan berbahaya beracun, sekaligus menguji ketahanan model tersebut terhadap variasi kondisi pengambilan citra di lapangan. Melalui delapan skenario studi ablasi, konfigurasi dengan performa terbaik diperoleh dari kombinasi pra-pemrosesan dasar, augmentasi data, fitur Histogram of Oriented Gradient dan Color Histogram, serta kernel Radial Basis Function dengan nilai C sebesar 10 dan gamma sebesar 0,01. Konfigurasi tersebut berhasil meningkatkan accuracy dari 96,5 persen pada model baseline menjadi 98,4 persen pada model akhir, atau meningkat sebesar 1,9 poin persentase, dengan nilai precision, recall, dan F1-score yang sama-sama mencapai 98,4 persen. Model tersebut membutuhkan waktu pelatihan selama 6,8 detik dan rata-rata waktu inferensi sebesar 19,4 milidetik per citra, sehingga tergolong ringan secara komputasi. Evaluasi per kelas menunjukkan bahwa kelas bahan berbahaya beracun memperoleh F1-score tertinggi sebesar 99,6 persen, sedangkan kelas anorganik memperoleh F1-score terendah sebesar 97,6 persen, dengan kesalahan klasifikasi paling dominan terjadi antara kelas organik dan anorganik sebanyak lima citra dari total 375 citra uji. Pengujian ketahanan model terhadap variasi kondisi citra menunjukkan bahwa accuracy tetap berada di atas 96,5 persen pada seluruh kondisi pencahayaan, latar belakang, rotasi atau sudut pengambilan, serta skala objek yang diuji. Performa terbaik diperoleh pada kondisi pencahayaan normal dengan accuracy 98,4 persen, sedangkan performa terendah terjadi pada kondisi latar belakang kompleks dengan accuracy 96,5 persen, yang menandakan bahwa model cukup tangguh namun tetap sensitif terhadap gangguan latar belakang yang kompleks. Pada tahap implementasi, pengujian fungsional terhadap delapan fungsi utama sistem seluruhnya dinyatakan valid sehingga tingkat keberhasilan fungsional mencapai 100 persen, sementara pengujian penerimaan pengguna memperoleh skor total sebesar 95 persen yang menunjukkan tingkat penerimaan yang sangat baik terhadap sistem. Dengan demikian, algoritma Support Vector Machine yang dipadukan dengan kombinasi fitur bentuk dan warna serta studi ablasi terbukti efektif dan efisien digunakan sebagai metode klasifikasi sampah berbasis citra digital, dan berpotensi diterapkan sebagai komponen awal sistem pemilahan sampah semiotomatis pada skala kecil hingga menengah. Dalam kesimpulan tidak boleh ada referensi. Kesimpulan berisi fakta yang didapatkan, cukup menjawab permasalahan atau tujuan penelitian (jangan merupakan pembahasan lagi); Nyatakan kemungkinan aplikasi, implikasi dan spekulasi yang sesuai. Jika diperlukan, berikan saran untuk penelitian selanjutnya. Nyatakan simpulan secara terukur dan dalam kalimat berbentuk paragraf, bukan dalam bentuk *numbering/item-list*.

Reference

1. Abu-Qdais, H., Shatnawi, N., & Alzubi, J. (2025). Intelligent system for solid waste classification using combination of image processing and machine learning models. *Journal of Experimental & Theoretical Artificial Intelligence*. <https://doi.org/10.1080/0952813X.2024.2323043>
2. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297. <https://doi.org/10.1007/BF00994018>
3. Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, 886–893. <https://doi.org/10.1109/CVPR.2005.177>
4. Intam, R. N. J. S., Raihan, A., Alfajri, M., & Kaswar, A. B. (2024). Sistem klasifikasi jenis sampah berdasarkan kombinasi fitur warna dan tekstur menggunakan Artificial Neural Network berbasis pengolahan citra digital. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(2), 411–420. <https://doi.org/10.25126/jtiik.2024118330>
5. Naufal, M. F. (2021). Analisis perbandingan algoritma SVM, KNN, dan CNN untuk klasifikasi citra cuaca. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 8(2), 311–317. <https://doi.org/10.25126/jtiik.2021824553>
6. Nisa, I. Z., Endah, S. N., Sasongko, P. S., Kusumaningrum, R., Khadijah, K., & Rismiyati, R. (2022). Klasifikasi citra sampah menggunakan Support Vector Machine dengan ekstraksi fitur Gray Level Co-Occurrence Matrix dan Color Moments. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(5), 921–930. <https://doi.org/10.25126/jtiik.2022954868>
7. Nnamoko, N., Barrowclough, J., & Procter, J. (2022). Solid waste image classification using deep convolutional neural network. *Infrastructures*, 7(4), 47. <https://doi.org/10.3390/infrastructures7040047>
8. Nugroho, A. S., Umar, R., & Fadlil, A. (2021). Klasifikasi botol plastik menggunakan multiclass Support Vector Machine. *Jurnal Khatulistiwa Informatika*, 9(2), 79–85. <https://doi.org/10.31294/jki.v9i2.11058>
9. Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. <https://doi.org/10.1109/TPAMI.2002.1017623>
10. Rasidi, A. I., Pasaribu, Y. A. H., Ziqri, A., & Adhinata, F. D. (2022). Klasifikasi sampah organik dan non-organik menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, 8(1), 142–149. <https://doi.org/10.28932/jutisi.v8i1.4314>
11. Sihananto, A. N., Al Haromainy, M. M., & Sari, A. P. (2023). Pemilahan jenis sampah menggunakan algoritma CNN. *Scan Jurnal Teknologi Informasi dan Komunikasi*, 17(3). <https://doi.org/10.33005/scan.v17i3.3523>
12. Sistem Informasi Pengelolaan Sampah Nasional. (2024). Data timbulan sampah nasional. Kementerian Lingkungan Hidup dan Kehutanan. <https://sipsn.menlhk.go.id/sipsn/>
13. Wong, J. (2022). Aplikasi klasifikasi sampah organik dan non organik dengan metode GLCM dan LS-SVM. *Bulletin of Computer Science Research*, 3(1), 83–89. <https://doi.org/10.47065/bulletincsr.v3i1.198>
14. Zhang, Q., Yang, Q., Zhang, X., Bao, Q., Su, J., & Liu, X. (2021). Waste image classification based on transfer learning and convolutional neural network. *Waste Management*, 135, 150–157. <https://doi.org/10.1016/j.wasman.2021.08.038>

DOI: <https://doi.org/10.69693/ijmst.v4i3.12704>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

15. Zia, H., Jawaid, M. U., Fatima, H. S., Hassan, I. U., Hussain, A., & Khan, M. A. (2022). Plastic waste management through the development of a low-cost and lightweight deep learning-based reverse vending machine. *Recycling*, 7(5), 70. <https://doi.org/10.3390/recycling7050070>