



Klasifikasi Botol Plastik dan Kaleng Minuman Menggunakan Metode *Support Vector Machine*

Hidayanthi Dwi Puja, Ayunisa Yasmin, Erizka Nia Ramadhani, Caerur Rozikin

Program Studi Informatika S1, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang Indonesia

2310631170020@student.unsika.ac.id, 2310631170008@student.unsika.ac.id, 2310631170014@student.unsika.ac.id,
chaerur.rozikin@staff.unsika.ac.id

Abstrak

Pengelolaan sampah anorganik, khususnya material botol plastik dan kaleng minuman, merupakan tantangan lingkungan yang membutuhkan solusi otomatisasi pemilahan cerdas berbasis pengolahan citra digital. Pemilahan manual yang selama ini diterapkan dinilai kurang efisien. Penelitian ini mengusulkan sistem klasifikasi citra sampah menggunakan algoritma *Support Vector Machine* (SVM) dengan pendekatan ekstraksi fitur gabungan (*feature fusion*). Untuk mengatasi bias model akibat ketidakseimbangan data (*data imbalance*), dataset *Bottles and Cans* diseimbangkan secara proporsional. Pipeline sistem mencakup prapemrosesan menggunakan filter Gaussian Blur untuk mereduksi noise, serta segmentasi Otsu Thresholding untuk memisahkan objek dari latar belakang. Fitur yang diekstraksi meliputi morfologi, statistik warna HSV, serta tekstur Gray-Level Co-occurrence Matrix (GLCM) yang menghasilkan 96 dimensi representasi objek. Optimasi hyperparameter model dilakukan melalui GridSearchCV dengan skema 5-fold Cross-Validation. Hasil pengujian pada data uji menunjukkan bahwa model SVM dengan kernel RBF ($C=10$, $\text{Gamma}=\text{'scale'}$) mencapai akurasi sebesar 93,33%, dengan F1-Score 93,41% dan ROC-AUC 0,981. Temuan ini mengonfirmasi bahwa kombinasi *handcrafted features* yang dioptimasi mampu memberikan performa klasifikasi yang tangguh dan efisien untuk diimplementasikan pada sistem pemilahan sampah otomatis skala menengah.

Kata kunci: *Bottles and Cans*, Ekstraksi Fitur, GLCM, Pengolahan Citra, *Support Vector Machine*.

1. Latar Belakang

Pengelolaan sampah anorganik masih menjadi persoalan lingkungan yang belum terselesaikan di Indonesia. Data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) tahun 2022 menunjukkan bahwa total timbunan sampah nasional mencapai 21,1 juta ton, dengan sekitar 7,2 juta ton atau 34,29% di antaranya belum tertangani secara optimal [2]. Botol plastik dan kaleng minuman termasuk dalam dua jenis sampah anorganik yang paling banyak ditemukan di lingkungan pemukiman maupun fasilitas daur ulang [8]. Proses pemilahan keduanya yang masih dilakukan secara manual dinilai tidak efisien karena membutuhkan tenaga kerja besar dan rentan terhadap inkonsistensi, khususnya pada fasilitas dengan kapasitas pemrosesan tinggi [13].

Perkembangan teknologi pengolahan citra digital dan pembelajaran mesin membuka peluang untuk mengatasi keterbatasan tersebut melalui otomatisasi pada proses pemilahan. Pendekatan berbasis analisis citra memungkinkan sistem mengidentifikasi dan mengklasifikasikan jenis sampah secara *real-time* tanpa keterlibatan operator manusia. [9] menunjukkan bahwa klasifikasi objek sampah dapat dilakukan dengan mengekstraksi fitur bentuk dan morfologi dari citra digital dalam sistem pemilah sampah cerdas (*Intelligent Waste Separator*). Lebih lanjut, [15] menegaskan bahwa integrasi metode pembelajaran mesin ke dalam sistem berbasis citra terbukti meningkatkan efisiensi dan konsistensi proses pemilahan sampah secara signifikan.

Kualitas ekstraksi fitur menjadi faktor penentu utama dalam *pipeline* klasifikasi berbasis citra. Fitur morfologi seperti *aspect ratio*, *solidity*, *eccentricity*, dan Hu Moments mampu merepresentasikan karakteristik geometri objek secara *robust* meskipun terdapat variasi sudut pandang dan skala [9]. Di samping fitur bentuk, representasi warna melalui ruang warna HSV (*Hue, Saturation, Value*) terbukti relevan dalam membedakan karakteristik visual antar kelas objek [6]. Selain itu, ekstraksi dari fitur tekstur menggunakan metode GLCM (*contrast, homogeneity, energy*, dan *correlation*) yang terdiri dari nilai *contrast, homogeneity, energy*, dan *correlation* terbukti efektif saat

digunakan bersama algoritma SVM [1]. Penggabungan ketiga kategori fitur tersebut (morfologi, warna, dan tekstur) ke dalam satu pipeline ekstraksi fitur gabungan (*feature fusion*) diharapkan mampu menghasilkan representasi objek yang lebih komprehensif dan diskriminatif dibandingkan penggunaan fitur tunggal.

Sejumlah penelitian telah dilakukan untuk mengeksplorasi pendekatan klasifikasi sampah berbasis citra. [6] membandingkan CNN dan SVM pada klasifikasi botol plastik, dengan hasil menunjukkan SVM lebih unggul pada dataset berukuran kecil, sedangkan CNN memerlukan data yang lebih besar untuk mencapai performa optimal. [7] menemukan bahwa pendekatan hybrid pada model deep learning memberikan akurasi yang kompetitif, meskipun masih rentan terhadap overfitting pada dataset berukuran terbatas. [15] menunjukkan bahwa kombinasi SVM dengan arsitektur deep learning seperti ResNet50 mampu meningkatkan akurasi klasifikasi pada kategori sampah yang lebih kompleks. [13] juga membuktikan bahwa mekanisme attention berbasis serial frame meningkatkan performa klasifikasi botol berlabel ganda dibandingkan metode konvensional. Berdasarkan temuan-temuan tersebut, pendekatan handcrafted feature dengan SVM tetap relevan untuk kondisi keterbatasan komputasi atau dataset berukuran sedang, karena lebih efisien dan menghasilkan model yang lebih mudah diinterpretasikan [6].

Selain pemilihan fitur dan metode klasifikasi, tahap preprocessing citra turut menentukan kualitas hasil akhir sistem. SVM bekerja dengan membangun hyperplane optimal yang memisahkan kelas data dengan margin maksimum, dan performanya sangat bergantung pada kualitas fitur masukan serta konfigurasi hyperparameter [1]. Dalam konteks ini, segmentasi citra menggunakan metode thresholding Otsu berperan sebagai langkah awal yang penting untuk memisahkan objek dari latar belakang. Berbagai penelitian pengembangan metode Otsu terus dilakukan guna meningkatkan akurasi segmentasi pada kondisi pencahayaan yang tidak seragam [3], [14].

Berdasarkan uraian di atas, penelitian ini dirancang untuk membangun sistem klasifikasi sampah botol plastik dan kaleng minuman menggunakan pipeline pengolahan citra yang terdiri dari tahap preprocessing (Gaussian Blur, Otsu Thresholding, dan operasi morfologi), ekstraksi fitur gabungan (morfologi, warna HSV/RGB, dan tekstur GLCM), normalisasi fitur, serta klasifikasi SVM yang dioptimasi menggunakan GridSearchCV. Dataset penelitian bersumber dari [4] yang tersedia secara publik pada platform Kaggle. Tujuan spesifik penelitian ini mencakup: (1) perancangan pipeline ekstraksi fitur yang komprehensif untuk membedakan karakteristik visual kedua kelas sampah; (2) optimasi hyperparameter SVM secara sistematis guna mencapai performa klasifikasi terbaik; serta (3) evaluasi model secara menyeluruh menggunakan metrik accuracy, precision, recall, F1-score, dan ROC-AUC.

Kontribusi utama penelitian ini adalah pengembangan pipeline ekstraksi fitur gabungan yang mengintegrasikan fitur morfologi, warna, dan tekstur untuk meningkatkan kemampuan representasi karakteristik objek, serta penerapan optimasi hyperparameter SVM menggunakan GridSearchCV untuk memperoleh performa klasifikasi yang optimal pada proses identifikasi jenis sampah botol plastic dan kaleng minuman.

2. Metode Penelitian

Metodologi yang digunakan dalam penelitian ini dirancang secara sistematis melalui pendekatan *handcrafted features* dan pembelajaran mesin berbasis *Support Vector Machine* (SVM). Alur pemrosesan data mengikuti tahapan standar pengolahan citra digital, mulai dari akuisisi data, pra pemrosesan, segmentasi, ekstraksi fitur gabungan, hingga tahap pemodelan dan evaluasi.

2.1 Pengumpulan dan Deskripsi Dataset

Data yang digunakan dalam penelitian ini adalah dataset publik bernama “*Bottles and Cans*” yang diambil dari platform Kaggle [4]. Dataset ini memiliki dua kelas, yaitu:

1. *bottles*: berisi sekumpulan citra botol plastik.
2. *can*: berisi sekumpulan citra kaleng minuman.

Agar model klasifikasi yang dibuat tidak mengalami bias akibat jumlah data yang tidak seimbang atau bisa disebut dengan data *imbalance*, dilakukan pembatas jumlah sampel pada kodingan menggunakan parameter `MAX_PER_CLASS = 300`. Dengan cara ini, distribusi kelas pada tahap penelitian maupun pengujian menjadi lebih seimbang. Semua citra yang digunakan kemudian diubah ukurannya menjadi 128x128 piksel dengan format bawaan BGR sebelum diproses lagi.

2.2 Prapemrosesan Citra (*Preprocessing*) dan Segmentasi

Tahap prapemrosesan dilakukan untuk memperbaiki kualitas citra mengurangi *noise*, dan memisahkan objek botol atau kaleng dari latar belakangnya. Tahapan ini terdiri dari beberapa proses berikut:

1. Konversi Ruang Warna: Citra BGR diubah menjadi citra *Grayscale* (keabuan) untuk keperluan segmentasi dan analisis tekstur. Selain itu, citra juga diubah ke ruang warna HSV (*Hue, Saturation, Value*) untuk mempermudah ekstraksi fitur warnanya.
2. Reduksi Noise (*Gaussian Blur*): Permukaan botol plastic dan kaleng sering kali memantulkan Cahaya pantulan (*specular reflection*) yang bisa mengganggu proses deteksi. Oleh karena itu, digunakan filter *Gaussian Blur* dengan ukuran *kernel* 5x5 untuk memperhalus citra dan menyamarkan *noise* pantulan tersebut.
3. Segmentasi Objek (*Otsu Thresholding*): Proses pemisahan objek dari latar belakang dilakukan secara otomatis menggunakan metode *Otsu Thresholding*. Metode ini mencari nilai ambang batas (*threshold*) yang paling pas untuk mengubah citra menjadi hitam-putih (biner).
4. Operasi Morfologi (*Cleaning*): Citra biner dari hasil segmentasi terkadang masih memiliki sisa-sisa *noise* atau lubang kecil pada area objek. Untuk membersihkannya, dilakukan operasi morfologi menggunakan *kernel* berbentuk elips ukuran 5x5.
 - *Morphological Closing* (2 iterasi): Bertujuan untuk menutup lubang-lubang kecil yang ada di dalam objek.
 - *Morphological Opening* (1 iterasi): Bertujuan untuk membersihkan sisa bintik *noise* di area latar belakang citra.

2.3 Ekstraksi Fitur Gabungan (*Feature Fusion*)

Untuk memperoleh representasi objek yang kaya dan diskriminatif, penelitian ini menerapkan strategi *feature fusion* dengan menggabungkan tiga kategori fitur visual: morfologi (bentuk), warna, dan tekstur.

2.3.1 Fitur Morfologi (Bentuk)

Fitur morfologi diekstraksi dari *binary mask* objek terbesar yang terdeteksi pada citra hasil segmentasi menggunakan fungsi *regionprops*. Parameter geometri yang dihitung meliputi:

1. Area & Perimeter: Luas dan keliling objek yang telah dinormalisasi terhadap ukuran citra.
2. Aspect Ratio: Rasio antara lebar dan tinggi dari *bounding box* objek.
3. Extent & Solidity: Rasio area objek terhadap area *bounding box*, serta rasio area objek terhadap area *convex hull*.
4. Eccentricity & Circularity: Mengukur tingkat kelonggangan objek dan seberapa dekat bentuk objek dengan lingkaran sempurna.
5. Euler Number & Equivalent Diameter: Karakteristik topologi (jumlah lubang) dan diameter lingkaran yang setara dengan luas objek.
6. Hu Moments (1-7): Tujuh nilai momen invarian logaritmik yang bersifat robust terhadap perubahan rotasi, skala, dan translasi objek.

2.3.2 Fitur Warna

Karakteristik visual dari segi warna didapatkan melalui ekstraksi ruang warna HSV dan RGB. Proses ini menghasilkan dua jenis fitur utama, yaitu:

1. Statistik Warna: Menghitung nilai rata-rata (*mean*) dan standar deviasi dari setiap saluran warna (H, S, V, R, G, dan B). Nilai-nilai ini kemudian dinormalisasi agar berada pada rentang skala 0 hingga 1.

2. Histogram Warna: Membuat distribusi frekuensi warna menggunakan histogram 20-bin untuk saluran H, S, dan V. Hasilnya Adalah 60 nilai fitur yang menggambarkan sebaran kerapatan warna pada objek.

2.3.3 Fitur Tekstur (GLCM)

Analisis tekstur permukaan objek seperti perbedaan fisik dari bahan plastic dan alumunium dilakukan menggunakan metode *Gray-Level Co-occurrence Matrix* (GLCM). Citra pertama diubah ke dalam bentuk *grayscale* dengan 256 tingkat keabuan. Matriks GLCM kemudian dihitung dengan jarak piksel sejauh 1 dan 3, serta menggunakan sudut arah 0° dan 90° . Dari matriks tersebut, diekstrak empat property statistic Haralick, di antaranya *Contrast*, *Homogeneity*, *Energy*, dan *Correlation*. Sebagai contoh, nilai *Contrast* dan *Energy* dihitung berdasarkan persamaan berikut:

$$Contrast = \sum_{i,j} (i - j)^2 P(i, j)$$

2.4 Normalisasi dan Pembagian Data

Sebelum modelnya dilatih, seluruh fitur yang telah diekstrak digabungkan menjadi satu matriks data. Data tersebut kemudian dibagi secara acak menjadi dua bagian, yaitu 80% sebagai data latih dan 20% sebagai data uji. Pada pembagian ini menggunakan metode *stratified sampling* untuk memastikan proporsi gambar botol dan kaleng tetap seimbang di kedua subset data.

Selanjutnya, semua nilai fitur dinormalisasi menggunakan metode *standard Scaler* agar memiliki nilai rata-rata (μ) 0 dan standar deviasi (σ) 1. Hal ini penting dilakukan agar fitur yang memiliki skala angka besar tidak mendominasi perhitungan jarak pada algoritma klasifikasi. Rumus normalisasi *Z-score* yang digunakan adalah:

$$z = (x - \mu) / \sigma$$

2.5 Pemodelan dan Optimasi Hyperparameter

Proses klasifikasi pada penelitian ini menggunakan algoritma *Support Vector Machine* (SVM). Untuk mendapatkan performa terbaik dan menghindari terjadinya *overfitting*, dilakukan pencarian hyperparameter (tuning) menggunakan metode *Grid Search* yang dikombinasikan dengan validasi silang (*5-fold Cross-Validation*).

Beberapa parameter yang diuji coba secara sistematis meliputi jenis *kernel* (Linear, Polynomial, dan RBF), parameter regularisasi atau C (0.1, 1, 10, dan 100), serta nilai gamma. Pada *kernel Radial Basis Function* (RBF), transformasi data ke dimensi yang lebih tinggi dihitung menggunakan persamaan:

$$K(x_i, x_j) = \exp(-\gamma ||x_i - x_j||^2)$$

Model yang menghasilkan tingkat akurasi validasi tertinggi akan dipilih sebagai model final untuk mengevaluasi data uji.

2.6 Metrik Evaluasi Kinerja Model

Evaluasi kinerja model klasifikasi diukur menggunakan *Confusion Matrix*, yang mencakup nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan nilai-nilai tersebut, performa pengujian dihitung melalui empat metrik utama, yaitu:

- Akurasi dari persentase total tebakan yang benar dari keseluruhan data uji

$$Accuracy = (TP + TN) / (TP + TN + FP + FN)$$

- Presisi dari Tingkat ketepatan model dalam menebak kelas positif tanpa adanya *false-positive*

$$Precision = TP / (TP + FP)$$

- Recall dengan kemampuan model dalam menemukan Kembali seluruh data kelas positif yang sebenarnya.

$$Recall = TP / (TP + FN)$$

- F1-Score yang rata-rata harmonic antara presisi dan *recall* untuk melihat keseimbangan model.


$$F1 = 2(Precision \times Recall) / (Precision + Recall)$$

Selain keempat metrik tersebut, performa model juga dievaluasi menggunakan nilai *ROC-AUC* untuk mengukur seberapa baik sistem mampu memisahkan batas keputusan antara objek botol plastik dan kaleng minuman.

3. Hasil dan Pembahasan

3.1 Hasil Pra Pemrosesan dan Segmentasi Citra


Tahap pra pemrosesan dilakukan untuk memastikan citra masukan bersih dari komponen informasi yang tidak relevan sebelum masuk ke tahap ekstraksi fitur. Proses konversi ruang warna dari BGR ke grayscale berhasil mereduksi dimensi matriks warna tanpa menghilangkan informasi kontur struktural objek. Penggunaan filter Gaussian Blur terbukti krusial untuk menghaluskan intensitas piksel, sehingga efek pantulan cahaya (*specular reflection*) yang tajam pada permukaan material kaleng aluminium dan botol plastik transparan dapat diredam. Hasil segmentasi menggunakan Otsu Thresholding menunjukkan keberhasilan dalam memisahkan area objek utama (*foreground*) secara biner dari latar belakangnya secara otomatis. Operasi morfologi *Closing* dan *Opening* yang diterapkan setelah segmentasi berhasil membersihkan lubang-lubang kecil (*hole*) di dalam area objek, menghasilkan binary mask kontur objek yang halus dan siap diekstrak.



Gambar 1 Hasil Pra-pemrosesan dan Segmentasi Citra

3.2 Analisis Karakteristik dan Distribusi Fitur


Proses ekstraksi fitur gabungan (*feature fusion*) menghasilkan total 96 dimensi fitur yang merepresentasikan karakteristik bentuk, warna, dan tekstur objek. Berdasarkan analisis histogram, fitur morfologi berupa *aspect ratio* dan *circularity* menunjukkan perbedaan sebaran nilai yang signifikan antara kedua kelas. Objek kaleng cenderung memiliki nilai *circularity* yang lebih terpusat karena bentuk geometris dasarnya yang mendekati silinder simetris, sedangkan objek botol plastik menunjukkan variasi nilai *aspect ratio* yang melebar akibat variasi bentuk leher dan badan botol. Pada fitur warna, nilai rata-rata *Hue* (*mean_H*) dan *Saturation* (*mean_S*) berhasil menangkap perbedaan karakteristik visual material secara tangguh, di mana botol plastik memiliki nilai saturasi yang lebih rendah dibandingkan permukaan kaleng minuman.



Gambar 2 Distribusi *Feature Fusion* Botol dan Kaleng

3.3 Hasil Optimasi Hyperparameter SVM dengan GridSearchCV

Tahap pelatihan model diawali dengan pembagian dataset secara *stratified* menjadi 480 sampel data latih dan 120 sampel data uji. Guna menghindari permasalahan *overfitting*, dilakukan proses optimasi melalui *GridSearchCV* dengan skema *5-fold Cross-Validation*. Hasil dari pencarian dari 60 kombinasi mengeksplorasi bahwa parameter terbaik dicapai oleh fungsi *kernel* RBF dengan nilai regularisasi $C = 10$ dan parameter *gamma* = 'scale'. Kombinasi parameter tersebut menghasilkan nilai rata-rata akurasi validasi silang (*CV MEAN*) tertinggi sebesar 92,50%. Nilai optimal ini berhasil membangun hyperlane keputusan dengan margin yang seimbang untuk memisahkan kedua kelas objek secara maksimal.




Gambar 3 Hasil Optimasi Hyperparameter SVM menggunakan GridSearchCV

3.4 Perbandingan Performa Arsitektur SVM

Model SVM final yang telah dioptimasi kemudian dibandingkan secara langsung dengan beberapa variasi konfigurasi *kernel* alternatif. Model SVM yang melalui tahap tuning hyperparameter secara sistematis


menunjukkan keunggulan akurasi yang lebih stabil dibandingkan model dengan parameter *default*. Proyeksi sebaran data uji pada ruang dimensi tereduksi mengonfirmasi bahwa mayoritas vektor fitur gabungan dari kelas botol plastik dan kaleng minuman dapat dipisahkan secara tegas oleh ruang keputusan model, dengan hanya menyisakan sebagian kecil sampel yang berada di dekat batas keputusan (*boundary area*).



Gambar 4 Perbandingan Kinerja Model SVM

3.5 Evaluasi Kinerja Komprehensif Model Terbaik


Pengujian performa mendalam terhadap model SVM terbaik dilakukan menggunakan 120 data uji independen. Model SVM final menghasilkan tingkat akurasi keseluruhan sebesar 93,33% dan *Recall* 93,33%. Keseimbangan metrik pada kedua kelas yang menghasilkan F-1Score rata-rata sebesar 93,41% menjadi bukti empiris yang valid bahwa model klasifikasi ini terbebas dari masalah bias kelas. Analisis kurva *Receiver Operating Characteristic* (ROC) menghasilkan nilai *Area Under Curve* (ROC-AUC) sebesar 0,981. Nilai AUC yang mendekati 1.0 ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam memisahkan kedua kelas secara akurat.



Gambar 5 Evaluasi Model menggunakan *Confusion Matrix* dan *ROC Curve*

3.6 Analisis Kurva Pembelajaran dan Kontribusi Fitur

Evaluasi dinamika pelatihan dilakukan dengan menganalisis grafik *Learning Curve* untuk mendeteksi indikasi terjadinya *overfitting* atau *underfitting* seiring bertambahnya volume data latih. Grafik menunjukkan pola konvergensi yang stabil, menandakan bahwa penambahan fitur gabungan tidak menyebabkan model mengalami gejala *overfitting* (high variance). Berdasarkan evaluasi metode *Permutation Importance*, fitur statistik warna (mean_S dan mean_H) serta fitur bentuk (circularity dan solidity) menjadi faktor yang paling berpengaruh terhadap performa model dalam mengenali karakteristik fisik sampah.



Gambar 6 Learning Curve dan Permutation Feature Importance

3.7 Analisis Kesalahan (Error Analysis)

Meskipun sistem membukukan performa yang tinggi, proses *Error Analysis* menemukan 8 sampel salah klasifikasi dari 120 data uji. Kesalahan klasifikasi ini umumnya disebabkan oleh kerusakan fisik objek yang cukup parah, seperti kaleng minuman yang penyok parah sehingga nilai circularity-nya menurun drastis menyerupai botol remuk, serta botol plastik dengan label kemasan (oklusi) penuh yang memancarkan warna saturasi tinggi menyerupai cetakan kaleng.



Gambar 7 Contoh Kesalahan Klasifikasi (Error Analysis)

4. Kesimpulan

Penelitian ini berhasil mengembangkan dan mengevaluasi sistem klasifikasi sampah anorganik (botol plastik dan kaleng minuman) berbasis pengolahan citra digital. Penggunaan kombinasi fitur (feature fusion) yang melibatkan 96 dimensi fitur dari ekstraksi morfologi, parameter warna HSV/RGB, dan analisis tekstur GLCM terbukti efektif dalam membedakan karakteristik kedua kelas objek. Melalui proses optimasi GridSearchCV, algoritma Support Vector Machine (SVM) dengan kernel RBF ($C=10$, $\text{Gamma}=\text{'scale'}$) berhasil mencapai tingkat akurasi klasifikasi sebesar 93,33% pada testing set, dengan nilai F1-Score 93,41% dan ROC-AUC 0,981. Hasil ini menunjukkan bahwa kombinasi prapemrosesan Otsu Thresholding dan ekstraksi fitur manual masih sangat andal dan efisien untuk diterapkan pada sistem klasifikasi sampah berskala menengah. Untuk pengembangan penelitian selanjutnya,

disarankan untuk memperluas cakupan dataset dengan memasukkan berbagai kondisi pencahayaan dan sudut pengambilan gambar yang lebih ekstrim. Eksperimen menggunakan algoritma Deep Learning seperti Convolutional Neural Network (CNN) dengan arsitektur ringan (misalnya MobileNet) dapat diujicobakan sebagai pembanding untuk membandingkan efisiensi waktu komputasi serta keandalan sistem dalam mengenali objek sampah yang saling bertumpuk.

Referensi

- [1] Anand, R., et al. (2022). GLCM feature-based texture image classification using support vector machine. *3rd EAI International Conference*. https://doi.org/10.1007/978-3-030-78750-9_10
- [2] Kementerian Koordinator PMK. (2023). 7,2 juta ton sampah di Indonesia belum terkelola dengan baik. <https://www.kemenkopmk.go.id/72-juta-ton-sampah-di-indonesia-belum-terkelola-dengan-baik>
- [3] Lei, Y., & Zhang, J. (2022). OTSU multi-threshold image segmentation based on improved particle swarm algorithm. *Applied Sciences*, 12(22), 11514. <https://doi.org/10.3390/app122211514>
- [4] Moezabid. (2022). *Bottles and cans* [Dataset]. Kaggle. <https://www.kaggle.com/datasets/moezabid/bottles-and-cans>
- [5] Nisa, I. Z., et al. (2022). Klasifikasi Citra Sampah Menggunakan SVM dengan Ekstraksi Fitur GLCM dan Color Moments. *JTIK*, 9(5), 921-930. <https://doi.org/10.25126/jtik.2022954868>
- [6] Nurhidayat, I., & Pimpunchat, B. (2022). Comparison of machine learning approach for waste bottle classification. *Emerging Science Journal*, 6(5). <https://doi.org/10.28991/ESJ-2022-06-05-012>
- [7] Qiao, Z. (2024). Advancing recycling efficiency: A comparative analysis of deep learning models in waste classification. *arXiv*. <https://arxiv.org/abs/2411.02779>
- [8] Rafi, P., & Perkasa, M. N. (2023). Dampak kerusakan lingkungan akibat sampah plastik. *Jurnal Multidisiplin Indonesia*, 2(7).
- [9] Rahmi, A. N., et al. (2022). Implementation and integration of image processing blocks in a real-time bottle classification system. *Scientific Reports*, 12, 4961. <https://doi.org/10.1038/s41598-022-08777-x>
- [10] Rasidi, A. I., et al. (2022). Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, 8(1). <https://doi.org/10.28991/jutisi.v8i1.4314>
- [11] 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>
- [12] Wulansari, A., et al. (2022). Systematic Literature Review of Waste Classification Using Machine Learning. *JITE*, 5(2), 405-413. <https://doi.org/10.31289/jite.v5i2.6211>
- [13] Xiao, J., et al. (2022). A serial attention frame for multi-label waste bottle classification. *Applied Sciences*, 12(3), 1742. <https://doi.org/10.3390/app12031742>
- [14] Xie, Z., et al. (2024). Advancing image segmentation with DBO-Otsu: Addressing rubber tree diseases through enhanced threshold techniques. *PLOS ONE*, 19(3). <https://doi.org/10.1371/journal.pone.0297284>
- [15] Zhang, H., et al. (2023). Hybrid deep learning model for accurate classification of solid waste in the society. *Waste Management*, 109, 107274. <https://doi.org/10.1016/j.wasman.2023.107274>