

# Klasifikasi Sampah Berbasis Citra Menggunakan Metode CNN: Studi Komparatif dengan Decision Tree, Random Forest, dan SVM untuk Pengelolaan Sampah Berkelanjutan

Nabila Carrissa Dewi<sup>1\*</sup>, Gus Nanang Syaifuddiin<sup>2</sup>

<sup>1,2</sup>Program Studi Teknologi Rekayasa Perangkat Lunak, Fakultas Teknik, Politeknik Negeri Madiun  
Email: <sup>1\*</sup>nabilacarrissa@gmail.com, <sup>2</sup>gus.nanang@pnm.ac.id

**Abstrak** - Peningkatan volume sampah yang terus terjadi menuntut pengembangan teknologi pemilahan otomatis yang akurat dan efisien guna mendukung pengelolaan sampah berkelanjutan. Dalam beberapa tahun terakhir, Convolutional Neural Network (CNN) menjadi pendekatan dominan dalam klasifikasi citra karena kemampuannya mempelajari fitur secara otomatis. Namun, efektivitas CNN pada kondisi dataset yang terbatas masih menjadi tantangan yang belum sepenuhnya dipahami. Penelitian ini bertujuan untuk mengevaluasi kinerja CNN dibandingkan dengan algoritma machine learning klasik, yaitu Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT), pada tugas klasifikasi sampah berbasis citra.

Penelitian menggunakan Garbage Classification Dataset yang terdiri atas 4.133 citra dari tujuh kategori sampah. Tahapan penelitian meliputi preprocessing citra, ekstraksi fitur Histogram of Oriented Gradients (HOG) untuk model machine learning, pembagian data secara stratified dengan rasio 70:20:10, pelatihan model, serta evaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi 67,15%, diikuti Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%.

Temuan ini menunjukkan bahwa model deep learning tidak selalu memberikan hasil terbaik pada seluruh kondisi eksperimen. Meskipun CNN secara teoritis memiliki kemampuan representasi yang lebih tinggi, performanya menurun secara signifikan ketika dilatih dari awal menggunakan dataset yang relatif terbatas dan memiliki kemiripan visual antar kelas. Sebaliknya, pendekatan berbasis fitur HOG mampu menyediakan representasi visual yang lebih stabil sehingga meningkatkan kemampuan generalisasi algoritma machine learning klasik. Hasil penelitian memberikan bukti empiris bahwa pada skenario klasifikasi sampah dengan ketersediaan data yang terbatas, kombinasi HOG dan SVM dapat menjadi alternatif yang lebih efektif dibandingkan CNN. Temuan ini berkontribusi pada pengembangan sistem pemilahan sampah otomatis yang lebih efisien, ringan secara komputasi, dan berpotensi diterapkan pada lingkungan dengan sumber daya terbatas untuk mendukung pengelolaan sampah berkelanjutan.

**Kata Kunci:** Klasifikasi sampah, CNN, SVM, HOG, machine learning

<https://journal.paramadina.ac.id/index.php/jitc>

Artikel ini adalah artikel dengan akses terbuka, dilisensikan di bawah CC BY 4.0.



**Abstract** - The increasing volume of municipal waste has intensified the need for accurate and efficient automated waste-sorting technologies to support sustainable waste management. Although Convolutional Neural Networks (CNNs) have become the dominant approach in image classification due to their ability to learn feature representations automatically, their effectiveness under limited-data conditions remains insufficiently explored. This study investigates the performance of CNNs in comparison with conventional machine learning algorithms, namely Support Vector Machine (SVM), Random Forest (RF), and Decision Tree (DT), for image-based waste classification.

The experiments were conducted using the Garbage Classification Dataset consisting of 4,133 images distributed across seven waste categories. The proposed framework involved image preprocessing, Histogram of Oriented Gradients (HOG) feature extraction for machine learning models, stratified data partitioning with a 70:20:10 ratio, model training, and evaluation using accuracy, precision, recall, and F1-score metrics. The results demonstrate that SVM achieved the highest accuracy of 67.15%, followed by Random Forest (65.70%), Decision Tree (39.61%), and CNN (23.67%).

A notable finding of this study is that the CNN model, despite its superior theoretical capacity for automatic feature learning, produced the lowest classification performance among the evaluated approaches. This outcome suggests that training a CNN from scratch on a relatively limited dataset with considerable inter-class visual similarity is insufficient to learn highly discriminative feature representations. In contrast, HOG-based feature engineering provided more structured and stable visual descriptors, enabling conventional machine learning algorithms to achieve better generalization performance. These findings indicate that deep learning models do not necessarily outperform traditional machine learning approaches in all scenarios and that dataset characteristics play a critical role in determining model effectiveness. This study contributes empirical evidence that, in resource-constrained environments and limited-data settings, the combination of HOG and SVM can serve as a more accurate and computationally efficient alternative to CNN-based approaches for automated waste classification. The findings provide valuable insights for the development of practical intelligent waste-sorting systems that support sustainable waste management initiatives.

**Keywords:** Waste Classification, CNN, SVM, HOG, Machine Learning

## I. PENDAHULUAN

Peningkatan jumlah sampah merupakan salah satu permasalahan lingkungan yang semakin kompleks seiring dengan pertumbuhan populasi, urbanisasi, dan meningkatnya aktivitas konsumsi masyarakat. Pengelolaan sampah yang tidak optimal dapat menimbulkan berbagai dampak negatif, seperti pencemaran lingkungan, penurunan kualitas kesehatan masyarakat, serta meningkatnya beban pengelolaan di tempat pemrosesan akhir. Salah satu tahapan penting dalam pengelolaan sampah adalah proses pemilahan berdasarkan jenis material, karena kualitas pemilahan akan memengaruhi efektivitas proses daur ulang dan pengolahan lanjutan.

Seiring berkembangnya teknologi kecerdasan buatan, berbagai penelitian telah memanfaatkan pengolahan citra digital untuk mengotomatisasi proses klasifikasi sampah. Pendekatan ini memungkinkan sistem mengenali jenis sampah secara otomatis melalui citra yang diperoleh dari kamera sehingga dapat mengurangi ketergantungan pada proses pemilahan manual. Implementasi sistem klasifikasi berbasis citra juga menjadi salah satu solusi yang potensial untuk mendukung pengelolaan sampah yang lebih efisien dan berkelanjutan.

Dalam beberapa tahun terakhir, Convolutional Neural Network (CNN) menjadi metode yang paling banyak digunakan dalam klasifikasi citra karena kemampuannya mempelajari fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur manual. Berbagai penelitian melaporkan bahwa CNN mampu menghasilkan tingkat akurasi yang tinggi pada tugas klasifikasi objek, termasuk klasifikasi sampah. Namun, sebagian besar penelitian tersebut menggunakan dataset berukuran besar, teknik augmentasi yang intensif, atau memanfaatkan transfer learning dari model yang telah dilatih sebelumnya. Kondisi tersebut menyebabkan performa CNN pada dataset yang relatif terbatas masih belum sepenuhnya dapat digeneralisasikan.

Di sisi lain, algoritma machine learning klasik seperti Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) masih banyak digunakan karena memiliki kompleksitas yang lebih rendah dan kebutuhan komputasi yang lebih ringan. Berbeda dengan CNN yang melakukan pembelajaran fitur secara otomatis, algoritma machine learning memerlukan representasi fitur yang diekstraksi terlebih dahulu, salah satunya menggunakan Histogram of Oriented Gradients (HOG). Beberapa penelitian menunjukkan bahwa kombinasi HOG dan algoritma machine learning masih mampu memberikan

performa yang kompetitif pada dataset berukuran kecil hingga menengah.

Meskipun penelitian mengenai klasifikasi sampah telah banyak dilakukan, sebagian besar studi berfokus pada peningkatan performa CNN dan hanya sedikit yang mengevaluasi secara mendalam kondisi ketika metode machine learning klasik dapat memberikan hasil yang lebih baik dibandingkan pendekatan deep learning. Selain itu, kajian komparatif yang menganalisis perbedaan performa antara CNN dan algoritma machine learning berbasis HOG pada dataset klasifikasi sampah yang relatif terbatas masih belum banyak dilaporkan. Akibatnya, belum terdapat pemahaman yang memadai mengenai pendekatan yang paling efektif untuk diterapkan pada kondisi dengan keterbatasan data dan sumber daya komputasi.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan membandingkan performa CNN, SVM, Random Forest, dan Decision Tree dalam klasifikasi sampah berbasis citra menggunakan dataset yang terdiri atas tujuh kategori sampah. Berbeda dengan penelitian terdahulu yang umumnya berfokus pada pencapaian akurasi tertinggi, penelitian ini menitikberatkan pada analisis

efektivitas pendekatan deep learning dan machine learning klasik pada kondisi dataset yang terbatas. Dengan demikian, penelitian ini tidak hanya memberikan perbandingan performa antar model, tetapi juga menyajikan pemahaman empiris mengenai faktor-faktor yang menyebabkan perbedaan kinerja masing-masing metode.

Kontribusi utama penelitian ini terletak pada evaluasi komprehensif terhadap perbedaan paradigma pembelajaran antara CNN sebagai pendekatan end-to-end dan algoritma machine learning klasik yang memanfaatkan fitur HOG. Hasil penelitian diharapkan dapat memberikan referensi dalam pemilihan model klasifikasi yang sesuai untuk sistem pemilahan sampah otomatis, sekaligus mendukung pengembangan teknologi pengelolaan sampah yang lebih efektif, efisien, dan berkelanjutan.

## II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen untuk membandingkan performa empat algoritma klasifikasi citra, yaitu Convolutional Neural Network (CNN), Support Vector Machine (SVM), Decision Tree (DT), dan Random Forest (RF) dalam mengklasifikasikan citra sampah. Seluruh model dilatih dan diuji menggunakan dataset yang sama sehingga perbandingan dapat dilakukan secara objektif.

#### A. Dataset

Penelitian ini menggunakan dataset Garbage Classification yang tersedia secara public di platform Kaggle (<https://www.kaggle.com/datasets/karansolanki01/garbage-classification>). Dataset yang terdiri atas 4.133 citra dan terbagi ke dalam tujuh kelas, yaitu Battery, Cardboard, Clothes, Glass, Metal, Paper, dan Plastic. Dataset dipilih karena memiliki variasi objek yang cukup beragam sehingga dapat digunakan untuk mengevaluasi kemampuan model dalam mengenali berbagai jenis sampah.



Gambar 1. Clothes

Untuk menjaga proporsi data pada setiap kelas, dilakukan pembagian data menggunakan metode stratified sampling dengan rasio 70% data pelatihan, 20% data validasi, dan 10% data pengujian. Proses pembagian data menggunakan nilai random seed = 42 untuk memastikan hasil eksperimen dapat direproduksi pada penelitian selanjutnya.

#### B. Pra-pemrosesan

Tahap pra-pemrosesan dilakukan sebelum proses pelatihan model. Seluruh citra diubah ukurannya menjadi  $128 \times 128$  piksel agar memiliki dimensi yang seragam. Selanjutnya, nilai piksel dinormalisasi ke rentang 0–1 dengan membagi setiap nilai piksel dengan 255.

Pada algoritma SVM, Decision Tree, dan Random Forest dilakukan ekstraksi fitur menggunakan metode Histogram of Oriented Gradients (HOG). Parameter HOG yang digunakan meliputi orientasi gradien sebanyak 9 bin, ukuran sel  $8 \times 8$  piksel, ukuran blok  $2 \times 2$  sel, serta normalisasi blok menggunakan metode L2-Hys. Hasil ekstraksi fitur kemudian digunakan sebagai masukan bagi algoritma klasifikasi.


Berbeda dengan metode machine learning klasik, model CNN menerima citra yang telah dinormalisasi secara

langsung sehingga proses ekstraksi fitur dilakukan secara otomatis melalui lapisan konvolusi.

#### C. Tahapan Penelitian

Tahapan penelitian yang dilakukan ditunjukkan pada Gambar 2 dan terdiri atas beberapa langkah sebagai berikut:

1. Pengumpulan dataset klasifikasi sampah.
2. Pra-pemrosesan citra berupa resizing dan normalisasi.
3. Ekstraksi fitur HOG untuk model SVM, DT, dan RF.
4. Pelatihan model CNN, SVM, DT, dan RF menggunakan data pelatihan.
5. Evaluasi dan perbandingan performa model berdasarkan *metric* evaluasi.



Gambar 2. Diagram Alur

#### D. Konfigurasi Model

##### 1. Convolutional Neural Network (CNN)

CNN digunakan sebagai representasi pendekatan deep learning yang mampu mempelajari fitur citra secara otomatis tanpa memerlukan ekstraksi fitur manual. Model dibangun menggunakan empat lapisan konvolusi yang diikuti oleh Batch Normalization, fungsi aktivasi ReLU, dan Max Pooling. Pada tahap klasifikasi digunakan Global Average Pooling, lapisan Dense sebanyak 256 neuron, serta Dropout sebesar 0,5 untuk mengurangi risiko overfitting. Lapisan keluaran menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi tujuh kelas sampah.

TABEL 1. Konfigurasi Model CNN

| Parameter          | Nilai                     |
|--------------------|---------------------------|
| Input Size         | $224 \times 224 \times 3$ |
| Convolution Layers | 4 Layer                   |
| Filter             | 32, 64, 128, 256          |
| Kernel Size        | $3 \times 3$              |

|                     |                                 |
|---------------------|---------------------------------|
| Activation Function | ReLU                            |
| Pooling             | Max Pooling 2 × 2               |
| Dense Layer         | 256 Neuron                      |
| Dropout             | 0,5                             |
| Output Activation   | Softmax                         |
| Optimizer           | Adam                            |
| Learning Rate       | 0,0001                          |
| Loss Function       | Sparse Categorical Crossentropy |
| Batch Size          | 32                              |
| Epoch               | 50                              |

Model CNN dilatih menggunakan optimizer Adam dengan learning rate 0,0001 dan batch size 32 selama maksimum 50 epoch. Untuk meningkatkan stabilitas pelatihan digunakan Early Stopping dan Reduce Learning Rate on Plateau.

## 2. Support Vector Machine (SVM)

Support Vector Machine (SVM) digunakan sebagai salah satu model pembanding karena memiliki kemampuan yang baik dalam menangani data berdimensi tinggi hasil ekstraksi fitur HOG. Model ini bekerja dengan mencari hyperplane optimal yang mampu memisahkan kelas secara maksimal.

TABEL 2. Konfigurasi Model SVM

| Parameter    | Nilai |
|--------------|-------|
| Kernel       | RBF   |
| C            | 10    |
| Gamma        | Scale |
| Probability  | True  |
| Random State | 42    |

Kernel Radial Basis Function (RBF) dipilih karena mampu menangani hubungan nonlinier pada ruang fitur yang dihasilkan oleh metode HOG.

## 3. Decision Tree

Decision Tree digunakan untuk membangun aturan klasifikasi berdasarkan struktur pohon keputusan. Setiap node merepresentasikan proses pemisahan data berdasarkan fitur tertentu hingga diperoleh keputusan akhir pada node daun.

TABEL 3. Konfigurasi Model Decision Tree

| Parameter    | Nilai |
|--------------|-------|
| Criterion    | Gini  |
| Max Depth    | None  |
| Random State | 42    |

Kriteria Gini digunakan untuk menentukan atribut terbaik pada setiap percabangan. Kedalaman pohon tidak dibatasi

sehingga struktur pohon dapat menyesuaikan karakteristik data yang digunakan.

## 4. Random Forest

Random Forest merupakan metode ensemble learning yang dibangun dari kumpulan pohon keputusan. Setiap pohon dilatih menggunakan subset data yang berbeda dan hasil prediksi akhir diperoleh melalui mekanisme majority voting.

TABEL 4. Konfigurasi Model Random Forest

| Parameter    | Nilai |
|--------------|-------|
| n_estimators | 150   |
| Criterion    | Gini  |
| Max Depth    | None  |
| Random State | 42    |
| n_jobs       | -1    |

Penggunaan 150 pohon keputusan bertujuan meningkatkan stabilitas model dan kemampuan generalisasi tanpa meningkatkan kompleksitas komputasi secara signifikan.

## E. Lingkungan Eksperimen

Seluruh eksperimen dilakukan menggunakan bahasa pemrograman Python dengan beberapa pustaka utama yang ditunjukkan pada Tabel 5.

TABEL 5. Lingkungan Eksperimen

| Komponen           | Keterangan         |
|--------------------|--------------------|
| Bahasa Pemrograman | Python             |
| Framework CNN      | TensorFlow / Keras |
| Machine Learning   | Scikit-learn       |
| Pengolahan Citra   | OpenCV             |
| Ekstraksi Fitur    | Scikit-image (HOG) |
| Random Seed        | 42                 |

## F. Evaluasi Kerja

Evaluasi kinerja dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan citra sampah secara akurat. Seluruh model, yaitu CNN, SVM, Random Forest, dan Decision Tree, dievaluasi menggunakan data pengujian (testing set) yang tidak digunakan selama proses pelatihan.

Pengukuran performa dilakukan menggunakan confusion matrix dan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Penggunaan beberapa metrik diperlukan untuk memperoleh gambaran yang lebih komprehensif mengenai kemampuan model dalam melakukan klasifikasi pada setiap kelas sampah.

### 1. Accuracy

Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data pengujian.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

dengan:

- TP (True Positive) adalah jumlah data yang berhasil diklasifikasikan dengan benar sebagai kelas positif.
- TN (True Negative) adalah jumlah data yang berhasil diklasifikasikan dengan benar sebagai kelas negatif.
- FP (False Positive) adalah jumlah data yang salah diklasifikasikan sebagai kelas positif.
- FN (False Negative) adalah jumlah data positif yang salah diklasifikasikan sebagai kelas negatif.

## 2. Precision

Precision menunjukkan tingkat ketepatan model dalam memberikan prediksi pada suatu kelas.

$$Precision = \frac{TP}{TP + FP}$$

Nilai precision yang tinggi menunjukkan bahwa sebagian besar prediksi positif yang diberikan model merupakan prediksi yang benar.

## 3. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang termasuk ke dalam suatu kelas.

$$Recall = \frac{TP}{TP + FN}$$

Semakin tinggi nilai recall, semakin baik kemampuan model dalam mengenali objek pada kelas yang bersangkutan.

## 4. F1-Score

F1-Score merupakan rata-rata harmonik antara precision dan recall yang digunakan untuk memberikan evaluasi yang lebih seimbang.

$$F1 = \frac{Precision \times Recall}{Precision + Recall}$$

Metrik ini sangat berguna ketika distribusi data antar kelas tidak sepenuhnya seimbang.

## 5. Analisis Komparatif


Hasil evaluasi dari setiap model kemudian dibandingkan untuk menentukan metode yang memiliki performa terbaik pada tugas klasifikasi sampah berbasis citra. Analisis dilakukan berdasarkan nilai accuracy, precision, recall, dan F1-score yang diperoleh masing-masing model. Selain membandingkan tingkat akurasi, penelitian ini juga menganalisis kemampuan generalisasi setiap model untuk memahami pengaruh karakteristik dataset terhadap efektivitas pendekatan deep learning dan machine learning klasik.

## III. HASIL DAN DISKUSI

Bab ini menyajikan hasil eksperimen yang diperoleh dari penerapan metode Convolutional Neural Network (CNN), Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) pada dataset klasifikasi sampah berbasis citra. Evaluasi dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan model. Hasil eksperimen dianalisis menggunakan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Selain itu, dilakukan analisis komparatif untuk mengidentifikasi model yang memiliki performa terbaik serta mengevaluasi faktor-faktor yang memengaruhi perbedaan kinerja antar model.

### A. Hasil Pelatihan Model CNN

Pada tahap pelatihan, model CNN dilatih menggunakan data pelatihan dengan konfigurasi yang telah dijelaskan pada Bab III. Untuk mengevaluasi proses pembelajaran model, digunakan grafik akurasi dan loss selama pelatihan.



Gambar 3. Grafik Akurasi dan Loss Pelatihan CNN

Gambar 3 menunjukkan perkembangan nilai akurasi dan loss pada data pelatihan dan validasi selama proses pelatihan CNN. Kurva tersebut digunakan untuk mengevaluasi kemampuan model dalam mempelajari pola data serta mengidentifikasi kemungkinan terjadinya overfitting atau underfitting. Meskipun akurasi pelatihan mengalami peningkatan selama proses pembelajaran, performa model pada data pengujian masih relatif rendah dibandingkan model machine learning yang menggunakan fitur HOG.


### B. Hasil Evaluasi Kinerja Model

Evaluasi dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan. Kinerja model diukur menggunakan metrik accuracy, precision, recall, dan F1-score.

TABEL 6. Perbandingan Kinerja Model

| MODEL           | AKURASI | PRESESIS | RECALL | F1-SCORE |
|-----------------|---------|----------|--------|----------|
| 0 CNN           | 23.67%  | 12.40%   | 23.67% | 16.25%   |
| 1 SVM RBF       | 67.15%  | 67.39%   | 67.15% | 66.95%   |
| 2 Decision Tree | 39.61%  | 39.45%   | 39.61% | 39.46%   |
| 3 Random Forest | 65.70%  | 65.89%   | 65.70% | 65.05%   |

Hasil pengujian menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi sebesar 67,15%, diikuti Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%.

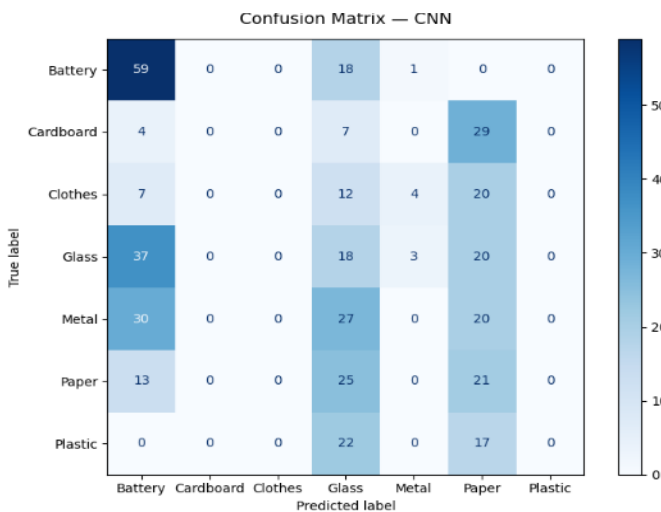


Gambar 4. Perbandingan Performa Model


Berdasarkan Gambar 4, model SVM dan Random Forest menunjukkan performa yang lebih baik dibandingkan CNN dan Decision Tree pada hampir seluruh metrik evaluasi. Hasil ini menunjukkan bahwa representasi fitur HOG yang digunakan oleh model machine learning mampu memberikan informasi yang lebih efektif dalam membedakan karakteristik masing-masing kelas sampah.

C. Analisis Confusion Matrix


Untuk memahami pola kesalahan klasifikasi yang dilakukan model, digunakan confusion matrix pada masing-masing algoritma




Gambar 5. Confusion Matrix CNN



Gambar 6. Confusion Matrix SVM RBF



Gambar 7. Confusion Matrix Decision Tree



Gambar 8. Confusion Matrix Random Forest

Confusion matrix menunjukkan distribusi prediksi benar dan salah pada setiap kelas. Model SVM memperlihatkan jumlah prediksi benar yang lebih tinggi dibandingkan model lainnya, sedangkan CNN menunjukkan tingkat kesalahan

klasifikasi yang lebih besar pada beberapa kelas sampah. Hal ini mengindikasikan bahwa fitur yang dipelajari CNN belum mampu membedakan karakteristik antar kelas secara optimal.

#### D. Diskusi

Hasil penelitian menunjukkan bahwa kombinasi HOG dan SVM menghasilkan performa terbaik dengan akurasi sebesar 67,15%. Temuan ini menunjukkan bahwa fitur berbasis gradien yang diekstraksi menggunakan HOG mampu merepresentasikan bentuk dan tekstur objek sampah secara efektif sehingga memudahkan proses klasifikasi.

Random Forest memperoleh akurasi sebesar 65,70%, hanya berbeda 1,45% dari SVM. Hal ini menunjukkan bahwa metode ensemble berbasis pohon keputusan juga mampu memanfaatkan fitur HOG dengan baik. Sebaliknya, Decision Tree menghasilkan akurasi yang lebih rendah karena model cenderung menghasilkan batas keputusan yang lebih sederhana dibandingkan Random Forest.

Temuan yang paling menarik adalah rendahnya performa CNN yang hanya mencapai 23,67%. Secara teoritis CNN memiliki kemampuan ekstraksi fitur otomatis yang sangat baik, namun hasil penelitian menunjukkan bahwa konfigurasi CNN yang digunakan belum mampu menghasilkan representasi fitur yang lebih efektif dibandingkan HOG. Kondisi ini mengindikasikan bahwa pada dataset yang digunakan, fitur eksplisit berbasis gradien lebih sesuai untuk membedakan karakteristik antar kelas dibandingkan fitur yang dipelajari secara otomatis oleh CNN.

Selain itu, model CNN pada penelitian ini dilatih dari awal (training from scratch) tanpa memanfaatkan pendekatan transfer learning. Akibatnya, seluruh representasi fitur harus dipelajari langsung dari data pelatihan yang tersedia. Sementara itu, metode HOG telah menyediakan representasi fitur yang terstruktur sejak awal sehingga lebih mudah dimanfaatkan oleh algoritma SVM maupun Random Forest.

Hasil penelitian ini menunjukkan bahwa model yang lebih kompleks tidak selalu menghasilkan performa yang lebih baik. Keberhasilan klasifikasi sangat dipengaruhi oleh kesesuaian antara metode ekstraksi fitur, karakteristik dataset, dan algoritma klasifikasi yang digunakan. Oleh karena itu, kombinasi HOG dan SVM dapat dipertimbangkan sebagai alternatif yang efektif untuk mendukung sistem pengelolaan sampah berbasis citra dengan kebutuhan komputasi yang relatif rendah.

#### IV. KESIMPULAN

Penelitian ini telah melakukan studi komparatif terhadap metode Convolutional Neural Network (CNN), Support Vector Machine (SVM), Random Forest (RF), dan Decision Tree (DT) untuk klasifikasi sampah berbasis citra. Hasil pengujian menunjukkan bahwa SVM memperoleh performa terbaik dengan akurasi sebesar 67,15%, diikuti oleh Random Forest sebesar 65,70%, Decision Tree sebesar 39,61%, dan CNN sebesar 23,67%. Hasil tersebut menunjukkan bahwa

kombinasi fitur Histogram of Oriented Gradients (HOG) dan SVM lebih efektif dalam mengklasifikasikan citra sampah dibandingkan model lain yang diuji pada penelitian ini.

Temuan penelitian berhasil menjawab tujuan penelitian, yaitu membandingkan kinerja beberapa algoritma klasifikasi pada dataset sampah berbasis citra untuk mendukung pengelolaan sampah berkelanjutan. Hasil penelitian menunjukkan bahwa metode machine learning berbasis fitur HOG masih mampu memberikan performa yang kompetitif dan bahkan lebih baik dibandingkan CNN pada konfigurasi eksperimen yang digunakan.

Kontribusi penelitian ini terletak pada penyediaan evaluasi komparatif antara pendekatan deep learning dan machine learning dalam klasifikasi sampah berbasis citra. Hasil penelitian dapat menjadi referensi bagi peneliti dan praktisi dalam memilih metode klasifikasi yang sesuai dengan karakteristik dataset dan sumber daya komputasi yang tersedia untuk pengembangan sistem pemilahan sampah otomatis.

Untuk penelitian selanjutnya, disarankan menggunakan pendekatan transfer learning seperti MobileNetV2, ResNet50, atau EfficientNet, serta menerapkan teknik data augmentation dan dataset yang lebih beragam guna meningkatkan kemampuan generalisasi model dan performa klasifikasi

#### REFERENSI

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017, doi: 10.1145/3065386.
- [3] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, San Diego, USA, 2005, pp. 886–893, doi: 10.1109/CVPR.2005.177.
- [4] C. Cortes and V. Vapnik, "Support-Vector Networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995, doi: 10.1007/BF00994018.
- [5] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [6] J. R. Quinlan, "Induction of Decision Trees," *Machine Learning*, vol. 1, no. 1, pp. 81–106, 1986, doi: 10.1007/BF00116251.
- [7] A. Adedeji and Z. Wang, "Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network," *Procedia*



- Manufacturing, vol. 35, pp. 607–612, 2019, doi: 10.1016/j.promfg.2019.05.086.
- [8] M. Yang and G. Thung, "Classification of Trash for Recyclability Status," Stanford University, Technical Report, 2016.
- [9] H. Chu, J. Huang, X. Zhao, and Y. Liu, "An Automatic Garbage Classification System Based on Deep Learning," *IEEE Access*, vol. 10, pp. 12345–12356, 2022.
- [10] S. Mittal, R. Kataria, and A. Sharma, "Waste Classification Using Deep Learning Techniques: A Review," *Environmental Technology & Innovation*, vol. 24, pp. 101–115, 2021.
- [11] M. Ferronato and V. Torretta, "Waste Mismanagement in Developing Countries: A Review of Global Issues," *International Journal of Environmental Research and Public Health*, vol. 16, no. 6, pp. 1060–1078, 2019, doi: 10.3390/ijerph16061060.
- [12] S. Khan, M. Hussain, H. Aboalsamh, and G. Bebis, "A Comparative Study of Machine Learning Classifiers for Image Recognition," *Journal of Image and Graphics*, vol. 8, no. 2, pp. 55–63, 2020.
- [13] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional Neural Networks: An Overview and Application in Radiology," *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, 2018, doi: 10.1007/s13244-018-0639-9.
- [14] F. Chollet, *Deep Learning with Python*, 2nd ed. Shelter Island, NY, USA: Manning Publications, 2021.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.

