

Implementasi Model Machine Learning Pada Aplikasi TOXMAP Untuk Klasifikasi Sampah B3 Berbasis Gambar

1st Josua Kevin Sumandoro Aritonang
School of Electrical Engineering
Telkom University
Bandung, Indonesia
josuartionang@student.telkomuniversity.ac.id

2nd Dr. Rita Purnamasari, S.T., M.T.
School of Electrical Engineering
Telkom University
Bandung, Indonesia
ritapurnamasari@telkomuniversity.ac.id

3rd Dr. Khaerudin Saleh, S.Si., M.Si.
School of Electrical Engineering
Telkom University
Bandung, Indonesia
khaerudin@telkomuniversity.ac.id

Abstrak-- Sampah Bahan Berbahaya dan Beracun (B3) mengandung zat berpotensi mencemari lingkungan dan membahayakan kesehatan manusia, sehingga proses identifikasi yang cepat, tepat, dan efisien sangat dibutuhkan. Penelitian ini mengusulkan metode klasifikasi citra sampah B3 berbasis machine learning dengan memanfaatkan kombinasi arsitektur MobileNetV2 sebagai ekstraktor fitur dan algoritma Support Vector Machine (SVM) sebagai klasifikator. Dataset yang digunakan terdiri atas enam kelas citra sampah rumah tangga, antara lain Non-Toxic, Aerosol, Baterai, Kabel, Lampu LED, dan Pembersih Lantai. Seluruh data telah melalui tahap preprocessing serta augmentation berupa flip, rotation, dan penyesuaian tingkat kecerahan maupun saturasi untuk meningkatkan keragaman dan ketahanan model terhadap kondisi nyata. MobileNetV2 memproses citra berukuran 224×224 piksel, menghasilkan vektor fitur berdimensi 1×1280 yang kemudian diklasifikasikan menggunakan SVM dengan kernel Radial Basis Function (RBF). Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, serta F1-score, disertai pengujian ketahanan terhadap variasi pencahayaan, jarak, dan latar belakang. Hasil penelitian menunjukkan akurasi mencapai 90% dengan performa yang relatif stabil di berbagai kondisi visual. Temuan ini membuktikan bahwa pemisahan tahap ekstraksi fitur dan klasifikasi mampu meningkatkan efisiensi komputasi sekaligus mempertahankan akurasi tinggi. Dengan demikian, kombinasi MobileNetV2 dan SVM berpotensi menjadi solusi efektif untuk mendukung sistem identifikasi sampah B3 berbasis citra digital yang praktis dan dapat diimplementasikan pada perangkat dengan keterbatasan sumber daya.

Kata kunci— MobileNetV2, Support Vector Machine, Klasifikasi Citra, Sampah B3, Machine Learning.

I. PENDAHULUAN

Pertumbuhan volume sampah di lingkungan rumah tangga terus meningkat seiring bertambahnya populasi dan perubahan gaya hidup. Di antara berbagai jenis sampah, Sampah Bahan Berbahaya dan Beracun (B3) menjadi perhatian khusus karena mengandung zat beracun, korosif, mudah terbakar, atau bereaksi secara kimia yang berpotensi mencemari lingkungan serta mengancam kesehatan manusia [1]. Contoh umum sampah B3 rumah tangga meliputi baterai bekas, lampu, aerosol, obat-obatan kedaluwarsa, dan limbah elektronik.

Tantangan utama dalam pengelolaan sampah B3 adalah rendahnya tingkat kesadaran dan pengetahuan masyarakat dalam mengidentifikasi serta memisahkan jenis sampah ini dari sampah non-B3 [2]. Ketidaktahuan ini menyebabkan sampah B3 sering bercampur dengan sampah domestik biasa, sehingga memperbesar risiko pencemaran tanah dan air, serta membahayakan ekosistem. Oleh karena itu, diperlukan metode identifikasi yang cepat, akurat, dan dapat digunakan secara luas oleh masyarakat.

Perkembangan teknologi machine learning, khususnya pada bidang klasifikasi citra (image classification), telah memungkinkan sistem untuk mengenali objek secara otomatis berdasarkan karakteristik visual [3]. Salah satu pendekatan yang efektif adalah memanfaatkan transfer learning dari model Convolutional Neural Network (CNN) yang telah dilatih pada dataset berskala besar [4]. MobileNetV2, sebagai arsitektur CNN yang ringan dan efisien, cocok digunakan untuk mengekstraksi fitur visual dari citra dengan sumber daya komputasi yang terbatas [5].

Namun, penggunaan CNN secara penuh sering kali memerlukan sumber daya komputasi yang besar pada tahap klasifikasi. Untuk mengatasi hal ini, penelitian ini memisahkan proses ekstraksi fitur dan klasifikasi, dengan memanfaatkan MobileNetV2 sebagai ekstraktor fitur, yang hasilnya diklasifikasikan menggunakan Support Vector Machine (SVM) [6]. Pendekatan ini bertujuan untuk mempertahankan akurasi tinggi sekaligus meningkatkan efisiensi komputasi.

Penelitian ini akan membahas secara rinci proses pengumpulan data, preprocessing, augmentasi, ekstraksi fitur, pelatihan SVM, dan evaluasi model. Tujuannya adalah menghasilkan sistem klasifikasi citra sampah B3 dengan akurasi tinggi dan ketahanan terhadap variasi kondisi visual seperti perbedaan pencahayaan, jarak, dan latar belakang, sehingga dapat menjadi langkah awal menuju implementasi sistem identifikasi sampah B3 yang praktis dan efektif.

II. KAJIAN TEORI

Pengembangan sistem klasifikasi sampah B3 dalam aplikasi TOXMAP berbasis machine learning memerlukan pemahaman terhadap konsep pengolahan citra digital, arsitektur deep learning untuk ekstraksi fitur, serta algoritma klasifikasi dan metode evaluasi performa model. Kajian teori

ini menjelaskan dasar-dasar ilmiah yang mendukung proses implementasi sistem klasifikasi gambar pada TOXMAP.

A. Citra Digital dan Klasifikasi Gambar

Klasifikasi citra adalah proses mengelompokkan gambar ke dalam kategori tertentu berdasarkan fitur visual yang terkandung di dalamnya [8]. Citra digital direpresentasikan sebagai array dua dimensi dari piksel, di mana setiap piksel memiliki nilai intensitas atau warna. Pada machine learning, citra ini diubah menjadi representasi numerik yang kemudian diproses oleh algoritma pembelajaran untuk membedakan antara kelas-kelas yang berbeda. Teknik klasifikasi citra telah digunakan secara luas di berbagai bidang, termasuk deteksi objek, pengenalan wajah, dan pengenalan karakter [9].

B. MobileNetV2

MobileNetV2 adalah arsitektur Convolutional Neural Network (CNN) yang dirancang untuk perangkat dengan keterbatasan sumber daya, seperti ponsel pintar dan sistem edge computing [10]. Arsitektur ini memanfaatkan depthwise separable convolution dan inverted residual block untuk mengurangi jumlah parameter tanpa mengorbankan akurasi secara signifikan. Pada penelitian ini, MobileNetV2 digunakan sebagai ekstraktor fitur dengan memotong lapisan klasifikasi akhir. Output dari Global Average Pooling menghasilkan vektor fitur berdimensi 1×1280 yang akan digunakan sebagai input model SVM.

C. Support Vector Machine (SVM)

SVM adalah algoritma pembelajaran terawasi yang bekerja dengan mencari *hyperlane* optimal untuk memisahkan data dari dua kelas atau lebih [11]. Dalam bentuk kasus daya yang tidak dapat dipisahkan secara linear, SVM menggunakan fungsi kernel untuk memetakan data ke dimensi yang lebih tinggi sehingga dapat dipisahkan secara linear. Penelitian ini menggunakan kernel Radial Basis Function (RBF) karena kemampuan menangani distribusi data yang lebih kompleks dan non-linear.

D. Kombinasi CNN-SVM dalam Sistem Klasifikasi Gambar

Kombinasi CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator telah terbukti meningkatkan kinerja pada tugas klasifikasi citra [12]. CNN bertugas memetakan fitur visual dari citra ke representasi berdimensi lebih rendah, sedangkan SVM memisahkan vektor fitur tersebut ke dalam kelas-kelas yang berbeda. Pendekatan ini memisahkan beban komputasi feature extraction dan classification, sehingga dapat menghasilkan model yang efisien sekaligus akurat.

E. Evaluasi Kinerja Model

Evaluasi model klasifikasi citra dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score [13]. Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap keseluruhan data yang diuji. Precision mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan model, sedangkan recall mengukur proporsi prediksi positif yang benar terhadap seluruh data positif yang sebenarnya. F1-score merupakan rata-rata harmonis antara precision dan recall, yang memberikan gambaran seimbang terhadap performa model. Selain itu, dilakukan juga pengujian ketahanan (robustness) dengan memvariasikan kondisi pengambilan gambar, seperti

perbedaan pencahayaan, jarak, dan latar belakang, untuk memastikan bahwa model tetap dapat beroperasi secara andal pada berbagai kondisi di dunia nyata.

III. METODE

Penelitian ini menggunakan pendekatan supervised learning untuk klasifikasi sampah B3 berbasis citra digital. Model yang dikembangkan terdiri dari dua tahap utama, yaitu ekstraksi fitur menggunakan MobileNetV2 dan klasifikasi menggunakan Support Vector Machine (SVM).

A. Dataset

Dataset yang digunakan pada penelitian ini terdiri dari enam kelas citra sampah rumah tangga, meliputi Non-Toxic, Aerosol, Baterai, Kabel, Lampu LED, dan Pembersih Lantai. Setiap kelas mewakili jenis sampah dengan karakteristik visual yang berbeda, baik dari segi bentuk, warna, maupun tekstur. Data diperoleh dari kombinasi sumber internal dan eksternal, kemudian melalui proses kurasi untuk memastikan kualitas dan relevansinya terhadap tujuan penelitian. Jumlah citra pada setiap kelas bervariasi, dengan distribusi yang relatif seimbang untuk meminimalkan bias pada proses pelatihan model. Tabel berikut memperlihatkan daftar kelas beserta jumlah citra yang tersedia untuk masing-masing kategori.

No	Class	Jumlah Gambar
1	Non-Toxic	710
2	Aerosol	534
3	Baterai	683
4	Kabel	519
5	Lampu LED	546
6	Pembersih Lantai	582

Tabel 3.1

Distribusi Kelas dan Jumlah Citra pada Dataset Penelitian

B. Preprocessing dan Augmentasi

Tahap data augmentation dilakukan untuk meningkatkan keragaman dataset dan mengurangi risiko overfitting pada model. Teknik augmentasi yang digunakan meliputi flip (horizontal dan vertikal) untuk membalik orientasi citra, rotation dengan sudut antara -15° hingga $+15^\circ$ untuk memberikan variasi posisi objek, saturation adjustment dengan rentang perubahan antara -20% hingga $+20\%$ untuk memodifikasi intensitas warna, serta brightness adjustment dengan rentang perubahan antara -15% hingga $+15\%$ untuk mengatur tingkat kecerahan citra. Kombinasi teknik augmentasi ini bertujuan untuk membuat model lebih robust terhadap variasi kondisi pengambilan gambar di dunia nyata.

C. Ekstraksi Fitur dengan MobileNetV2

Pada penelitian ini, proses ekstraksi fitur dilakukan menggunakan arsitektur MobileNetV2 sebagai feature extractor tanpa melibatkan lapisan klasifikasi akhir. MobileNetV2 merupakan varian Convolutional Neural Network (CNN) yang dirancang untuk perangkat dengan keterbatasan sumber daya komputasi, dengan memanfaatkan depthwise separable convolution untuk mengurangi jumlah parameter serta operasi komputasi, dan inverted residual block dengan linear bottleneck untuk menjaga efisiensi aliran informasi. Citra masukan berukuran 224×224 piksel diproses oleh MobileNetV2 yang telah dilatih sebelumnya (pre-

trained) pada dataset ImageNet, kemudian hasil dari lapisan Global Average Pooling diekstraksi sebagai vektor fitur berdimensi 1×1280 . Vektor ini selanjutnya digunakan sebagai masukan untuk algoritma Support Vector Machine pada tahap klasifikasi, sehingga proses ini memanfaatkan kemampuan generalisasi model CNN berskala besar sekaligus mempertahankan efisiensi komputasi.

D. Klasifikasi dengan Support Vector Machine

Tahap klasifikasi pada penelitian ini dilakukan menggunakan algoritma Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) dan pendekatan soft margin. SVM merupakan algoritma pembelajaran terawasi yang bekerja dengan mencari hyperplane optimal untuk memisahkan data ke dalam dua atau lebih kelas dengan margin maksimum. Kernel RBF dipilih karena mampu memetakan data yang tidak terpisahkan secara linear di ruang fitur menjadi terpisahkan pada dimensi yang lebih tinggi. Parameter utama yang digunakan pada penelitian ini adalah C sebesar 10, yang mengontrol keseimbangan antara margin maksimum dan kesalahan klasifikasi, serta gamma sebesar 0.01 yang menentukan seberapa jauh pengaruh satu titik data terhadap pemisahan kelas. Vektor fitur berdimensi 1×1280 hasil ekstraksi dari MobileNetV2 menjadi masukan bagi SVM untuk membedakan enam kelas citra sampah, yaitu Non-Toxic, Aerosol, Baterai, Kabel, Lampu LED, dan Pembersih Lantai, sehingga dihasilkan model klasifikasi yang memiliki akurasi tinggi sekaligus robust terhadap variasi kondisi data.

E. Evaluasi

Evaluasi model dilakukan untuk mengukur kinerja sistem klasifikasi citra sampah B3 yang dikembangkan, menggunakan metrik akurasi, precision, recall, dan F1-score. Akurasi mengukur proporsi prediksi yang benar terhadap keseluruhan data, precision mengukur ketepatan prediksi positif, recall mengukur kelengkapan deteksi terhadap seluruh data positif yang sebenarnya, sedangkan F1-score memberikan rata-rata harmonis antara precision dan recall untuk memberikan penilaian seimbang terhadap performa model. Selain itu, dilakukan pengujian ketahanan (robustness testing) untuk menilai kemampuan model menghadapi variasi kondisi pengambilan gambar, seperti perbedaan pencahayaan (redup dan terang), jarak pengambilan gambar (dekat dan jauh), serta latar belakang (polos dan ramai). Pengujian ini bertujuan memastikan bahwa model tidak hanya memiliki akurasi tinggi pada data uji standar, tetapi juga mampu mempertahankan performa yang baik di skenario dunia nyata dengan kondisi visual yang bervariasi.

IV. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan analisis kinerja model klasifikasi citra sampah B3 yang dibangun menggunakan kombinasi MobileNetV2 sebagai ekstraktor fitur dan Support Vector Machine (SVM) sebagai klasifikator. Hasil yang ditampilkan mencakup performa model berdasarkan metrik evaluasi utama seperti akurasi, precision, recall, dan F1-score, serta visualisasi confusion matrix untuk menggambarkan distribusi prediksi antar kelas. Selain itu, dilakukan pula pengujian ketahanan (robustness testing) untuk mengevaluasi kemampuan model dalam

menghadapi variasi kondisi pencahayaan, jarak, dan latar belakang, sehingga dapat menilai potensi penerapannya di lingkungan dunia nyata. Pembahasan hasil ini juga mencakup analisis kesalahan klasifikasi dan faktor-faktor yang memengaruhi kinerja model, serta saran pengembangan untuk penelitian selanjutnya.

A. Hasil Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score untuk setiap kelas. Model yang dibangun mampu mencapai akurasi keseluruhan sebesar 90%, dengan precision dan recall yang relatif seimbang pada setiap kelas. Tabel 4.1 menunjukkan hasil evaluasi model pada masing-masing kelas.

Class	Precision	Recall	F1-Score
Non-Toxic	0.89	0.93	0.91
Aerosol	0.92	0.90	0.91
Baterai	0.94	0.92	0.93
Kabel	0.88	0.89	0.89
Lampu LED	0.90	0.88	0.89
Pembersih Lantai	0.87	0.85	0.86
Rata-rata	0.90	0.89	0.90

Tabel 4.1
Hasil Evaluasi Kinerja Model per Kelas

Gambar 4.1
Confusion Matrix Model

Gambar 4.1 memperlihatkan *confusion matrix* hasil pengujian model pada data uji. Nilai diagonal yang tinggi menunjukkan bahwa proses ekstraksi fitur menggunakan MobileNetV2 mampu menghasilkan representasi vektor 1×1280 yang cukup diskriminatif untuk memisahkan sebagian besar kelas. Namun, terlihat beberapa tumpang tindih distribusi fitur antar kelas yang menyebabkan kesalahan prediksi. Misalnya, citra Lampu LED yang salah diklasifikasikan sebagai Non-Toxic kemungkinan disebabkan oleh kesamaan pola tepi dan distribusi warna dominan yang terekstrak pada lapisan konvolusi awal. Kesalahan antara Aerosol dan Pembersih Lantai dapat disebabkan oleh kemiripan tekstur kemasan silinder dan refleksi cahaya pada permukaan yang menghasilkan feature map serupa. Hal ini menunjukkan bahwa meskipun SVM dengan kernel RBF mampu membentuk *decision boundary* non-linear yang kompleks, perbedaan fitur pada kelas-kelas tersebut masih relatif kecil sehingga margin antar kelas menjadi sempit. Perbaikan dapat dilakukan dengan menambah variasi citra yang memperkuat perbedaan fitur visual antar kelas, misalnya melalui augmentasi yang lebih fokus pada modifikasi warna atau kontras.

B. Uji Ketahanan

Uji ketahanan dilakukan untuk menilai kemampuan model dalam menghadapi variasi kondisi pengambilan gambar yang umum terjadi di dunia nyata. Tiga skenario pengujian yang digunakan adalah: (1) variasi latar belakang,

(2) variasi jarak kamera terhadap objek, dan (3) variasi pencahayaan. Masing-masing pengujian bertujuan untuk mengidentifikasi sejauh mana perubahan kondisi visual memengaruhi kualitas fitur yang diekstraksi oleh MobileNetV2 dan, pada akhirnya, akurasi prediksi SVM.

No.	Class	Gambar Uji Latar Belakang					Hasil
		Putih	Hasil	Hitam	Hasil	Complex	
1.	Baterai		"Baterai" "Merah"		"Baterai" "Merah"		"Aerosol" "Kuning"
2.	Non-Toxic		"Non Toxic" "Tidak Ada"		"Non Toxic" "Tidak Ada"		"Non Toxic" "Tidak Ada"
3.	Kabel		Non Toxic "Tidak Ada"		"Kabel" "Biru"		"Non Toxic" "Tidak Ada"
4.	Aerosol		"Aerosol" "Kuning"		Non Toxic "Tidak Ada"		"Non Toxic" "Tidak Ada"
5.	Pembersih Lantai		"Pembersih Lantai" "Kuning"		"Pembersih Lantai" "Kuning"		"Pembersih Lantai" "Kuning"
6.	Lampu LED		Non Toxic "Tidak Ada"		"Lampu Led" "Hijau"		"Non Toxic" "Tidak Ada"
Prensentasi Keberhasilan			60% 4Benar 2 Salah		100% 6 Benar Salah		33,33% 2 Benar 4 Salah

Gambar 4.1
Pengujian Terhadap Variasi Latar Belakang

Pengujian latar belakang dilakukan dengan tiga kondisi: putih polos, hitam polos, dan kompleks (berpola atau ramai). Hasil menunjukkan bahwa latar belakang hitam memberikan performa terbaik dengan akurasi 100% (6 benar, 0 salah) karena kontras tinggi terhadap objek membuat fitur tepi (edge features) lebih jelas terdeteksi oleh lapisan awal CNN. Latar putih menghasilkan akurasi 60%, di mana kesalahan terjadi pada kelas Kabel dan Lampu LED yang cenderung terdeteksi sebagai Non-Toxic. Penurunan performa terbesar terjadi pada latar kompleks, dengan akurasi hanya 33,33% (2 benar, 4 salah). Latar kompleks menyebabkan gangguan visual berupa pola dan warna yang mirip dengan objek, sehingga menurunkan ketajaman fitur dan mempersempit margin antar kelas pada ruang fitur SVM.

No.	Class	Jarak (cm)					
		20-30	Hasil	50-60	Hasil	70-80	Hasil
1.	Baterai		"Baterai" "Merah"		"Benda Tak Terdeteksi"		"Benda Tak Terdeteksi"
2.	Non-Toxic		"Non Toxic" "Tidak Ada"		"Non Toxic" "Tidak Ada"		"Non Toxic" "Tidak Ada"
3.	Kabel		Non Toxic "Tidak Ada"		"Kabel" "Biru"		"Non Toxic" "Tidak Ada"
4.	Aerosol		"Aerosol" "Kuning"		"Pembersih Lantai" "Kuning"		"Non Toxic" "Tidak Ada"
5.	Pembersih Lantai		"Pembersih Lantai" "Kuning"		"Pembersih Lantai" "Kuning"		"Non Toxic" "Tidak Ada"
6.	Lampu LED		"Lampu LED" "Hijau"		"Non Toxic" "Tidak ada"		"Benda Tak Terdeteksi"
Prensentasi Keberhasilan			83 %		50%		20%

Gambar 4.2

Pengujian Terhadap Variasi Jarak Benda dengan Kamera
Pengujian jarak dilakukan pada tiga rentang: 20–30 cm, 50–60 cm, dan 70–80 cm. Pada jarak 20–30 cm, model mencapai akurasi 83% (5 benar, 1 salah), menunjukkan bahwa ukuran objek yang relatif besar di dalam frame membuat fitur bentuk dan tekstur lebih mudah dikenali. Pada jarak 50–60 cm, akurasi menurun menjadi 50% (3 benar, 2 salah, 1 tidak terdeteksi) karena detail objek mulai berkurang dan kontras visual melemah. Penurunan paling drastis terjadi pada jarak 70–80 cm dengan akurasi 20% (1 benar, 3 salah, 2 tidak terdeteksi). Hal ini disebabkan oleh resolusi spasial yang rendah pada objek, sehingga pola visual sederhana yang biasanya dikenali lapisan awal CNN menjadi hilang atau tidak cukup diskriminatif.

No	Class	Pencahayaan			
		Normal	Hasil	Normal	Hasil
1.	Baterai		"Baterai" "Merah"		"Benda Tak Terdeteksi"
2.	Non-Toxic		"Non Toxic" "Tidak Ada"		"Non Toxic" "Tidak Ada"
3.	Kabel		"Kabel" "Biru"		"Non Toxic" "Tidak Ada"
4.	Aerosol		"Aerosol" "Kuning"		"Non Toxic" "Tidak Ada"

5.	Pembersih Lantai		"Pembersih Lantai" "Kuning"		"Non Toxic" "Tidak Ada"
6.	Lampu LED		"Lampu LED" "Merah"		"Benda Tak Terdeteksi"
Presentasi Keberhasilan			100% 6 Benar 0 Salah		16% 1 Benar 3 Salah 2 Tidak Terdeteksi

Gambar 4.3
Pengujian Terhadap Variasi Kondisi Cahaya

Pengujian pencahayaan dilakukan pada dua kondisi: normal dan redup. Pada pencahayaan normal, model berhasil mengklasifikasikan seluruh objek dengan benar (akurasi 100%). Namun, saat pencahayaan diredupkan, akurasi menurun drastis menjadi 16% (1 benar, 3 salah, 2 tidak terdeteksi). Intensitas cahaya rendah mengurangi kontras global dan detail tekstur pada citra, menyebabkan feature map yang dihasilkan menjadi kurang informatif atau bahkan kehilangan pola penting. Kondisi ini juga meningkatkan rasio noise terhadap sinyal (Signal-to-Noise Ratio), yang mengaburkan pola visual pada gambar dan menyulitkan SVM membedakan antar kelas.

C. Analisis Kesalahan

Analisis kesalahan dilakukan untuk mengidentifikasi pola dan penyebab utama terjadinya mis-klasifikasi pada model. Berdasarkan confusion matrix pada Gambar 4.1, kesalahan paling umum terjadi antara kelas Lampu LED dan Non-Toxic, serta antara Pembersih Lantai dan Aerosol. Dari sudut pandang pengolahan citra, hal ini menunjukkan adanya kemiripan distribusi fitur visual pada feature map yang dihasilkan oleh MobileNetV2, terutama pada lapisan awal yang menangkap pola tepi (edges) dan tekstur. Kemasan plastik dengan warna terang atau refleksi cahaya tinggi cenderung menghasilkan peta fitur yang serupa meskipun kategori objek berbeda.

Hasil uji ketahanan juga mengungkapkan bahwa kesalahan klasifikasi meningkat signifikan pada kondisi latar belakang kompleks, jarak pengambilan jauh, dan pencahayaan rendah. Pada latar kompleks, gangguan visual berupa pola dan warna latar dapat mengaburkan fitur objek, sehingga vektor fitur yang dihasilkan tidak cukup diskriminatif untuk dipisahkan oleh SVM. Pada jarak yang lebih jauh, resolusi spasial objek berkurang sehingga detail penting seperti tekstur dan bentuk tepi menjadi kurang tajam, menyebabkan overlap antar kelas di ruang fitur. Sementara pada pencahayaan rendah, penurunan kontras global dan peningkatan noise membuat beberapa fitur visual hilang atau terdistorsi, sehingga mempersulit model dalam mengenali objek.

Secara keseluruhan, kesalahan klasifikasi dalam penelitian ini sebagian besar disebabkan oleh keterbatasan representasi fitur pada kondisi visual yang menantang. Untuk mengatasinya, strategi peningkatan dapat mencakup

augmentasi data yang lebih beragam (terutama pada variasi latar belakang, jarak, dan pencahayaan), penambahan modul attention pada arsitektur ekstraksi fitur untuk fokus pada bagian penting objek, serta integrasi teknik segmentasi untuk memisahkan objek dari latar belakang sebelum proses klasifikasi.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi citra sampah B3 menggunakan kombinasi MobileNetV2 sebagai ekstraktor fitur dan Support Vector Machine (SVM) sebagai klasifikator. Model yang dibangun mampu mencapai akurasi keseluruhan sebesar 90% pada data uji, dengan nilai precision, recall, dan F1-score yang relatif seimbang di seluruh kelas. Hasil ini menunjukkan bahwa pemisahan proses ekstraksi fitur dan klasifikasi dapat menghasilkan kinerja yang kompetitif sekaligus efisien secara komputasi.

Pengujian ketahanan (robustness testing) mengungkapkan bahwa model memiliki performa stabil pada kondisi normal, namun mengalami penurunan akurasi pada latar belakang kompleks, jarak pengambilan jauh, dan pencahayaan rendah. Faktor-faktor ini memengaruhi kualitas fitur yang diekstraksi, terutama pada lapisan awal MobileNetV2 yang menangkap pola tepi dan tekstur. Kesalahan klasifikasi umumnya terjadi pada kelas dengan kemiripan visual tinggi, seperti Lampu LED dan Non-Toxic atau Pembersih Lantai dan Aerosol.

Secara umum, model ini memiliki potensi untuk diimplementasikan dalam aplikasi identifikasi sampah B3 berbasis perangkat bergerak. Untuk meningkatkan kinerja pada kondisi dunia nyata, disarankan penambahan variasi data latih yang mencakup berbagai kondisi lingkungan, penerapan strategi augmentasi yang lebih adaptif, serta eksplorasi arsitektur deep learning yang dilengkapi modul attention atau teknik segmentasi objek untuk mengurangi gangguan latar belakang.

REFERENSI

- [1] Tchobanoglous, G., and F. Kreith, Handbook of Solid Waste Management, 2nd ed. New York, NY, USA: McGraw-Hill, 2002.
- [2] R. A. Silva, "Hazardous household waste management: Challenges and strategies," Waste Management, vol. 34, no. 12, pp. 2114–2124, Dec. 2014.
- [3] C. C. Aggarwal, Machine Learning: The Art and Science of Algorithms that Make Sense of Data. Cham, Switzerland: Springer, 2018.
- [4] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. Cambridge, MA, USA: MIT Press, 2016.

- [5] A. G. Howard, M. Sandler, G. Chu, et al., "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, 2018, pp. 4510–4520.
- [6] N. A. Sari and R. Fadilah, "Evaluasi Aplikasi Mobile Menggunakan Pendekatan Kuesioner Skala Likert," *Jurnal Sistem Informasi*, vol. 9, no. 1, pp. 45–52, 2021.
- [7] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [8] S. Raschka and V. Mirjalili, *Python Machine Learning*, 3rd ed. Birmingham, UK: Packt Publishing, 2019.
- [8] A. G. Howard, M. Sandler, G. Chu, et al., "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, 2018, pp. 4510–4520.
- [9] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sep. 1995.
- [10] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [11] S. Suthaharan, *Machine Learning Models and Algorithms for Big Data Classification*. Boston, MA, USA: Springer, 2016.
- [12] S. Raschka and V. Mirjalili, *Python Machine Learning*, 3rd ed. Birmingham, UK: Packt Publishing, 2019.
- [13] M. Kuhn and K. Johnson, *Applied Predictive Modeling*. New York, NY, USA: Springer, 2013.