

## KLASIFIKASI OTOMATIS SAMPAH KERING MENGGUNAKAN HSV COLOR SPACE, SEGMENTASI MORFOLOGI, DAN EXTREME LEARNING MACHINE

Abuzar Gafari, Dito Jurinaldo, Agung Ramadhanu

Magister Teknik Informatika, Universitas Putra Indonesia Yptk Padang

Jl. Raya Lubuk Begalung, Lubuk Begalung Nan XX, Kecamatan Lubuk Begalung Kota Padang Sumbar

gafariabuzar.2@gmail.com

### ABSTRAK

Pengelolaan sampah di Indonesia masih bergantung pada pemilahan manual, sehingga menimbulkan inefisiensi dan tingginya kesalahan klasifikasi. Untuk mengatasi masalah ini, penelitian ini bertujuan mengembangkan sistem klasifikasi sampah kering berbasis citra digital secara otomatis. Metode yang digunakan merupakan gabungan dari ekstraksi ciri berbasis ruang warna HSV, segmentasi morfologi (dilatasi dan erosi), serta *Extreme Learning Machine (ELM)* untuk klasifikasi objek. Dataset terdiri dari 30 citra data latih dan 12 citra uji yang dibagi jadi tiga kelas sampah, botol kaleng, kertas, dan botol plastik. Proses diawali dengan konversi citra ke HSV, segmentasi objek melalui thresholding kanal Value, dan ekstraksi 5 fitur geometri (seperti luas dan keliling). Model ELM dengan arsitektur 5-10-3 (input-hidden-output) dilatih menggunakan fungsi aktivasi sigmoid. Hasilnya, sistem mencapai akurasi 100% pada data latih dan 91,66% pada data uji, dengan satu kesalahan klasifikasi pada kelas botol plastik. Hasil penelitian menunjukkan bahwa gabungan HSV, morfologi, dan ELM efektif untuk dataset kecil, meskipun perlu adanya peningkatan pada variasi sampel untuk hasil yang lebih baik. Temuan ini membuka peluang penerapan otomatisasi pengelolaan sampah dengan biaya komputasi rendah.

**Kata kunci :** HSV, Segmentasi Morfologi, ELM, Klasifikasi Sampah, Citra Digital

### 1. PENDAHULUAN

Pengelolaan sampah telah menjadi isu global yang mendesak, namun hingga kini masih menjadi tantangan besar bagi banyak negara, termasuk Indonesia. Adapun upaya untuk mengatasi permasalahan ini, setiap negara terus melakukan peningkatan sistem pengelolaannya. Di Indonesia sendiri, berdasarkan data Kementerian Lingkungan Hidup dan Kehutanan (KLHK) tahun 2024, timbulan sampah nasional mencapai lebih dari 34 juta ton per tahun, dan sekitar 28,42% dari total sampah rumah tangga itu berasal dari sampah anorganik kering seperti botol plastik, kertas, dan kaleng [1]. Salah satu kendala utama dalam pengelolaan sampah adalah proses pemilahan yang masih dilakukan secara manual. Metode ini tidak hanya memakan waktu lama, tetapi juga rentan terhadap kesalahan klasifikasi [2], [3], terutama jika diterapkan dalam skala besar. Oleh karena itu, diperlukan solusi yang lebih efisien dan akurat untuk mengoptimalkan pengelolaan sampah di Indonesia.

Seiring berkembangnya teknologi, pendekatan berbasis pengolahan citra digital dan kecerdasan buatan semakin banyak diaplikasikan dalam sistem klasifikasi objek, termasuk untuk pemilahan sampah. Salah satu metode yang populer dalam pengolahan citra adalah penggunaan ruang warna HSV (*Hue, Saturation, Value*). Berbeda dengan RGB, HSV dinilai lebih unggul karena memiliki stabilitas yang lebih baik terhadap variasi pencahayaan serta representasi warna yang lebih akurat [4], [5].

Setelah citra objek dikonversi ke ruang warna HSV, langkah selanjutnya adalah melakukan segmentasi morfologi. Proses ini bertujuan untuk memisahkan objek utama dari latar belakang dengan

lebih presisi. Proses ini menggunakan metode penghitungan matematis seperti *dilation* dan *erosion*, yang berfungsi untuk memperjelas batas objek sekaligus mengurangi noise yang mengganggu [6]. Kemudian, setelah proses segmentasi morfologi selesai dengan baik, tahap berikutnya adalah melakukan klasifikasi. Dalam penelitian ini, digunakan algoritma *Extreme Learning Machine (ELM)* yang merupakan sebuah varian single-hidden layer feedforward neural network (SLFN) yang dikenal memiliki kecepatan pelatihan tinggi. Keunggulan ELM terletak pada inisialisasi bobot lapisan tersembunyi yang bersifat acak dan tidak memerlukan pembaruan, sementara bobot keluaran dihitung secara analitik [7]. Selain itu, ELM telah banyak digunakan pada penelitian yang berfokus pada pengklasifikasian citra karena efisiensinya, khususnya ketika bekerja dengan dataset berukuran terbatas [8].

Namun demikian, penelitian terdahulu masih didominasi oleh pendekatan deep learning yang kompleks dan memerlukan sumber daya komputasi tinggi, sehingga kurang sesuai untuk implementasi berskala kecil seperti pemilahan sampah rumah tangga atau UKM pengelola daur ulang. Oleh karena itu, dibutuhkan pendekatan yang efektif dalam pengklasifikasian sampah kering, terutama untuk sistem yang dirancang berbasis perangkat lunak sederhana seperti MATLAB atau aplikasi Android berbasis citra.

Penelitian ini diinisiasi dengan menyusun dataset dari berbagai sumber daring, kemudian dilakukan praproses berupa penggantian latar belakang menjadi putih dan penyeragaman ukuran gambar menjadi 300×300 piksel. adapun jenis sampah kering yang akan diolah, diklasifikasikan kedalam tiga buah kelas,

yaitu kelas sampah botol kaleng, kertas, dan botol deterjen, dan masing-masing kelas memiliki sampel data citra sebanyak 10 data latih. sementara untuk pengujian data menggunakan data uji sebanyak 12 data uji dengan sebaran 4 botol kaleng, 2 kertas, dan 6 botol deterjen. Sistem dikembangkan berdasarkan ekstraksi fitur warna dan morfologi, lalu diklasifikasikan menggunakan *ELM*.

Tujuan utama dari penelitian ini adalah untuk mengembangkan sistem klasifikasi otomatis sampah kering berbasis citra digital menggunakan kombinasi metode HSV, segmentasi morfologi, dan *ELM*. Serta bertujuan menguji tingkat keefektifitasan pendekatan ini dalam mengelompokkan jenis sampah dengan akurasi tinggi walaupun dengan jumlah data yang terbatas. Signifikansi dari penelitian ini terletak pada kontribusinya terhadap pengembangan sistem klasifikasi sampah yang efisien, murah, dan dapat diadopsi secara luas, baik di rumah tangga, sekolah, maupun UKM pengelola sampah. Di samping itu, hasil penelitian ini juga diharapkan dapat memperkuat literatur terkait pemanfaatan *ELM* dan fitur berbasis HSV-morfologi dalam sistem klasifikasi citra, serta membuka peluang untuk implementasi lebih lanjut ke dalam antarmuka grafis atau aplikasi mobile.

Untuk memperkuat dasar teoritis, bagian berikut membahas teknologi yang digunakan dalam penelitian ini, mulai dari sistem klasifikasi berbasis citra digital hingga pemanfaatan algoritma *Extreme Learning Machine (ELM)*.

## 2. TINJAUAN PUSTAKA

### 2.1. Teknologi Klasifikasi Sampah Berbasis Citra Digital

Klasifikasi sampah dengan citra digital merupakan salah satu pendekatan terkini yang menggunakan ciri visual seperti warna, bentuk, dan tekstur dari objek untuk diidentifikasi secara otomatis. Meskipun *CNN* secara umum dikenal lebih unggul dalam ekstraksi fitur secara mendalam, metode ini masih memiliki keterbatasan pada kebutuhan data besar dan analisis yang lebih kompleks, terutama dalam penerapan sistem waktu nyata [9], [10]. Untuk mengatasi hal ini, pendekatan hybrid yang menggabungkan *CNN* sebagai fitur *extractor* dengan algoritma classifier ringan seperti *Extreme Learning Machine (ELM)* menjadi pilihan yang banyak diteliti karena mampu menyeimbangkan antara keakuratan dan peningkatan efektifitas sistem, menjadikannya penggunaannya sangat sesuai untuk aplikasi klasifikasi dengan penggunaan perangkat yang rendah daya [11].

### 2.2. Ruang Warna HSV (Hue, Saturation, Value)

Ruang warna *HSV* merupakan contoh dari representasi warna yang digunakan untuk memisahkan elemen berupa hue dan saturasi dari kecerahan [5], serta menjadikannya lebih stabil terhadap banyak variasi pencahayaan dibandingkan *RGB*. Kestabilan ruang warna *HSV* di nilai sangat cocok untuk

dimanfaatkan dalam identifikasi objek dengan warna dominan seperti plastik bening, kertas putih, atau logam reflektif. Tahun 2024, model ini banyak diintegrasikan dengan teknik segmentasi seperti *adaptive thresholding* dan clustering untuk meningkatkan isolasi objek dan memperkuat proses segmentasi visual, yang sangat bermanfaat dalam konteks sistem klasifikasi berbasis penglihatan komputer [12].

### 2.3. Segmentasi Morfologi

Segmentasi morfologi merupakan teknik penting dalam pra-pemrosesan citra yang menggunakan operasi logika biner seperti dilasi, erosi, dan thresholding untuk memperjelas batas objek dan mengurangi noise latar belakang. Teknik ini membantu memperbaiki kualitas citra dan memastikan hanya area relevan yang diproses pada tahap selanjutnya, seperti ekstraksi fitur dan klasifikasi. Kombinasi metode ini dengan ruang warna *HSV* banyak digunakan dalam sistem pengenalan visual karena kemampuannya dalam mempertajam bentuk objek dan menjaga konsistensi kontur visual, terutama dalam kondisi latar yang kompleks [13].

### 2.4. Extreme Learning Machine (ELM)

*Extreme Learning Machine (ELM)* merupakan algoritma jaringan saraf feedforward satu lapis tersembunyi yang dirancang untuk pelatihan cepat dengan bobot input acak dan bobot output dihitung secara eksplisit menggunakan solusi least-squares. Metode ini sangat efisien dan cocok untuk sistem real-time karena tidak memerlukan iterasi berulang dalam pelatihan. Penelitian terakhir menunjukkan bahwa *ELM* kian hari semakin fleksibel, sehingga membuatnya dapat lebih kompetitif dalam penanganan klasifikasi citra kompleks tanpa mengorbankan efisiensi pelatihan [14].

### 2.5. Penelitian Terdahulu

Penelitian terdahulu terkait klasifikasi sampah berbasis pengolahan citra telah menunjukkan berbagai pendekatan yang menjanjikan, mulai dari metode klasifikasi konvensional hingga pemanfaatan jaringan syaraf dalam. Sebagian besar pendekatan mengandalkan fitur warna, tekstur, dan bentuk sebagai representasi visual utama dalam membedakan jenis objek. Salah satu studi menggunakan model *Convolutional Neural Network (CNN)* untuk mengklasifikasikan botol plastik, kaca, dan kaleng dalam sistem penukaran sampah otomatis. Meskipun hasil akurasi pada proses pelatihan mencapai nilai 100% dan validasi sebesar 87%, hasil klasifikasi terhadap data uji nyata menurun drastis hingga mencapai 57,5%, hal ini menunjukkan keterbatasan model dalam melakukan generalisasi terhadap data baru [15]. Penelitian yang sama mengklasifikasikan sampah organik dan anorganik, masih menunjukkan adanya ketidakseimbangan performa, terlihat bahwa

sampah anorganik memperoleh hasil akurasi 96%, sementara sampah organik hanya 62% [16].

Fitur warna *HSV* banyak digunakan di berbagai penelitian untuk mengekstraksi ciri warna objek yang lebih dominan. Pada beberapa penelitian terdahulu, ruang warna *HSV* telah di uji dengan menggabungkan beberapa metode seperti ruang warna *Lab\** dan fitur tekstur *GLCM* menggunakan arsitektur *CNN* untuk melakukan klasifikasi penyakit daun, nilai akurasi yang dihasilkan mencapai 92,48% [17]. Sementara itu, pendekatan berbasis *HSV* dan algoritma *k-Nearest Neighbor (k-NN)* digunakan untuk mengklasifikasikan tingkat kematangan buah kelapa sawit, dengan hasil akurasi mencapai 94,16% [8]. Segmentasi objek berdasarkan warna juga dikaji dalam konteks citra medis. Dalam sebuah penelitian lainnya, metode thresholding pada ruang *HSV* dan *RGB* digunakan untuk segmentasi citra rontgen paru-paru, dan diperoleh temuan bahwa segmentasi menggunakan *HSV* menghasilkan kontur objek yang lebih optimal, khususnya pada nilai ambang tertentu [18]. Teknik ini relevan untuk diterapkan dalam sistem klasifikasi sampah guna memperoleh bentuk objek yang lebih bersih dan konsisten.

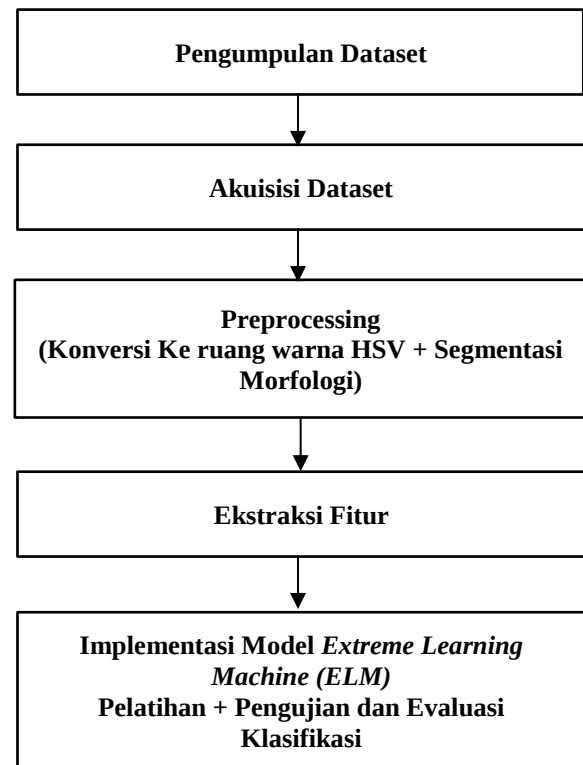
*Extreme Learning Machine (ELM)* telah banyak digunakan para peneliti sebagai alternatif untuk metode klasifikasi terbatas. Salah satu penelitian telah mencoba menggabungkan arsitektur *DP-CNN* dan *Ensemble ELM (En-ELM)* guna mengklasifikasikan citra sampah yang memiliki banyak kelas, dengan hasil akurasi mencapai 96% pada klasifikasi dengan kelas terendah menggunakan dua kelas, serta 85,25% pada klasifikasi menggunakan 36 kelas [19]. Studi lain memanfaatkan *ELM* yang dioptimasi menggunakan algoritma *PSO-AWDV* untuk klasifikasi kondisi stabilitas tambang batu bara, dan hasil evaluasi menunjukkan *AUC* sebesar 91,4% serta efisiensi waktu pelatihan yang tinggi [20].

Berdasarkan penelitian tersebut, terlihat jelas bahwa penggunaan fitur ruang warna *HSV*, segmentasi morfologi, dan *ELM* masing-masing tentunya memiliki keunggulan yang lebih dalam hal klasifikasi citra. Namun, penelitian yang secara menyeluruh menggabungkan ketiga pendekatan tersebut dalam satu sistem klasifikasi sampah kering belum banyak ditemukan. Kebanyakan studi masih bergantung pada *CNN* yang berat secara komputasi dan membutuhkan dataset dalam jumlah besar. Oleh karena itu, penelitian ini ditujukan untuk mengisi kesenjangan tersebut dengan merancang sistem klasifikasi otomatis sampah kering berbasis *HSV*, segmentasi morfologi, dan *ELM* yang efisien dan dapat diterapkan pada sistem ringan atau real-time.

### 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan merancang sistem klasifikasi otomatis sampah kering berbasis citra digital. Adapun beberapa tahapan pembangunan sistem klasifikasi citra sebagai berikut: pengumpulan

dan akuisisi dataset, preprocessing, ekstraksi fitur, pelatihan model menggunakan *Extreme Learning Machine (ELM)*, dan pengujian klasifikasi, seluruh proses dijalankan menggunakan perangkat lunak *MATLAB*. Setiap tahapan dijelaskan sebagai berikut:



Gambar 1. Diagram alir metodologi penelitian


Selanjutnya, masing-masing tahapan yang ditampilkan dalam Gambar 1 tersebut akan dijelaskan secara lebih rinci pada subbab berikut, mulai dari proses pengumpulan dataset hingga evaluasi performa klasifikasi menggunakan model *Extreme Learning Machine (ELM)*

#### 3.1. Pengumpulan dan Akuisisi Dataset

Dataset dalam penelitian ini dikumpulkan melalui dataset yang telah tersedia pada *kaggle.com* serta diambil langsung dari internet berupa citra sampah kering yang terdiri dari tiga kelas, yaitu botol kaleng, kertas, dan botol plastik. Setiap kelas terdiri dari 10 citra latih dan 12 citra uji dengan sebaran 4 citra uji kelas botol kaleng, 2 citra uji kelas kertas, dan 6 citra kelas botol plastik, sehingga total terdapat 30 data latih dan 12 data uji.

Citra yang telah diperoleh tahap selanjutnya akan diubah ukuran dan latarbelakang warnanya, dimana untuk ukuran diseragamkan menjadi 300x300 pixel dan latar belakang citranya menjadi putih untuk meminimalkan gangguan visual. Seluruh citra disimpan dalam format *.png* dan dikelompokkan ke dalam dua direktori, yaitu data latih dan data uji. Kemudian untuk penamaan kelas akan diberikan secara manual sesuai dengan jenis objek yang terdapat pada citra. Gambar 2 berikut menunjukkan beberapa

contoh citra dari masing-masing kelas pada dataset, yang telah diseragamkan ukurannya menjadi 300x300 piksel dan latar belakang putih:




Gambar 2. Contoh citra dari masing-masing kelas: (a) Botol Kaleng, (b) Kertas, dan (c) Botol Plastik

### 3.2. Preprocessing

Setiap citra yang diperoleh dan telah dilakukan proses resize dan penggantian latarbelakang akan dikonversi dari ruang warna *RGB* ke *HSV* menggunakan fungsi *rgb2hsv*. Komponen *Value* (*V*) dipilih karena paling stabil terhadap variasi warna dan pencahayaan. Segmentasi objek dilakukan dengan metode *thresholding* terhadap kanal *V* menggunakan ambang batas 0.9. Hasil *threshold* kemudian diproses lebih lanjut menggunakan median filtering, dilanjutkan dengan operasi *morfologi* seperti *filling holes*, *area opening*, dan *closing* untuk memperjelas kontur objek serta menghilangkan *noise* atau komponen yang tidak relevan. Gambar 3 menunjukkan

tahapan hasil preprocessing citra secara bertahap dari *RGB*, *HSV-V*, hasil *threshold*, dan morfologi akhir.



Gambar 3 Tahapan hasil preprocessing untuk citra kelas Botol Kaleng: (a) *RGB*, (b) kanal *Value* dari *HSV*, (c) hasil *thresholding*, dan (d) hasil morfologi.

### 3.3. Ekstraksi Fitur

Citra hasil segmentasi dikonversi menjadi data numerik dengan mengekstraksi lima fitur morfologi utama menggunakan fungsi *regionprops*, yaitu: luas area (*Area*), keliling (*Perimeter*), keeksentrikan (*Eccentricity*), panjang sumbu mayor (*Major Axis Length*), dan panjang sumbu minor (*Minor Axis Length*). Nilai tertinggi dari masing-masing fitur akan digunakan untuk membentuk vektor ciri berdimensi lima bagi setiap citra. Vektor-vektor fitur yang terbentuk tersebut kemudian digabungkan dengan nama kelas untuk membentuk data latih dan data uji. Tabel 1 berikut menyajikan contoh hasil ekstraksi fitur morfologi dari tiga citra yang telah diproses.

Tabel 1 Contoh hasil ekstraksi lima fitur morfologi dari citra hasil segmentasi

| Nama File     | Area  | Perimeter | Eccentricity | Major Axis | Minor Axis |
|---------------|-------|-----------|--------------|------------|------------|
| Botol Kaleng  | 20418 | 556.031   | 0.83082      | 219.354    | 122.08     |
| Kertas        | 26341 | 889.949   | 0.87086      | 288.5513   | 141.833    |
| Botol Plastik | 8736  | 392.366   | 0.90511      | 165.6677   | 70.4398    |

### 3.4. Pelatihan Model Menggunakan *Extreme Learning Machine* (ELM)

Data latih yang terdiri dari vektor ciri dan label kelas digunakan untuk melatih model *ELM*. Metode ini merupakan jenis jaringan syaraf tiruan satu lapis (*single hidden layer feedforward neural network*) dengan pembobotan acak pada lapisan tersembunyi. Jumlah neuron input ditetapkan sebanyak lima (sesuai jumlah fitur), dengan 60 neuron tersembunyi dan fungsi aktivasi sinusoidal (*sin*). Sementara bobot dan bias lapisan tersembunyi ditentukan berdasarkan file *bobot\_awal*. Setelah pelatihan, model disimpan untuk digunakan pada tahap pengujian.

### 3.5. Pengujian dan Evaluasi Klasifikasi

Data uji diproses dengan tahapan yang sama seperti data latih, mulai dari preprocessing hingga ekstraksi fitur. Vektor ciri hasil pengolahan diklasifikasikan menggunakan model *ELM* yang telah dilatih sebelumnya. Akurasi pengujian dihitung dengan membandingkan hasil klasifikasi dengan label sebenarnya. Selain itu, citra yang gagal diklasifikasikan juga ditampilkan untuk mengevaluasi kelemahan model. Evaluasi dilakukan dalam bentuk presentase akurasi dan jumlah kesalahan klasifikasi

## 4. HASIL DAN PEMBAHASAN

Pada Bab sebelumnya telah dibahas dengan singkat, tentang pendekatan yang akan digunakan dalam penelitian ini, yaitu pendekatan klasifikasi citra digital, penggunaan ruang warna *HSV*, segmentasi morfologi dan pendekatana atau metode *ELM*, sementara pada bab ini hasil dari penerapan pendekatan tersebut akan disajikan secara baik, ringkas dan detail. Adapun pengolahan dan klasifikasi dataset dilakukan sesuai dengan tahapan yang telah dijelaskan pada metodologi, kemudia hasil yang diperoleh akan di analisa untuk menilai apakah kombinasi metode yang digunakan dari sisi akurasi pengklasifikasian dan ketepatan dalam mengidentifikasi data sudah efektif.

### 4.1. Hasil Ekstraksi Fitur Citra

Setelah proses pra-pemrosesan selesai dilakukan, citra sampah yang telah disegmentasi dianalisis untuk mengekstraksi fitur-fitur morfologis. Fungsi *regionprops* dipakai untuk melakukan proses pada citra biner hasil dari segmentasi. Lima fitur utama yang digunakan dalam penelitian ini meliputi: *Area*: luas permukaan objek dalam piksel, *Perimeter*: keliling objek dalam piksel. *Eccentricity*: tingkat kebulatan objek (0 = lingkaran sempurna, mendekati 1

= elips panjang). *Major Axis Length*: panjang sumbu utama objek citra. *Minor Axis Length*: panjang sumbu terkecil objek citra.

Setiap citra diwakili oleh sebuah vektor berdimensi lima yang menyatakan kelima fitur

tersebut. Proses ekstraksi dilakukan terhadap seluruh citra latih dan uji. Adapun hasil ekstraksi fitur berdasarkan data citra latih sebagai berikut:

Tabel 2. Hasil ekstraksi fitur data citra latih

| Nama File      | Area  | Perimeter | Eccentricity | Major Axis | Minor Axis |
|----------------|-------|-----------|--------------|------------|------------|
| Botol1.png     | 16385 | 531.568   | 0.91698      | 232.291    | 92.6703    |
| Botol2.png     | 20418 | 556.031   | 0.83082      | 219.354    | 122.08     |
| Botol3.png     | 22809 | 571.202   | 0.82005      | 226.718    | 129.7477   |
| Botol4.png     | 17216 | 642.92    | 0.88788      | 228.8186   | 105.2723   |
| Botol5.png     | 14888 | 526.783   | 0.71993      | 166.3757   | 115.474    |
| Botol6.png     | 35507 | 731.105   | 0.75044      | 265.4069   | 175.4171   |
| Botol7.png     | 12970 | 572.897   | 0.8825       | 197.0942   | 92.6943    |
| Botol8.png     | 20738 | 852.762   | 0.81901      | 223.0504   | 127.9817   |
| Botol9.png     | 23575 | 584.82    | 0.80732      | 228.367    | 134.7616   |
| Botol10.png    | 5555  | 283.35    | 0.82793      | 113.5492   | 63.6815    |
| Kertas1.png    | 41993 | 869.504   | 0.57817      | 262.821    | 214.4392   |
| Kertas2.png    | 26341 | 889.949   | 0.87086      | 288.5513   | 141.833    |
| Kertas3.png    | 38043 | 813.396   | 0.68715      | 267.8931   | 194.6277   |
| Kertas4.png    | 62929 | 1041.803  | 0.4851       | 310.6597   | 271.6598   |
| Kertas5.png    | 41337 | 914.132   | 0.49168      | 256.9895   | 223.7798   |
| Kertas6.png    | 39992 | 892.845   | 0.70841      | 271.9466   | 191.9395   |
| Kertas7.png    | 25764 | 962.166   | 0.81473      | 283.4835   | 164.377    |
| Kertas8.png    | 61077 | 1277.485  | 0.74103      | 359.6232   | 241.4758   |
| Kertas9.png    | 53980 | 1015.895  | 0.74614      | 337.1315   | 224.4576   |
| Kertas10.png   | 61452 | 1069.183  | 0.63129      | 324.6343   | 251.7689   |
| Bplastik1.png  | 14192 | 511.282   | 0.92876      | 223.0157   | 82.6686    |
| Bplastik2.png  | 3782  | 270.02    | 0.86642      | 104.701    | 52.2782    |
| Bplastik3.png  | 17223 | 535.762   | 0.87142      | 214.493    | 105.2165   |
| Bplastik4.png  | 8736  | 392.366   | 0.90511      | 165.6677   | 70.4398    |
| Bplastik5.png  | 18270 | 587.569   | 0.90078      | 241.8498   | 105.0273   |
| Bplastik6.png  | 23902 | 571.458   | 0.67505      | 204.3503   | 150.7639   |
| Bplastik7.png  | 19462 | 545.4     | 0.70084      | 189.6737   | 135.2974   |
| Bplastik8.png  | 22268 | 1017.564  | 0.8651       | 261.4939   | 131.1668   |
| Bplastik9.png  | 21796 | 612.088   | 0.86958      | 241.5815   | 119.2925   |
| Bplastik10.png | 11527 | 708.483   | 0.96264      | 315.4298   | 85.4185    |

Data hasil ekstraksi yang terlihat pada Tabel 2 ini digunakan sebagai input (fitur) untuk proses klasifikasi menggunakan metode *Extreme Learning Machine (ELM)*. Dengan memanfaatkan fitur bentuk dari objek, model diharapkan mampu mengidentifikasi antar kelas secara lebih akurat, tanpa ketergantungan pada warna atau latar belakang citra.

#### 4.2. Hasil Penelitian Model ELM

30 Citra latih yang terbagi kepada tiga kelas, yaitu kelas botol kaleng, kertas dan botol plastik dilakukan pelatihan menggunakan model *ELM*. Masing-masing kelas memiliki 10 citra. Data citra tersebut telah melalui tahapan *preprocessing* dan ekstraksi fitur, sehingga setiap sampel diwakili oleh vektor berdimensi lima yang mencerminkan sifat morfologi objek. Metode klasifikasi yang digunakan adalah *Extreme Learning Machine (ELM)*, yaitu jaringan syaraf tiruan satu lapis tersembunyi (*Single Layer Feedforward Neural Network/SLFN*) yang memiliki keunggulan dalam kecepatan pelatihan karena bobot input dan bias diatur acak serta tidak di perbaharui saat proses pelatihan. Konfigurasi

parameter *ELM* yang digunakan adalah sebagai berikut:

Tabel 3. Konfigurasi parameter *ELM*

| Parameter                 | Nilai                                   |
|---------------------------|-----------------------------------------|
| Jumlah Neuron Input       | 5 (jumlah fitur)                        |
| Jumlah Neuron Tersembunyi | 60                                      |
| Fungsi Aktivasi           | sin                                     |
| Tipe <i>ELM</i>           | Klasifikasi                             |
| Bobot & Bias              | Diinisialisasi dari file bobot_awal.mat |

Berdasarkan Tabel 3 dapat diuraikan bahwa proses pelatihan model yang digunakan adalah metode *ELM* dengan konfigurasi parameter yang telah ditetapkan diawal. Model ini memiliki lima neuron pada lapisan input, yang merepresentasikan lima fitur morfologi utama yang diekstraksi dari citra, yaitu area, perimeter, eccentricity, panjang sumbu mayor, dan panjang sumbu minor. Jumlah neuron tersembunyi yang digunakan adalah sebanyak 60, yang bertujuan untuk memberikan kapasitas representasi yang cukup dalam menangkap pola kompleks dari data input.

Berikutnya fungsi aktivasi menggunakan fungsi *sinusoidal* (*sin*), yang mampu memberikan transformasi non-linier dan fleksibel dalam memetakan data input ke ruang fitur berdimensi tinggi. Tipe *ELM* yang digunakan adalah klasifikasi, karena tujuan utama dari model ini adalah memetakan citra sampah ke dalam tiga kelas target. Untuk menjaga konsistensi dan menghindari variasi hasil akibat inisialisasi bobot secara acak, bobot dan bias pada lapisan tersembunyi tidak di-generate secara langsung di skrip utama, melainkan diambil dari file eksternal *bobot\_awal.mat* yang telah diinisialisasi sebelumnya. Pendekatan ini juga membantu dalam replikasi hasil dan efisiensi waktu pelatihan. Pelatihan dilakukan dengan memasukkan data latih ke dalam fungsi *ELM(...)*, yang menghasilkan kelas prediksi untuk setiap sampel. Hasil evaluasi menunjukkan bahwa seluruh 30 sampel data latih diklasifikasikan dengan benar, sehingga diperoleh akurasi pelatihan sebesar 100%. Berikut adalah ringkasan hasil pelatihan:

Tabel 4. Hasil Pelatihan

| Kelas         | Jumlah Sampel | Prediksi Benar | Akurasi Kelas |
|---------------|---------------|----------------|---------------|
| Botol Kaleng  | 10            | 10             | 100%          |
| Kertas        | 10            | 10             | 100%          |
| Botol Plastik | 10            | 10             | 100%          |
| <b>Total</b>  | <b>30</b>     | <b>30</b>      | <b>100%</b>   |

Berdasarkan data yang diperoleh dari Tabel 4, hasil pelatihan menggunakan model *ELM* memperlihatkan hasil klasifikasi yang sangat baik dan ini terjadi untuk keseluruhan kelas citra yang diuji. Masing-masing kelas, yaitu botol kaleng, kertas, dan botol plastik, terdiri dari 10 sampel data latih dan semuanya berhasil diklasifikasikan dengan benar oleh model, menghasilkan akurasi per kelas sebesar 100%. Hasil ini mengindikasikan bahwa model *ELM* mampu mempelajari pola fitur dari data latih dengan sangat baik dan tanpa kesalahan klasifikasi pada fase pelatihan. Meskipun hasil akurasi pada pelatihan model menunjukkan akurasi tinggi, hal ini belum menjamin hasil yang sama terhadap data uji yang tentunya belum pernah dikenali oleh model. Akurasi tinggi pada data latih harus dikaji ulang melalui pengujian, untuk memastikan bahwa model tidak mengalami *overfitting*. Oleh karena itu, tahap berikutnya adalah evaluasi terhadap data uji untuk mengukur kemampuan generalisasi model.

#### 4.3. Hasil Pengujian dan Evaluasi

Pengujian model dilakukan menggunakan 12 citra uji yang terdiri dari tiga kelas: botol kaleng (4 sampel), kertas (2 sampel), dan botol plastik (6 sampel). Setiap citra telah melalui proses preprocessing dan ekstraksi fitur yang sama seperti pada data latih. Data yang dihasilkan kemudian diklasifikasikan menggunakan model *ELM* yang telah dilakukan pelatihan sebelumnya. Berdasarkan hasil klasifikasi, diketahui bahwa akurasi pengujian dengan data uji sebesar 91,66%, dengan rincian 11 dari 12

sampel berhasil diklasifikasikan dengan benar. Hanya satu sampel dari kelas botol plastik yang salah diklasifikasikan. Berikut ringkasan hasil klasifikasi per kelas:

Tabel 5. Hasil klasifikasi per kelas


| Kelas         | Jumlah Sampel | Prediksi  |          | Akurasi Kelas |
|---------------|---------------|-----------|----------|---------------|
|               |               | Benar     | Salah    |               |
| Botol Kaleng  | 4             | 4         | 0        | 100%          |
| Kertas        | 2             | 2         | 0        | 100%          |
| Botol Plastik | 6             | 5         | 1        | 83,33%        |
| <b>Total</b>  | <b>12</b>     | <b>11</b> | <b>1</b> | <b>91,66%</b> |

Untuk memperjelas hasil klasifikasi per kelas sebagaimana yang dapat dilihat pada Tabel 5, berikut ditampilkan sebagian hasil klasifikasi model terhadap beberapa sampel data uji:

Tabel 6. Sampel hasil klasifikasi


| Nama File        | Ekstraksi Fitur                    | Kelas             | Hasil Prediksi |
|------------------|------------------------------------|-------------------|----------------|
| kaleng1_uji.png  | [14560, 490.2, 0.81, 182.1, 101.2] | 1 (Botol Kaleng)  | 1              |
| kertas1_uji.png  | [20520, 630.8, 0.62, 170.0, 148.3] | 2 (Kertas)        | 2              |
| plastik2_uji.png | [14010, 485.3, 0.85, 187.5, 98.1]  | 3 (Botol Plastik) | 1 ✗            |

Tabel 6 memperlihatkan secara jelas bahwa, file *Plastik2\_uji.png* merupakan satu-satunya citra yang gagal diklasifikasikan, karena diprediksi sebagai kelas 1 (botol kaleng) padahal seharusnya kelas 3 (botol plastik). Hal ini karena adanya kemiripan bentuk morfologi antara objek pada citra tersebut dengan citra pada kelas lain. Untuk memberikan gambaran yang lebih jelas terkait performa klasifikasi model, hasil tersebut divisualisasikan dalam bentuk grafik akurasi pengujian per kelas dan grafik perbandingan antara label aktual dengan prediksi model pada seluruh data uji.



Gambar 2. Grafik akurasi pengujian per kelas objek sampah

Grafik akurasi pengujian per kelas berdasarkan gambar 2 menginformasikan bahwa ada dua kelas yang nilai akurasinya sempurna, yaitu 100% pada kelas botol kaleng dan kertas, sedangkan pada kelas botol plastik keakuratan pengujian sebesar 83,33%, menurun dibandingkan 2 kelas lain, kesalahan klasifikasi pada satu sampel citra menjadi penyebab hal ini.



Gambar 2. Grafik perbandingan antara kelas aktual dan hasil prediksi model *ELM* pada data uji

Grafik prediksi vs kelas aktual: memvisualisasikan urutan kelas aktual dibandingkan dengan hasil prediksi untuk tiap sampel. Disini dapat dilihat bahwa ada satu perbedaan yaitu bisa dilihat pada sampel ke-12, di mana prediksi model tidak sesuai dengan label sebenarnya.

#### 4.4. Pembahasan

Hasil penelitian menunjukkan bahwa kombinasi antara metode ekstraksi fitur berbasis morfologi, konversi warna *HSV*, dan algoritma klasifikasi *Extreme Learning Machine (ELM)* mampu memberikan performa yang sangat baik dalam klasifikasi citra sampah kering. Hasil akurasi sempurna 100% pada pelatihan model mengindikasikan bahwa model dapat mempelajari pola-pola ciri per kelas secara utuh tanpa adanya kesalahan pada data latih.

Hal ini menunjukkan bahwa penggunaan fitur *area*, *perimeter*, *eccentricity*, panjang sumbu *mayor* dan *minor* cukup representatif dalam membedakan bentuk dan struktur visual dari objek yang termasuk dalam kategori sampah botol kaleng, kertas, dan botol plastik. Namun demikian, hasil pengujian terhadap data uji mengungkapkan adanya penurunan akurasi menjadi 91,66%, yang diakibatkan oleh satu kesalahan klasifikasi pada sampel dari kelas botol plastik. Kesalahan ini diperkirakan terjadi karena adanya kemiripan morfologi antara objek botol plastik dengan botol kaleng. Jika dilihat dari sisi fitur, keduanya cenderung memiliki nilai *eccentricity* dan rasio panjang sumbu *mayor* dan *minor* yang relatif mendekati, sehingga menyebabkan model mengalami ambiguitas dalam menentukan kelas. Performa

klasifikasi yang tinggi meskipun menggunakan metode *feedforward* yang sederhana seperti *ELM* menegaskan bahwa jaringan saraf lapisan tunggal masih sangat relevan apabila dipadukan dengan pemilihan fitur yang tepat dan *preprocessing* yang efektif. Penggunaan konversi warna *HSV* juga terbukti membantu proses segmentasi objek dari latar belakang, karena komponen value (*V*) memungkinkan pemisahan objek terang dari latar gelap dengan lebih konsisten.

Meskipun hasil yang diperoleh sangat memuaskan, perlu dicermati bahwa jumlah data uji yang digunakan masih terbatas. Model ini belum diuji terhadap variasi pencahayaan, latar belakang kompleks, atau bentuk objek yang tidak standar. Selain itu, proses inisialisasi bobot dan bias pada *ELM* dilakukan secara acak (meskipun disimpan untuk konsistensi), sehingga model ini memiliki potensi menghasilkan hasil berbeda jika dilatih ulang dengan bobot berbeda. Secara umum, eksperimen ini berhasil membuktikan bahwa pendekatan kombinasi antara *HSV*, segmentasi morfologi, dan *ELM* dapat menjadi solusi ringan namun efektif untuk sistem klasifikasi citra berbasis bentuk. Berikutnya, model ini tentu masih dapat dikembangkan kembali baik dari sisi volume data, variasi fitur (misalnya dengan menambahkan fitur tekstur), maupun dengan eksplorasi arsitektur pembelajaran yang lebih kompleks untuk mengolah data nyata dengan kompleksitas visual yang lebih tinggi.

#### 5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem klasifikasi otomatis untuk sampah kering berbasis citra digital dengan memanfaatkan ruang warna *HSV*, segmentasi morfologi, dan algoritma *Extreme Learning Machine (ELM)*. Dari hasil pengujian, model menunjukkan akurasi pelatihan sebesar 100% dan akurasi pengujian mencapai 91,66%. Ini membuktikan bahwa penggunaan kombinasi metode tersebut berhasil mengidentifikasi bentuk visual objek sampah dengan cukup akurat dan efisien. Keberhasilan model dalam mengenali ciri visual objek didukung oleh proses ekstraksi fitur bentuk yang tepat serta *preprocessing* citra yang konsisten. Meski demikian, kesalahan klasifikasi pada sebagian kecil data uji menandakan masih ada ruang untuk perbaikan, terutama pada objek yang memiliki kemiripan bentuk antar kelas. Agar sistem klasifikasi yang dikembangkan dapat lebih optimal dan aplikatif dalam skala yang lebih luas, disarankan untuk memperluas jumlah dan keragaman dataset, terutama dengan menambahkan variasi bentuk objek, pencahayaan, serta latar belakang yang berbeda. Hal ini bertujuan agar model memiliki kemampuan generalisasi yang lebih baik saat menghadapi data baru. Selain itu, penambahan fitur citra lain seperti tekstur atau kontur dapat meningkatkan akurasi klasifikasi, terutama untuk objek yang memiliki morfologi serupa. Proses pelatihan model juga sebaiknya menggunakan validasi

silang (cross-validation) agar hasil evaluasi lebih akurat dan tidak bergantung pada pembagian data tertentu. Di sisi implementasi, pengembangan antarmuka dalam bentuk aplikasi berbasis GUI atau mobile dapat menjadi langkah penting untuk menjadikan sistem ini lebih mudah digunakan oleh masyarakat umum atau pihak pengelola sampah. Untuk mendukung keterbukaan dan replikasi penelitian, seluruh source code, dataset, serta dokumentasi implementasi sistem klasifikasi sampah ini telah dipublikasikan dan dapat diakses melalui repositori GitHub berikut:

<https://github.com/abuzar308/Klasifikasi-Otomatis-Sampah-Hsv-Color-Space-Segmentasi-Morfologi-Dan-Extreme-Learning-Machine>.

#### DAFTAR PUSTAKA

- [1] Kementerian Lingkungan Hidup dan Kehutanan, "Timbulan Sampah," 2023.
- [2] K. Mustafi, A. Prima, N. Dimas, and M. Arya, "Klasifikasi sampah menggunakan Convolutional Neural Network," vol. 3, no. 2, pp. 72–81, 2022.
- [3] Y. Zahrah, J. Yu, and X. Liu, "How Indonesia's Cities Are Grappling with Plastic Waste: An Integrated Approach towards Sustainable Plastic Waste Management," *Sustain.*, vol. 16, no. 10, 2024, doi: 10.3390/su16103921.
- [4] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. Pearson, 2018.
- [5] B. Jäckl, Y. Metz, U. Schlegel, D. A. Keim, and M. T. Fischer, "Leveraging Color Channel Independence for Improved Unsupervised Object Detection," pp. 1–38, 2024, [Online]. Available: <http://arxiv.org/abs/2412.15150>
- [6] P. Soille, *Morphological Image Analysis: Principles and Applications*, 2nd ed. Berlin, Heidelberg: Springer-Verlag, 2003.
- [7] G.-B. Huang, "Extreme Learning Machines Tutorial," no. October 2014, pp. 1–42, 2013.
- [8] Mohammad Yazdi Pusadan, Indah Safitri, and Wirdayanti, "The Image Extraction Using the HSV Method to Determine the Maturity Level of Palm Oil Fruit with the k-nearest Neighbor Algorithm," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 6, pp. 1448–1456, 2023, doi: 10.29207/resti.v7i6.5558.
- [9] J. Son and Y. Ahn, "AI-based plastic waste sorting method utilizing object detection models for enhanced classification," *Waste Manag.*, vol. 193, pp. 273–282, 2025, doi: <https://doi.org/10.1016/j.wasman.2024.12.014>.
- [10] R. Okubo and M. Kimura, "A Classification Model for Small Waste Image Datasets With Knowledge Distillation and Input Masking," in *Proceedings of the 2024 9th International Conference on Intelligent Information Technology*, in ICIIT '24. New York, NY, USA: Association for Computing Machinery, 2024, pp. 179–185. doi: 10.1145/3654522.3654571.
- [11] S. K. Ali and D. Boughaci, "Improving extreme learning machine model using deep learning feature extraction and grey wolf optimizer: Application to image classification," *Intell. Decis. Technol.*, vol. 18, no. 1, pp. 457–483, 2024, doi: 10.3233/IDT-230382.
- [12] P. J. Haupts, H. Al-Joumaa, L. Al-Shrouf, and M. Jelali, "Comparative Analysis of Binarization Approaches for Automated Dye Penetrant Testing," *Processes*, vol. 13, no. 4, 2025, doi: 10.3390/pr13041212.
- [13] X. Zheng and G. Xu, "Extreme learning machine with incremental hidden layers," in *Third International Conference on Electronic Information Engineering, Big Data, and Computer Technology (EIBDCT 2024)*, J. Zhang and N. Sun, Eds., SPIE, 2024, p. 131818G. doi: 10.1117/12.3031279.
- [14] Q. Yu, X. Li, H. Zhang, and J. Xu, "Spatial-spectral graph convolutional extreme learning machine for hyperspectral image classification," *Int. J. Remote Sens.*, vol. 45, pp. 1773–1795, Feb. 2024, doi: 10.1080/01431161.2024.2318771.
- [15] A. Marzuki, A. Zaky, A. C. Adha, and T. M. Yoshandi, "Analisis Model Klasifikasi Sampah Botol Berbasis Image Processing Dan Machine Learning Dalam Rancang Bangun Aplikasi Penukaran Sampah Botol Otomatis JURNAL MEDIA INFORMATIKA [JUMIN ]," vol. 6, no. 2, pp. 432–438, 2024.
- [16] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 142–149, 2022, doi: 10.28932/jutisi.v8i1.4314.
- [17] P. F. Johari, N. Arifin, M. Surya, and A. Utama, "Corn Leaf Diseases Classification Using CNN with GLCM, HSV, and L\*a\*b\* Features," vol. 6, no. 2, pp. 709–722, 2025.
- [18] S. S. Sitanggang, Y. Yuhandri, and Adil Setiawan, "Image Transformation With Lung Image Thresholding and Segmentation Method," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 2, pp. 278–285, 2023, doi: 10.29207/resti.v7i2.4321.
- [19] M. Nahiduzzaman *et al.*, "An automated waste classification system using deep learning techniques: Toward efficient waste recycling and environmental sustainability," *Knowledge-Based Syst.*, vol. 310, no. May 2024, p. 113028, 2025, doi: 10.1016/j.knosys.2025.113028.
- [20] N. Farhana, G. F. Hertono, B. D. Handari, M. Matematika, and U. Indonesia, "CLASSIFICATION OF COAL MINE PILLAR STABILITY USING EXTREME LEARNING MACHINE AND PARTICLE SWARM OPTIMIZATION ADAPTIVE KLASIFIKASI KESTABILAN PILAR TAMBANG BATU BARA MENGGUNAKAN EXTREME LEARNING MACHINE DAN PARTICLE SWARM OPTIMIZATION ADAPTIVE WEIGHT DELAY," vol. 5, no. 6, pp. 1569–1580, 2024.