

KLASIFIKASI CITRA SAMPAH MENGGUNAKAN *SUPPORT VECTOR MACHINE* DENGAN EKSTRAKSI FITUR *GRAY LEVEL CO-OCCURRENCE MATRIX* DAN *COLOR MOMENTS*

Iffa Zainan Nisa¹, Sukmawati Nur Endah^{*2}, Priyo Sidik Sasongko³, Retno Kusumaningrum⁴, Khadijah⁵, Rismiyati⁶

^{1,2,3,4,5,6} Universitas Diponegoro, Semarang

Email: ¹iffazainannisa@student.undip.ac.id, ²sukmane@lecturer.undip.ac.id, ³priyoss_undip@yahoo.co.id, ⁴retno@live.undip.ac.id, ⁵khadijah0303@gmail.com, ⁶rismi13@gmail.com

^{*}Penulis Korespondensi

(Naskah masuk: 26 Maret 2021, diterima untuk diterbitkan: 14 Oktober 2022)

Abstrak

Sampah merupakan salah satu permasalahan global yang dihadapi seluruh dunia termasuk Indonesia. Sampah yang tidak dikelola dengan baik dapat berdampak buruk pada lingkungan dan mengganggu kesehatan. Pemilahan sampah merupakan langkah awal dalam melakukan pengolahan sampah. Pemilahan sampah secara manual tidak mudah dilakukan karena jumlah sampah yang amat besar. Oleh karena itu, teknologi deteksi sampah diperlukan dalam menunjang pemilahan sampah yang lebih optimal. Penelitian ini mengusulkan klasifikasi citra sampah menggunakan *Support Vector Machine* (SVM) dengan ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM) dan *Color Moments* serta mengoptimalkan kinerja terbaik dalam proses klasifikasinya. Dataset TrashNet digunakan untuk mengevaluasi metode yang diusulkan. Beberapa parameter yang dituning dalam penelitian ini adalah orientasi sudut GLCM, parameter C (*soft margin*) pada SVM, dan parameter γ pada *Radial Basis Kernel* (RBF). Pembagian data dilakukan dengan menggunakan *10-Fold Cross Validation*. Hasil penelitian menunjukkan bahwa kombinasi fitur GLCM dengan orientasi sudut 45° dan *Color Moments* memberikan rata-rata akurasi terbaik sebesar 78,87% dengan menggunakan parameter C bernilai 32 dan parameter γ bernilai 4. Hasil pengujian terbaik diperoleh pada *fold* ke-3 dengan akurasi sebesar 85,43% yang digunakan sebagai skenario pengujian data baru diluar dataset TrashNet. Pengujian terhadap 30 citra sampah baru menggunakan model terbaik memperoleh akurasi sebesar 70%.

Kata kunci: *klasifikasi citra sampah, trashnet, gray level co-occurrence matrix, color moments, support vector machine*

WASTE IMAGE CLASSIFICATION USING SUPPORT VECTOR MACHINE WITH GRAY LEVEL CO-OCCURRENCE AND COLOR MOMENTS FEATURES EXTRACTION

Abstract

Waste is one of the global problems faced by the whole world, including Indonesia. Improper waste management can harm the environment and interfere with health. Waste management involved several steps in handling waste, the first one being waste sorting. In Indonesia, waste sorting is still performed manually. Manual waste sorting is not easy to do because the waste amount is very large. Therefore, automatic waste detection technology is needed to support more optimal waste sorting. This study proposes waste image classification using Support Vector Machine (SVM) with Gray Level Co-Occurrence Matrix (GLCM) and Color Moments as the features. The TrashNet dataset is used to evaluate the proposed method. In addition, 30 additional waste image outside trashnet is used as testing data. Some of the important parameters that are tuned in this study are the angle orientation of the GLCM, C (*soft margin*) parameter on the SVM, and γ parameter on the Radial Base Kernel (RBF). Data splitting is done using *10-Fold Cross Validation*. The results showed that the combination of GLCM features with 45° angle orientation and Color Moments gave the best average accuracy of 78.87% using C parameter with a value of 32 and γ parameter with a value of 4. The best test results were obtained in the third fold with an accuracy of 85, 43%. This result is used to test the 30 test image outside the TrashNet dataset, and achieve accuracy of 70%.

Keywords: *waste image classification, trashnet, gray level co-occurrence matrix, color moments, support vector machine*

1. PENDAHULUAN

Sampah merupakan salah satu permasalahan global yang dihadapi seluruh dunia termasuk Indonesia. Seiring bertambahnya populasi dan berkembangnya industri, sampah yang dihasilkan juga semakin meningkat. Hal ini erat kaitannya dengan perubahan pola konsumsi atau gaya hidup masyarakat.

Berdasarkan data Sustainable Waste Indonesia (SWI) yang dipublikasikan dalam CNN Indonesia (2018), dari sekitar 65 juta ton sampah yang diproduksi Indonesia perharinya, 24% atau sekitar 15 juta ton tidak terkelola dan mencemari lingkungan. Sementara itu, hanya 7% sampah yang didaur ulang dan 69% dikirim ke Tempat Pembuangan Akhir (TPA). Jenis sampah yang paling umum dihasilkan adalah 60% sampah organik, 14% sampah plastik, 9% sampah kertas, 4.3% sampah logam, serta 12.7% sampah kaca, kayu, dan bahan lainnya. Oleh karena itu, pemilahan sampah perlu dilakukan sebagai langkah awal dalam pengelolaan sampah.

Sampah dipilah untuk didaur ulang dengan cara yang berbeda. Pemilahan sampah ini dapat dilakukan secara manual. Namun, prosesnya membutuhkan banyak waktu dan biaya serta dapat membahayakan pemilah apabila terdapat bahan B3. Selain itu, prosesnya tidak mudah dilakukan karena jumlah sampah yang amat besar (Brintha et al., 2020). Sehingga teknologi deteksi sampah diperlukan untuk menunjang pemilahan sampah yang lebih optimal.

Metode pengenalan sampah telah diperkenalkan oleh banyak peneliti untuk memilah sampah. Berbagai metode telah diusulkan untuk mendapatkan akurasi yang tinggi dalam klasifikasi citra sampah, diantaranya adalah *Support Vector Machine* (SVM) (Leonardo et al., 2020; Yang & Thung, 2016), *Convolutional Neural Network* (CNN) (Mittal et al., 2020; Sidharth et al., 2020; Yang & Thung, 2016), maupun kombinasi CNN untuk ekstraksi fitur dan SVM untuk klasifikasi (Adedeji & Wang, 2019). TrashNet merupakan *public benchmark dataset* untuk klasifikasi citra sampah. Selain TrashNet, terdapat *dataset* seperti TACO, AquaTrash, dan VN-trash, namun jumlahnya lebih sedikit dan tidak *open source* (Mao et al., 2020).

Berdasarkan penelitian Yang & Thung (2016), klasifikasi citra sampah menggunakan metode SVM dengan ekstraksi fitur Scale-Invariant Feature Transform (SIFT) dan dibandingkan dengan metode CNN terhadap dataset TrashNet, disimpulkan bahwa metode SVM lebih baik daripada CNN dengan akurasi sebesar 63%. Selanjutnya, dengan dataset citra sampah pribadi yang diambil menggunakan kamera pi yang terkoneksi dengan Raspberry pi 3, Sakr et al. (2016) membandingkan metode SVM dan CNN untuk mengklasifikasikan citra sampah.

Penelitian tersebut juga menyimpulkan bahwa SVM lebih baik daripada CNN. Sementara itu, dalam penelitian Leonardo et al. (2020), klasifikasi citra sampah menggunakan SVM dengan ekstraksi fitur Local Binary Pattern (LBP) terhadap dataset TrashNet juga menghasilkan akurasi yang cukup baik dengan rata-rata 88,09%.

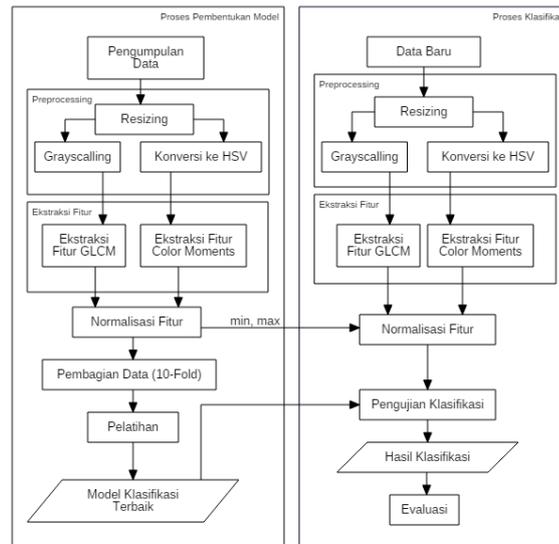
Ekstraksi fitur LBP sensitif terhadap rotasi gambar dan hanya menangkap sebagian informasi terbatas, sehingga kurang menggambarkan struktur lokal citra seperti kontras (Humeau-Heurtier, 2019). Hal ini diatasi oleh fitur GLCM yang dapat diperoleh dari satu nilai orientasi sudut maupun kombinasinya, sehingga membuat arah GLCM lebih independen (Humeau-Heurtier, 2019)

Penelitian terkait klasifikasi sampah dengan ekstraksi fitur GLCM telah dilakukan oleh Wang Kun & Kong Songtao (2011) menggunakan Neural Network terhadap dataset pribadi dengan kelas botol plastik, buah, daun, dan kayu. Pada penelitian ini, GLCM yang bekerja dalam domain grayscale memiliki kelemahan dimana komponen warna dari citra diabaikan sehingga perlu dikombinasikan dengan fitur warna. Selain itu, dataset yang digunakan juga kurang mewakili sampah yang ada di sekitar.

Penelitian yang menggunakan GLCM sebagai ekstraksi fitur dan SVM sebagai klasifikasi pernah dilakukan oleh Asery et al. (2016) untuk mendeteksi kabut yang hasilnya mencapai 97,16% untuk data sintesis dan 85% untuk data natural. Selain itu penggunaan GLCM dan SVM juga pernah dilakukan oleh Foady et al. (2018) untuk diagnosis Diabetic Retinopathy (DR) dengan hasil mencapai 82.35% untuk mata normal dan DR serta 100% untuk non-proliferative diabetes retinopathy (NPDR) dan proliferative diabetes retinopathy (PDR). Hasil tersebut menunjukkan bahwa penggunaan GLCM sebagai ekstraksi fitur dan SVM sebagai metode klasifikasinya cukup menjanjikan.

Berkaitan dengan metode kombinasi ekstraksi fitur, penelitian yang dilakukan oleh Shaparia et al. (2017) untuk klasifikasi bunga, Bairwa & Sharma (2017) untuk klasifikasi buah, dan Ahsani et al. (2019) untuk klasifikasi makanan, disimpulkan bahwa kombinasi ekstraksi fitur GLCM dan Color Moments memberikan akurasi terbaik.

Oleh karena itu, pada penelitian ini melakukan klasifikasi citra sampah menggunakan SVM dengan ekstraksi fitur GLCM dan Color Moments serta mengoptimalkan kinerja terbaik dalam proses klasifikasinya. Evaluasi model dilakukan terhadap dataset TrashNet dan dataset pribadi yang telah dikumpulkan. Dengan metode ini diharapkan mampu menghasilkan hasil klasifikasi yang lebih optimal.



Gambar 1. Gambaran Umum Penelitian

2. METODE PENELITIAN

Tahapan dalam penelitian ini terbagi ke dalam 2 proses utama, yaitu proses pembentukan model dan proses klasifikasi. Pada proses pembentukan model terdiri dari 6 proses, yaitu pengumpulan data, *preprocessing*, ekstraksi fitur, normalisasi fitur, pembagian data, dan pelatihan. *Preprocessing* data dilakukan dengan *resizing*, *grayscale*, dan konversi ke HSV. Sementara itu, pada proses ekstraksi fitur digunakan metode ekstraksi fitur GLCM dan *Color Moments*.

Pembagian data disesuaikan dengan metode 10-Fold Cross Validation. Sedangkan untuk proses pelatihan digunakan metode SVM sebagai pengklasifikasi. Selanjutnya dipilih model klasifikasi terbaik yang digunakan dalam proses pengujian data baru untuk dievaluasi. Gambaran umum penelitian ini ditunjukkan pada Gambar 1.

2.1. Pengumpulan Data

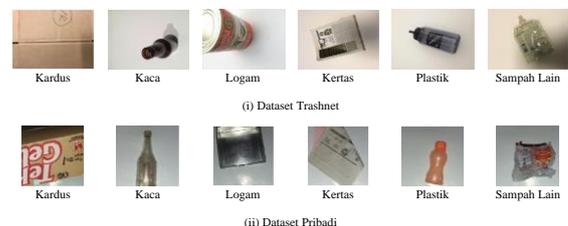
Data sampah yang digunakan adalah *dataset* TrashNet dari Yang & Thung (2016) yang dimuat dalam <https://github.com/garythung/trashnet>. Secara keseluruhan terdapat 2.527 citra yang terbagi menjadi 6 kelas, yaitu 403 kardus, 501 kaca, 410 logam, 482 plastik, 594 kertas, dan 137 sampah lain. Setiap data pada *dataset* tersebut berukuran 512×384 piksel yang diambil menggunakan kamera *smartphone* dengan ekstensi JPG.

Selain itu, data baru di luar *dataset* TrashNet juga digunakan untuk pengujian model terbaik. Data ini diambil menggunakan kamera *smartphone* dengan ukuran 2448×2448 piksel, *background* berwarna putih, dan jarak pengambilan gambar sejauh 30 cm. Data ini berjumlah 30 citra (5 citra setiap kelas). Contoh data dari setiap kelas ditunjukkan pada Gambar 2.

2.2. Preprocessing Data

Dalam penelitian ini, *preprocessing* dilakukan dengan *resizing* citra asal, *grayscale*, dan konversi ke ruang warna HSV sebelum digunakan pada tahapan selanjutnya.

Dataset TrashNet memiliki ukuran 512×384 piksel. Dimensi pada citra ini *resize* menjadi citra dengan dimensi yang lebih kecil, yaitu 256×256 piksel untuk mempercepat proses pengolahan citra pada tahap selanjutnya.



Gambar 2. Contoh Data dari Setiap Kelas

Selanjutnya *grayscale* dilakukan terhadap citra dengan *channel* RGB yang telah *resize* untuk dikonversi menjadi citra keabuan sebagai inputan ekstraksi fitur GLCM. Proses konversi ini didefinisikan dalam Persamaan (1).

$$Y = (0,299 \times R) + (0,587 \times G) + (0,114 \times B) \quad (1)$$

Pada Persamaan (1), Y merupakan nilai intensitas citra *grayscale* sedangkan R , G , dan B merupakan nilai intensitas citra *red*, *green*, dan *blue* dari citra asal.

Setelah itu, konversi ke ruang warna HSV dilakukan terhadap citra dengan *channel* RGB yang telah *resize* untuk dikonversi menjadi citra HSV sebagai inputan untuk ekstraksi fitur *Color Moments*. Proses konversi ini didefinisikan pada Persamaan (2) sampai (11). *Channel* R , G , dan B di normalisasikan dalam rentang $[0, 1]$ seperti Persamaan (2) sampai

(4), kemudian, nilai HSV dihitung berdasarkan Persamaan (5) sampai (8), selanjutnya, dikonversikan kembali ke rentang [0, 255] seperti Persamaan (9) sampai (11).

$$R' = \frac{R}{255} \tag{2}$$

$$G' = \frac{G}{255} \tag{3}$$

$$B' = \frac{B}{255} \tag{4}$$

$$V = \max(R', G', B') \tag{5}$$

$$S = \begin{cases} \frac{V - \min(R', G', B')}{V} & \text{if } V \neq 0 \\ 0 & \text{otherwise} \end{cases} \tag{6}$$

$$H = \begin{cases} \frac{60(G' - B')}{V - \min(R', G', B')} & \text{if } V = R' \\ 120 + \frac{60(B' - R')}{V - \min(R', G', B')} & \text{if } V = G' \\ 240 + \frac{60(R' - G')}{V - \min(R', G', B')} & \text{if } V = B' \end{cases} \tag{7}$$

$$\text{if } H < 0 \text{ then } H = H + 360 \tag{8}$$

$$H = \frac{H}{2} \tag{9}$$

$$S = 255 \times S \tag{10}$$

$$V = 255 \times V \tag{11}$$

Pada Persamaan (2) sampai (11) R' , G' , dan B' merupakan nilai normalisasi intensitas citra *red*, *green*, dan *blue* sedangkan H , S , dan V merupakan nilai intensitas citra *hue*, *saturation*, dan *value*.

2.3. Ekstraksi Fitur GLCM

GLCM dibangun dari citra *grayscale* dari dengan menghitung jumlah ketetangaan antara dua derajat keabuan dengan *distance* 1 dan orientasi sudut 0° , 45° , 90° , dan 135° (Bakti et al., 2021). Pada metode ini digunakan 6 fitur, yaitu *contrast*, *dissimilarity*, *homogeneity*, *ASM*, *energy*, dan *correlation* (Haryanto et al., 2020) yang didefinisikan pada Persamaan (12) sampai (17).

$$\text{Contrast} = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2 \tag{12}$$

$$\text{Dissimilarity} = \sum_{i,j=0}^{N-1} P_{i,j} |i - j| \tag{13}$$

$$\text{Homogeneity} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \tag{14}$$

$$\text{ASM} = \sum_{i,j=0}^{N-1} P_{i,j}^2 \tag{15}$$

$$\text{Energy} = \sqrt{\text{ASM}} \tag{16}$$

$$\text{Correlation} = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \tag{17}$$

dimana

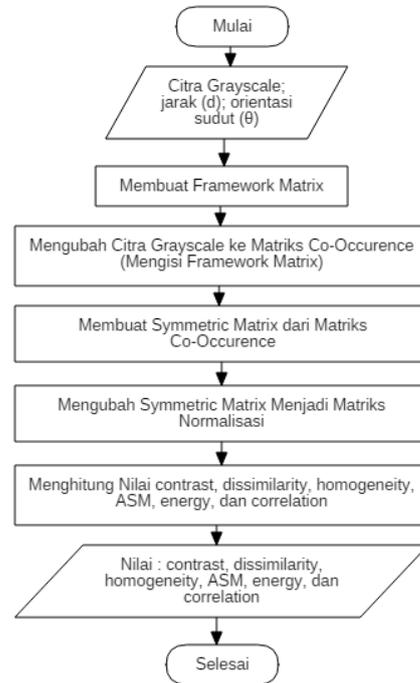
$$\mu_i = \sum_{i,j=0}^{N-1} i(P_{i,j}) \tag{18}$$

$$\mu_j = \sum_{i,j=0}^{N-1} j(P_{i,j}) \tag{19}$$

$$\sigma_i^2 = \sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_i)^2 \tag{20}$$

$$\sigma_j^2 = \sum_{i,j=0}^{N-1} P_{i,j} (j - \mu_j)^2 \tag{21}$$

Pada Persamaan (2) sampai (21) $P_{i,j}$ menunjukkan matriks GLCM dan (i, j) menunjukkan nilai piksel. Nilai μ_i dan μ_j menunjukkan rata-rata elemen baris dan kolom, kemudian nilai σ_i^2 dan σ_j^2 menunjukkan varians elemen baris dan kolom. *Flowchart* proses ekstraksi fitur GLCM ditunjukkan pada Gambar 3.



Gambar 3. *Flowchart* Ekstraksi Fitur GLCM

2.4. Ekstraksi Fitur *Color Moments*

Color Moments dihitung berdasarkan citra HSV dari tahapan *preprocessing* dengan menghitung *moments* yang terdistribusi pada citra. Pada metode ini digunakan 3 *moments*, yaitu *mean*, *standard deviation*, dan *skewness* untuk setiap *channel* (Keen, 2005) yang didefinisikan pada Persamaan (22) sampai (24).

$$\text{Mean} (\mu_i) = \sum_N^{j=1} \frac{1}{N} P_{ij} \tag{22}$$

$$\text{Standar Deviasi} (\sigma_i) = \sqrt{\left(\frac{1}{N} \sum_N^{j=1} (P_{ij} - \mu_i)^2\right)} \tag{23}$$

$$\text{Skewness} (s_i) = \sqrt[3]{\left(\frac{1}{N} \sum_N^{j=1} (P_{ij} - \mu_i)^3\right)} \tag{24}$$

Pada Persamaan (22) sampai (24) P_{ij} merupakan nilai piksel ke- j dari *channel* ke- i dengan jumlah piksel sebanyak N . Sehingga, gambar

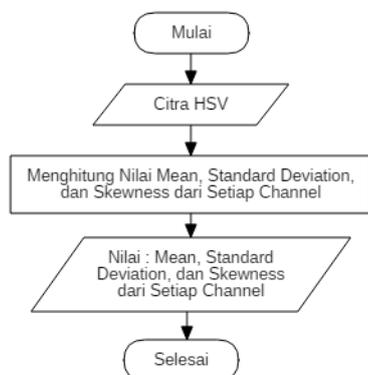
dicirikan oleh 9 *moments* dengan 3 *moments* untuk setiap *channel* warna. *Flowchart* proses ekstraksi fitur *Color Moments* dapat dilihat pada Gambar 4.

2.5. Normalisasi Fitur

Semua fitur yang telah didapatkan dari proses ekstraksi fitur selanjutnya dinormalisasi dalam rentang nol sampai satu menggunakan normalisasi *min-max* yang didefinisikan pada Persamaan (25).

$$x_n = \frac{x_0 - x_{min}}{x_{max} - x_{min}} \tag{25}$$

Pada Persamaan (25) x_n merupakan hasil *scaling* untuk variabel x , x_0 merupakan nilai awal dari variabel x , x_{min} merupakan nilai minimum dari setiap fitur, sedangkan x_{max} merupakan nilai maksimum dari setiap fitur.



Gambar 4. *Flowchart* Ekstraksi Fitur *Color Moments*

2.6. Pembagian Data

Data citra yang telah melalui proses *preprocessing*, ekstraksi fitur, dan normalisasi fitur, kemudian dibagi menjadi data pelatihan dan data pengujian. Data pelatihan digunakan untuk membangun model klasifikasi menggunakan metode SVM, sedangkan data pengujian digunakan dalam evaluasi model klasifikasi. Pembagian data tersebut ditentukan menggunakan metode 10-Fold Cross Validation.

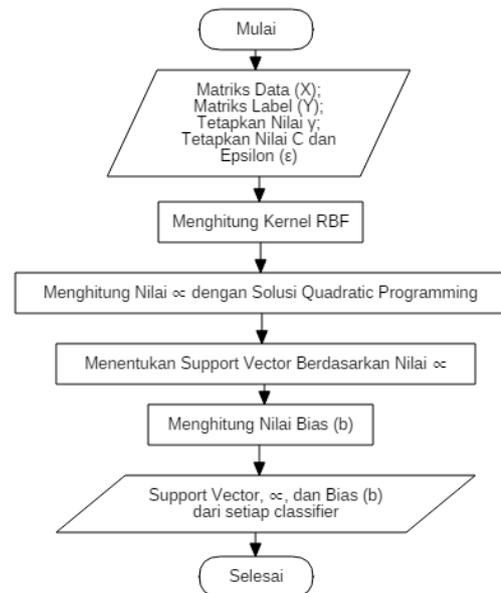
Dataset sejumlah 2.527 dibagi menjadi 10 partisi (fold) dan diiterasi sebanyak 10 kali dimana 1 partisi pada setiap iterasi menjadi data pengujian dan 9 partisi lainnya menjadi data pelatihan. Data yang digunakan sebagai data pelatihan berkisar antara 2271 – 2276 citra. Sementara itu, 251 – 256 citra lainnya digunakan sebagai data pengujian. Penentuan anggota setiap partisi dilakukan secara acak (*random*) dengan *Stratified Cross Validation* agar suatu kelas tidak direpresentasikan secara berlebihan sehingga jumlahnya kurang lebih sama pada setiap *fold*.

2.7. Pelatihan

Proses pelatihan dilakukan menggunakan metode *multiclass classification* SVM dengan kernel RBF dan strategi *One-Against-All*. Alur proses

pelatihan SVM untuk setiap *classifier* yang dilatih dapat dilihat pada Gambar 5.

Pada strategi *One-Against-All*, setiap kelas biner dilatih dengan mengambil salah satu kelas sebagai kelas positif (+1) dan semua kelas lain sebagai kelas negatif (-1). Hasil akhir dipilih klasifikasi biner yang memberikan nilai paling maksimum. Sehingga pada proses pelatihan dihasilkan 6 *classifier* (sesuai jumlah kelas).



Gambar 5. *Flowchart* Pelatihan SVM

Untuk setiap *classifier*, dihitung kernel RBFnya dengan Persamaan (26).

$$K(x_i, y_j) = \exp(-\gamma ||x_i - x_j||^2) \tag{26}$$

Pada Persamaan (26) $K(x_i, y_j)$ merupakan kernel RBF yang dihasilkan dengan x_i merupakan matriks data pelatihan ke-i dan y_j merupakan transpose matriks data pelatihan ke-j dengan γ (Gamma) adalah parameter yang menentukan bagaimana data *training* dipetakan ke *feature space*.

Selanjutnya menghitung nilai α_i dengan solusi *Quadratic Programming* yang didefinisikan dengan *Lagrange Multiplier* dalam Persamaan (27) dengan *constraint* Persamaan (28).

$$\min_{\vec{w}} \tau(\vec{w}, \epsilon_i) = \frac{1}{2} ||\vec{w}'||^2 + C \sum_{i=1}^N \epsilon_i \tag{27}$$

$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1 - \epsilon_i \tag{28}$$

Pada Persamaan (27) dan (28) C merupakan *tuning parameter* yang digunakan untuk mengontrol *trade off* antara *margin* dan *error* klasifikasi (ϵ). Nilai C yang besar memberikan penalti yang lebih besar terhadap *error* klasifikasi. Data yang berkorelasi dengan α_i yang positif merupakan *support vector*. Sementara itu, \vec{w} dan b merupakan nilai yang dicari

untuk menemukan *hyperplane* terbaik. Nilai bias (b) ditentukan dari Persamaan (29).

$$b = y_i - \sum_{j=1}^N \alpha_j y_j K(x_i, x_j) \tag{29}$$

Keluaran dari proses pelatihan adalah *support vector*, α_i , dan b dari setiap *classifier* yang digunakan dalam proses pengujian.

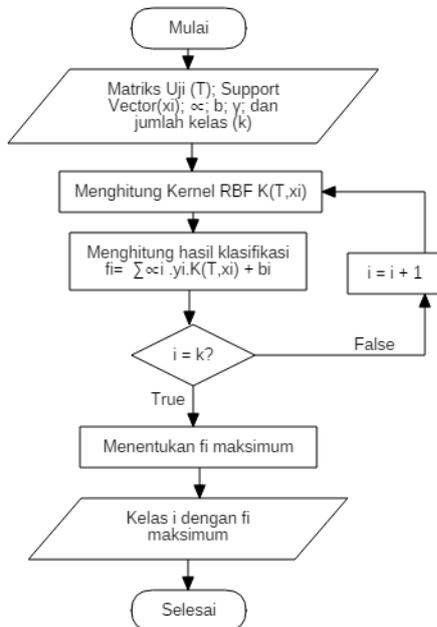
2.8. Pengujian

Setelah proses pelatihan, didapatkan *support vector* serta nilai variabel α dan b untuk setiap *classifier*. Nilai ini selanjutnya digunakan dalam proses pengujian.

Data pengujian dihitung kernel RBFnya lalu dimasukkan kedalam model klasifikasi dari setiap *classifier*. Hasil klasifikasi pada setiap *classifier* ditentukan dengan Persamaan (30). Hasil klasifikasi ditentukan berdasarkan *classifier* yang memberikan nilai paling maksimum.

$$f(x) = w\phi(x) + b = \sum_{i=1}^N \alpha_i y_i K(x_i, x) + b \tag{30}$$

Alur proses pelatihan SVM untuk setiap *classifier* yang dilatih dapat dilihat pada Gambar 6.



Gambar 6. Flowchart Pengujian SVM

Pada proses pengujian diujicobakan untuk *dataset* TrashNet. Model terbaik dari pengujian ini kemudian diujicobakan terhadap *dataset* baru diluar *dataset* TrashNet.

2.9. Evaluasi

Evaluasi dari hasil klasifikasi data pengujian dilakukan dengan menghitung nilai rata-rata akurasi

dari seluruh *fold*. Akurasi didapatkan melalui jumlah data pengujian yang diprediksi dengan benar dibagi dengan jumlah seluruh data pengujian. Hasil ini dibandingkan dan dianalisis melalui beberapa skenario penggunaan parameter SVM (C dan γ) serta penggunaan orientasi sudut pada ekstraksi fitur GLCM untuk melihat kinerja dari metode ekstraksi fitur GLCM dan *Color Moments* dengan SVM sebagai pengklasifikasinya. Parameter C yang digunakan adalah 8, 16, 32, 64, dan 128 sedangkan parameter γ yang digunakan adalah 0.125, 0.25, 0.5, 1, 2, 4, dan 8. Sementara itu, orientasi sudut pada ekstraksi fitur GLCM yang digunakan adalah 0°, 45°, 90°, dan 135°. Model terbaik dari evaluasi ini digunakan untuk mengklasifikasikan citra sampah lain di luar *dataset* TrashNet.

3. HASIL DAN PEMBAHASAN

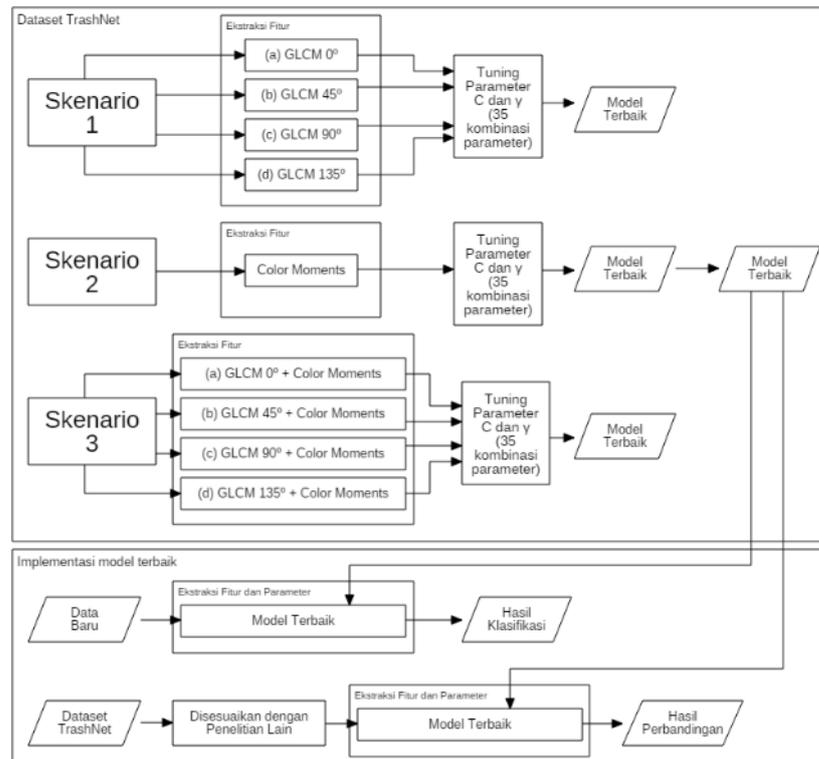
Dalam penelitian ini diujicobakan menggunakan 3 skenario dengan penjelasan sebagai berikut:

- a. Skenario 1 : Menguji akurasi klasifikasi dengan menggunakan ekstraksi fitur GLCM dengan berbagai orientasi sudut yang meliputi 0°, 45°, 90°, dan 135°.
- b. Skenario 2 : Menguji akurasi klasifikasi dengan menggunakan ekstraksi fitur *Color Moments*.
- c. Skenario 3 : Menguji akurasi klasifikasi dengan menggunakan kombinasi ekstraksi fitur GLCM dengan berbagai orientasi sudut yang meliputi 0°, 45°, 90°, dan 135° dan *Color Moments*.

Pada skenario 1 sampai 3 diujicobakan parameter SVM dan kernel RBF dengan parameter C bernilai 8, 16, 32, 64, dan 128 dan parameter γ bernilai 0.125, 0.25, 0.5, 1, 2, 4, dan 8 menggunakan *dataset* TrashNet. Model terbaik diujicobakan untuk klasifikasi data baru diluar *dataset* TrashNet dan dibandingkan dengan penelitian lain disertai penyesuaian jumlah data berdasarkan penelitian lain. Detail skenario pengujian dapat dilihat pada skema dalam Gambar 7.

Perbandingan rata-rata akurasi terbaik dari setiap skenario ditunjukkan pada Gambar 8, Gambar 9, dan Gambar 10.

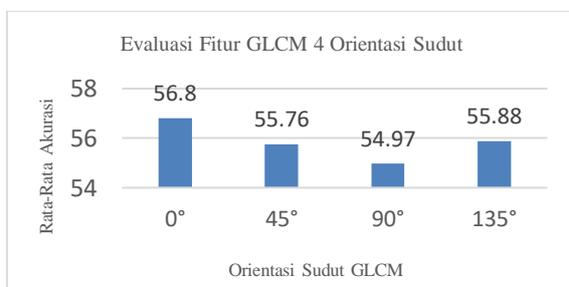
Pada skenario 1, skenario 1a untuk fitur GLCM orientasi sudut 0° merupakan rata-rata akurasi tertinggi sebesar 56,8%. Hal ini menunjukkan bahwa tekstur dari citra sampah lebih dominan apabila dilihat dari arah horizontal dengan orientasi sudut 0°. Apabila dibandingkan dengan skenario 1 yang menggunakan fitur GLCM, skenario 2 yang menggunakan fitur *Color Moments* memberikan rata-rata akurasi yang lebih optimal sebesar 74,83%.



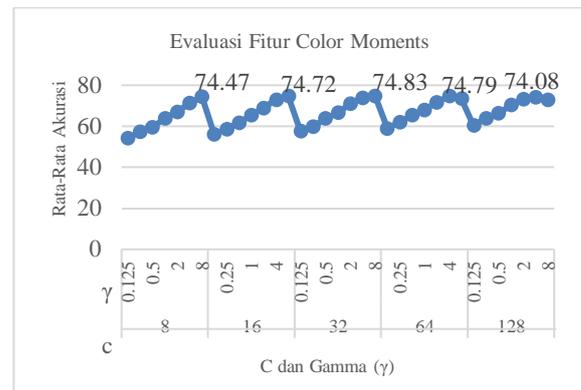
Gambar 7. Skenario Pengujian

Hal ini menunjukkan bahwa karakteristik warna dari objek lebih kuat sehingga rata-rata akurasi lebih besar. Sementara itu, skenario 3 yang menggunakan kombinasi fitur GLCM dan *Color Moments* memberikan rata-rata akurasi yang lebih baik dari ekstraksi fitur tunggal yaitu sebesar 78,87% pada orientasi sudut 45°. Hal ini menunjukkan bahwa tekstur dari citra sampah lebih dominan ketika dilihat dari arah diagonal dengan orientasi sudut 45° apabila dikombinasikan dengan fitur warna.

Perbandingan rata-rata akurasi terbaik dari setiap skenario ditunjukkan pada Tabel 1. Model terbaik memiliki 10 model pelatihan dari *10-Fold Cross Validation*. Perbandingan akurasi pengujian setiap *fold* pada model terbaik ditunjukkan pada Gambar 11.



Gambar 8. Perbandingan Rata-Rata Akurasi Skenario 1

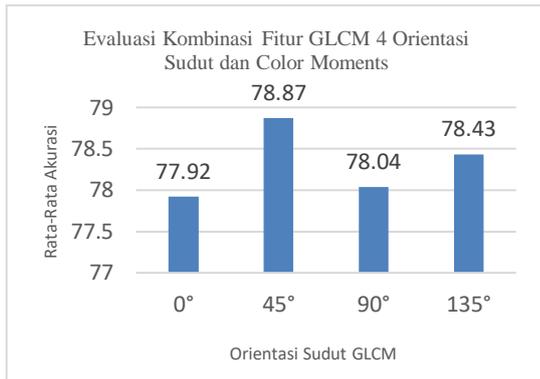


Gambar 9. Evaluasi Skenario 2

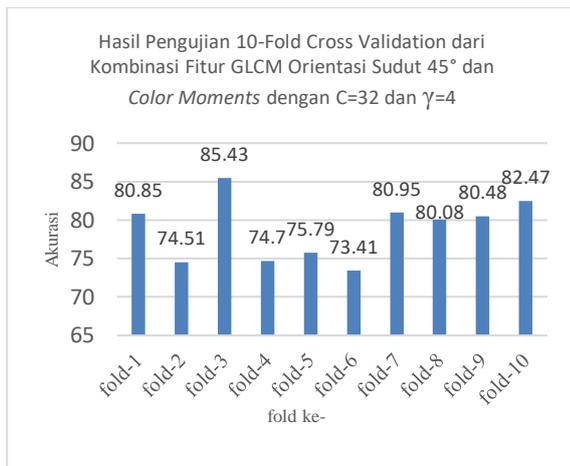
Berdasarkan Gambar 10, hasil pengujian terbaik diperoleh di *fold* ke-3 dengan akurasi sebesar 85,43%. Model pelatihan terbaik ini digunakan untuk klasifikasi data baru diluar *dataset* TrashNet dan dibandingkan dengan penelitian lain disertai penyesuaian jumlah data berdasarkan penelitian lain.

Tabel 1. Perbandingan Rata-Rata Akurasi Terbaik Setiap Skenario

| Skenario | Ekstraksi Fitur | Parameter | | Rata-Rata Akurasi |
|------------|---------------------------------|-----------|---|-------------------|
| | | C | γ | |
| Skenario 1 | GLCM 0° | 128 | 8 | 56,8% |
| Skenario 2 | <i>Color Moments</i> | 32 | 8 | 74,83% |
| Skenario 3 | GLCM 45° + <i>Color Moments</i> | 32 | 4 | 78,87% |



Gambar 10. Perbandingan Rata-Rata Akurasi Skenario 3



Gambar 11. 10-Fold Cross Validation Model Terbaik

3.1. Pengujian di luar Dataset TrashNet

Data sampah baru yang berjumlah 30 citra diujicobakan menggunakan model terbaik dari data pelatihan pada *fold-3*. *Confusion Matrix* dari pengujian data baru ditunjukkan pada Tabel 2 dengan perolehan akurasi sebesar 70%.

Tabel 2. *Confusion Matrix* Pengujian Data Baru

| | Kardus | Kaca | Logam | Kertas | Plastik | Sampah Lain |
|-------------|--------|------|-------|--------|---------|-------------|
| Kardus | 5 | 0 | 0 | 0 | 0 | 0 |
| Kaca | 0 | 2 | 0 | 0 | 3 | 0 |
| Logam | 0 | 0 | 5 | 0 | 0 | 0 |
| Kertas | 0 | 0 | 0 | 5 | 0 | 0 |
| Plastik | 0 | 1 | 0 | 0 | 4 | 0 |
| Sampah Lain | 0 | 0 | 2 | 1 | 2 | 0 |

Akurasi ini menunjukkan bahwa pengujian terhadap data baru masih belum optimal karena data yang masuk ke dalam model belum bisa diklasifikasikan dengan benar. Terutama pada kelas plastik, kaca, dan sampah lain. Data yang mengalami kesalahan klasifikasi berjumlah 9 dari 21 data pengujian. Hal ini disebabkan karena data pengujian baru memiliki karakteristik yang berbeda dari data pelatihan terkait *background* dan pencahayaannya. Selain itu, *dataset* TrashNet juga belum cukup mewakili data baru yang diuji.

Untuk memperbaikinya, perlu dilakukan perbaikan terhadap pengumpulan data baru dengan pengaturan intensitas pencahayaan, sudut pencahayaan, dan kamera yang digunakan. Data baru yang masuk ke model juga dapat digabungkan dengan data pelatihan untuk pembaruan model secara berkelanjutan.

3.2. Perbandingan dengan Penelitian Lain

Perbandingan akurasi pengujian terbaik dari penelitian ini dengan penelitian sebelumnya yang menggunakan *dataset* TrashNet secara penuh dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Akurasi Pengujian

| Penelitian | Metode | Akurasi |
|----------------------|-------------------------------------|---------|
| Yang & Thung (2016) | SVM + SIFT | 63% |
| Mittal et al. (2020) | CNN | 78% |
| Usulan (2021) | SVM + GLCM dan <i>Color Moments</i> | 78,87% |

Penelitian ini memberikan akurasi yang lebih tinggi daripada penelitian dari Yang & Thung (2016) dan Mittal et al. (2020). Penelitian ini memiliki kelemahan dalam persebaran data yang tidak seimbang pada setiap kelas.

Berdasarkan penelitian Leonardo et al. (2020) digunakan *dataset* TrashNet secara seimbang dengan jumlah 403 citra untuk lima kelas (kardus, kaca, logam, kertas, dan plastik). Ketika metode terbaik penelitian ini diterapkan menggunakan pembagian data yang seimbang seperti penelitian Leonardo et al. (2020), perbandingan akurasinya ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Akurasi Pengujian Data Seimbang

| Penelitian | Metode | Akurasi |
|------------------------|-------------------------------------|---------|
| Leonardo et al. (2020) | SVM + LBP | 88,09% |
| Usulan (2021) | SVM + GLCM dan <i>Color Moments</i> | 80,86% |

Penelitian ini memiliki rata-rata akurasi yang lebih rendah dibandingkan dengan penelitian Leonardo et al. (2020). Rendahnya nilai akurasi pada penelitian ini menunjukkan bahwa penggunaan ekstraksi fitur GLCM dan *Color Moments* saja dalam proses pengenalan sampah masih belum cukup, sehingga harus dikombinasikan dengan ekstraksi fitur lain seperti bentuk, warna, maupun tekstur. Hal ini dikarenakan adanya faktor kemiripan dalam citra ketika dilihat dari persebaran warna dan kedekatan tetangga piksel keabuan sehingga terjadi kesalahan klasifikasi.

4. KESIMPULAN

Penggunaan ekstraksi fitur GLCM dengan berbagai orientasi sudut, *Color Moments*, dan kombinasinya memengaruhi kinerja model yang terbentuk. Begitu pula penggunaan parameter C dan

γ dalam pembentukan model SVM. Kombinasi fitur GLCM dengan orientasi sudut 45° dan *Color Moments* memberikan rata-rata akurasi terbaik untuk pengujian *dataset* TrashNet sebesar 78,87% dengan parameter C bernilai 32 dan parameter γ bernilai 4. Hasil pengujian terbaik diperoleh pada *fold* ke-3 dari *10-Fold Cross Validation* dengan akurasi sebesar 85,43% yang digunakan sebagai skenario pengujian data baru. Persebaran data yang tidak seimbang pada setiap kelas memengaruhi hasil prediksi. Hasil prediksi didominasi oleh kelas-kelas dengan jumlah data yang lebih besar dari kelas lainnya. Sementara itu, pengujian terhadap 30 citra sampah baru menggunakan model terbaik memperoleh akurasi sebesar 70%. Pengujian pada data baru masih belum optimal dikarenakan data pengujian yang baru memiliki karakteristik yang berbeda dari segi background dan pencahayaannya.

Pada penelitian selanjutnya, perbaikan metode ekstraksi fitur dapat dilakukan dengan mengombinasikan ekstraksi fitur GLCM dan Color Moments dengan metode lain dari ekstraksi fitur bentuk, warna, dan atau tekstur. Selain itu, juga dapat dikembangkan dengan penerapan metode optimasi parameter SVM. Hal ini diharapkan dapat meningkatkan performa menjadi lebih optimal.

DAFTAR PUSTAKA

- ADEDEJI, O., & WANG, Z. 2019. Intelligent Waste Classification System using Deep Learning Convolutional Neural Network. *Procedia Manufacturing*, 35, 607–612. <https://doi.org/10.1016/j.promfg.2019.05.086>
- AHSANI, A. F., SARI, Y. A., & ADIKARA, P. P. 2019. Food Image Retrieval with Gray Level Co-Occurrence Matrix Texture Feature and CIE $L^*a^*b^*$ Color Moments Feature. *International Conference on Sustainable Information Engineering and Technology (SIET)*, 130–134. <https://doi.org/10.1109/SIET48054.2019.8985990>
- ASERY, R., SUNKARIA, R. K., SHARMA, L. D., & KUMAR, A. 2016, June. Fog detection using GLCM based features and SVM. *2016 Conference on Advances in Signal Processing (CASP)*. <https://doi.org/10.1109/CASP.2016.7746140>
- BAIRWA, D., & SHARMA, G. 2017. Classification of Fruits Based on Shape, Color and Texture using Image Processing Techniques. *International Journal Of Engineering Research & Technology (IJERT)*, 6(12, December 2017), 110–114. <https://doi.org/10.17577/IJERTV6IS120057>
- BAKTI, L. D., IMRAN, B., WAHYUDI, E., ARWIDIYARTI, D., SURYADI, E., MULTAZAM, M., & MASPAENI. 2021. Data extraction of the gray level Co-occurrence matrix (GLCM) Feature on the fingerprints of parents and children in Lombok Island, Indonesia. *Data in Brief*, 36. <https://doi.org/10.1016/j.dib.2021.107067>
- BRINTHA, V. P., REKHA, R., NANDHINI, J., SREEKAARTHICK, N., ISHWARYAA, B., & RAHUL, R. 2020. Automatic Classification of Solid Waste Using Deep Learning. In *Proceedings of International Conference on Artificial Intelligence, Smart Grid and Smart City Applications* (pp. 881–889). Springer International Publishing. https://doi.org/10.1007/978-3-030-24051-6_83
- CNN INDONESIA. 2018, April 25. *Riset: 24 Persen Sampah di Indonesia Masih Tak Terkelola*. Retrieved from <https://www.cnnindonesia.com/gaya-hidup/20180425101643-282-293362/riset-24-persen-sampah-di-indonesia-masih-tak-terkelola> [Accessed 24 October 2020]
- FOEADY, A. Z., NOVITASARI, D. C. R., ASYHAR, A. H., & FIRMANSJAH, M. 2018, October. Automated Diagnosis System of Diabetic Retinopathy Using GLCM Method and SVM Classifier. *2018 5th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*. <https://doi.org/10.1109/EECSI.2018.8752726>
- HARYANTO, T., PRATAMA, A., SUHARTANTO, H., MURNI, A., KUSMARDI, K., & PIDANIC, J. 2020. Multipatch-GLCM for texture feature extraction on classification of the colon histopathology images using deep neural network with GPU acceleration. *Journal of Computer Science*, 16(3), 280–294. <https://doi.org/10.3844/JCSSP.2020.280.294>
- HUMEAU-HEURTIER, A. 2019. Texture feature extraction methods: A survey. In *IEEE Access* (Vol. 7, pp. 8975–9000). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2018.2890743>
- KEEN, N. 2005. *Color Moments*. Retrieved from http://homepages.inf.ed.ac.uk/rbf/CVonline/L_OCAL_COPIES/AV0405/KEEN/av_as2_nkeen.pdf
- LEONARDO, YOHANNES, & HARTATI, E. 2020. Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine dengan Fitur Local Binary Pattern. *Jurnal Algoritme*, 1, 78–89. Retrieved from <http://jurnal.mdp.ac.id/index.php/algoritme/article/view/440>
- MAO, W. L., CHEN, W. C., WANG, C. T., & LIN, Y. H. 2020. Recycling Waste Classification using Optimized Convolutional Neural Network. *Resources, Conservation and Recycling*, 164. <https://doi.org/10.1016/j.resconrec.2020.105132>

- MITTAL, I., TIWARI, A., RANA, B., & SINGH, P. 2020. *Trash Classification: Classifying garbage using Deep Learning*. *Journal of Engineering Sciences*. 11. 61-68. <http://dx.doi.org/10.13140/RG.2.2.19452.56969>
- SAKR, G. E., MOKBEL, M., DARWICH, A., KHNEISSER, M. N., & HADI, A. 2016. Comparing Deep Learning And Support Vector Machines for Autonomous Waste Sorting. *2016 IEEE International Multidisciplinary Conference on Engineering Technology (IMCET)*, 207–212. <https://doi.org/10.1109/IMCET.2016.7777453>
- SHAPARIA, R. H., PATEL, N. M., & SHAH, Z. H. 2017. Flower Classification using Texture and Color Features. *International Conference on Re-Search and Innovations in Science, Engineering & Technology (ICRISET)*, 2, 113–118. <https://doi.org/10.29007/6mt1>
- SIDHARTH, R., ROHIT, P., VISHAGAN, S., KARTHIKA, R., & GANESHAN, M. 2020. Deep Learning based Smart Garbage Classifier for Effective Waste Management. *5th International Conference on Communication and Electronics Systems (ICCES)*, 1086–1089. <https://doi.org/10.1109/ICCES48766.2020.9137938>
- WANG KUN, & KONG SONGTAO. 2011, May. Identification method of waste based on gray level co-occurrence matrix and neural network. *2011 International Conference on Materials for Renewable Energy & Environment*. <https://doi.org/10.1109/ICMREE.2011.5930954>
- YANG, M., & THUNG, G. 2016. *Classification of Trash for Recyclability Status*. Retrieved from <http://cs229.stanford.edu/proj2016/report/ThungYang-ClassificationOfTrashForRecyclabilityStatus-report.pdf>