

SISTEM KLASIFIKASI JENIS SAMPAH BERDASARKAN KOMBINASI FITUR WARNA DAN TEKSTUR MENGGUNAKAN ARTIFICIAL NEURAL NETWORK BERBASIS PENGOLAHAN CITRA DIGITAL

Rezki Nurul Jariah S. Intam¹, Ahmad Raihan², Muh.Alfajri³, Andi Baso Kaswar^{*4},
Dyah Darma Andayani⁵, Asnidar⁶

^{1,2,3,4,5,6} Universitas Negri Makassar, Makassar

Email: ¹rezkinuruljariah@gmail.com, ²araihanassyam@gmail.com, ³muhalfajri225@gmail.com,
⁴a.baso.kaswar@unm.ac.id, ⁵dyahdarma@unm.ac.id, ⁶asnidarbahri@gmail.com

*Penulis Korespondensi

(Naskah masuk: 20 Desember 2023, diterima untuk diterbitkan: 25 April 2024)

Abstrak

Pengelolaan sampah merupakan isu multisektor yang memiliki dampak dalam berbagai aspek kehidupan manusia. Dalam pengelolaan sampah yang efektif bukan hanya tentang membersihkan lingkungan, tetapi juga tentang melindungi kesehatan masyarakat dan mendorong pembangunan berkelanjutan. Sampah harus dikelola dengan cermat untuk mengurangi dampak negatifnya dan memaksimalkan manfaatnya bagi masyarakat. Namun, di berbagai lokasi pembuangan sampah, kecenderungan campuran antara sampah organik dan anorganik masih menjadi tantangan yang signifikan. Hal ini tidak hanya menghambat efisiensi proses pengelolaan sampah, tetapi juga meningkatkan risiko pencemaran lingkungan yang berpotensi merugikan. Oleh karena itu, dalam penelitian ini, penggunaan teknologi pengolahan citra digital dengan metode Artificial Neural Network (ANN) menjadi krusial. Metode ini tidak hanya dapat memilah sampah dengan lebih efisien, tetapi juga memberikan kemungkinan untuk meminimalkan kesalahan dalam pengelompokan sampah. Adapun metode yang disarankan terdiri dari enam tahap yaitu, tahap akuisisi citra, *preprocessing*, segmentasi, morfologi, ekstraksi fitur, dan klasifikasi berdasarkan model jaringan syaraf tiruan yang telah dilatih. Pada penelitian ini juga, dilakukan beberapa skenario pengujian untuk menentukan kombinasi fitur yang memiliki tingkat akurasi terbaik. Hasil pengujian menunjukkan 2 kombinasi fitur terbaik yaitu fitur warna *HSV*, *LAB* dan fitur tekstur. Berdasarkan hasil pengujian terhadap 210 citra uji, diperoleh rata-rata *precision* 84,11%, *recall* 84,16%, *F1-Score* 84,08% dan akurasi keseluruhan mencapai 84%. Hasil tersebut menunjukkan bahwa pengelompokan jenis sampah telah dilakukan dengan cukup akurat.

Kata kunci: Jaringan Syaraf Tiruan, Klasifikasi, Pengolahan Citra, Sampah

WASTE TYPE CLASSIFICATION SYSTEM BASED ON A COMBINATION OF COLOR AND TEXTURE FEATURES USING ARTIFICIAL NEURAL NETWORK BASED ON DIGITAL IMAGE PROCESSING

Abstract

Waste management is a multisector issue that has an impact on various aspects of human life. Effective waste management is not only about cleaning the environment, but also about protecting public health and promoting sustainable development. Waste must be managed carefully to reduce its negative impacts and maximize its benefits for society. However, in various waste disposal locations, the tendency for mixing organic and inorganic waste is still a significant challenge. This not only hampers the efficiency of the waste management process, but also increases the risk of potentially detrimental environmental pollution. Therefore, in this research, the use of digital image processing technology using the Artificial Neural Network (ANN) method is crucial. This method can not only sort waste more efficiently, but also provides the possibility to minimize errors in waste grouping. The proposed method consists of six stages, namely, image acquisition, preprocessing, segmentation, morphology, feature extraction and classification based on a drilled artificial neural network model. In this research, several test scenarios were also carried out to determine the combination of features that had the best level of accuracy. The test results show the 2 best feature combinations, namely HSV color features, LAB and texture features. Based on test results on 210 test images, an average precision of 84.11%, recall of 84.16%, F1-Score of 84.08% and overall accuracy of 84% were obtained. These results indicate that the classification of waste types has been carried out quite accurately.

Keywords: Artificial Neural Networks, Classification, Image Processing, Waste

1. PENDAHULUAN

Sampah adalah benda yang tidak lagi digunakan oleh pemiliknya dan harus dikelola dengan baik. Sampah merupakan salah satu dari banyaknya permasalahan dalam kehidupan masyarakat yang dapat memberikan dampak negatif bagi lingkungan masyarakat jika tidak dikelola dengan baik (Pageh, and Aryana, 2019). Dalam pengelompokannya, sampah bisa dibedakan menjadi dua kategori utama, yakni sampah anorganik serta sampah organik. Sampah organik ialah jenis limbah yang dihasilkan oleh sisa-sisa alam, seperti tumbuhan dan hewan yang akan mengalami proses pembusukan ataupun pelapukan. Sampah anorganik, yang berasal dari sisa aktivitas manusia, sulit terurai oleh bakteri dan membutuhkan waktu yang lama (hingga ratusan tahun) untuk dapat terurai. Sampah organik, di sisi lain, merupakan jenis sampah yang lebih ramah lingkungan karena dapat terurai oleh bakteri secara alami dalam waktu yang relative cepat (Aulia et al., 2021) dan (Prasetyo et al., 2023).

Perlu diketahui bahwa sampah, baik itu organik atau anorganik, pada dasarnya masih memiliki nilai manfaat. Salah satu manfaat dari sampah organik adalah dapat dijadikan kompos dan pupuk sederhana, sedangkan sampah anorganik dapat dijadikan bahan kerajinan tangan jika di daur ulang. Meskipun demikian, sampah organik dan anorganik juga dapat memberikan dampak kerusakan lingkungan apabila tidak dikelola dengan baik dan tepat (Zuraidah, Rosyidah and Zulfi, 2022).

Menurut data yang dipublikasikan oleh Sistem Informasi Penanggulangan Sampah Nasional (SIPSN) pada tahun 2023, Indonesia menghasilkan sekitar 35,93 juta ton sampah per tahun. Meskipun terdapat penurunan sebanyak 15,1% atau sekitar 5,4 juta ton dibandingkan tahun sebelumnya, perlu dicatat bahwa dari jumlah tersebut, hanya sekitar 62,49% atau sekitar 22,45 juta ton sampah yang berhasil dikelola dengan baik. Sementara, sekitar 37,51% atau sekitar 13,48 juta ton sampah masih tidak terkelola dengan baik. Selain itu, dengan jumlah tersebut, dalam komposisi jenis sampah, sisa makanan merupakan jenis sampah terbanyak dengan persentase sekitar 40,8%, diikuti oleh sampah plastik yang mencapai 18% (Rasidi et al., 2022).

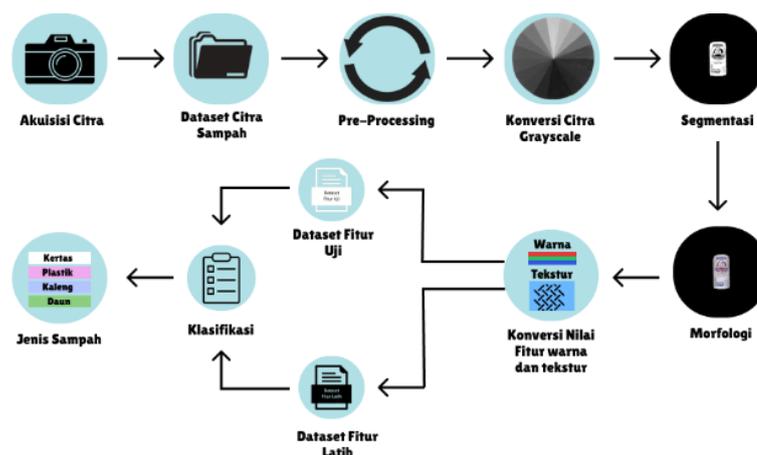
Saat ini, fasilitas pengelolaan sampah sudah diatur secara terpisah. Meskipun demikian, masyarakat masih tidak membuang sampah sesuai dengan kategori ataupun jenis sampahnya. Fenomena tersebut terlihat ketika sampah diangkut ke tempat pembuangan akhir. Sampah organik dan anorganik masih tercampur, dimana banyak sampah jenis organik masuk ke tempat sampah yang seharusnya untuk sampah anorganik, dan sebaliknya. Salah satu faktornya adalah kurangnya kesadaran serta kemampuan masyarakat dalam membedakan antara kedua jenis sampah tersebut. Permasalahan tersebut kemudian menjadi landasan diperlukannya sistem

yang dapat secara otomatis mengklasifikasikan sampah organik dan anorganik. Dengan memisahkan dua jenis sampah yaitu organik dan anorganik, tidak hanya dapat membantu mencegah pencemaran, tetapi juga mempermudah proses daur ulang sampah.

Saat ini, teknik klasifikasi citra telah berkembang pesat, terutama dalam mengenali objek yang memiliki kemiripan bentuk dan ukuran. Salah satu tantangan utama dalam pengembangan aplikasi berbasis *computer vision* adalah mengembangkan jenis klasifikasi yang mampu menemukan pola pada citra sehingga dapat menarik informasi bermakna dan mengenali objek secara akurat dari dalam citra tersebut. Dalam proses klasifikasi citra, salah satu metode yang paling umum digunakan yaitu konsep *Machine Learning* (ML). ML adalah suatu model pembelajaran di mana komputer dapat menggunakan data latih citra untuk belajar secara mandiri (Nugroho, Umar and Fadlil, 2021). Dapat dilihat pada perkembangan teknologi tersebut, teknologi pengolahan citra digital dapat menjadi alternatif pendekatan yang efektif untuk mempermudah dalam mengklasifikasikan atau mengelompokkan sampah organik dan anorganik.

Salah satu algoritma dalam ML yang masih berkembang dan masih banyak digunakan saat ini adalah Jaringan Syaraf Tiruan (JST). Sampai saat ini telah banyak penelitian yang dilakukan sebelumnya dengan memanfaatkan JST. Misalnya penelitian terkait pengidentifikasian dan pengklasifikasian citra digital, dengan menggunakan beberapa metode dan berbagai bentuk sampel yang berbeda, salah satunya yaitu metode JST *Backpropagation* guna mengklasifikasikan penyakit karies (karang gigi), dimana data yang digunakan yaitu data dari dokter gigi. Hasil penelitian tersebut menunjukkan tingkat akurasi sebesar 90% (Nur Rohkham and Darujati, 2020). Selain itu juga terdapat penelitian sebelumnya yang memanfaatkan Jaringan Saraf Tiruan (JST) guna mengidentifikasi usia berdasarkan citra wajah secara otomatis. Sampel yang digunakan berasal dari *FG-Net*, yaitu situs yang menyediakan dataset citra wajah dalam jumlah besar, dimana dataset tersebut dibagi menjadi 3 kelas yaitu kelas anak-anak, remaja, dan dewasa. Dalam penelitian tersebut *Gabor Filter* dimanfaatkan untuk membangun ciri setiap dataset yang digunakan. Metode yang disarankan dalam penelitian ini menunjukkan akurasi sebesar 83% (Melangi, 2020).

Penelitian berikutnya memanfaatkan JST dengan menggunakan fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) untuk mendeteksi penyakit tanaman daun. Pada penelitian ini, dataset dibagi ke dalam 3 kelas yaitu kelas penyakit karat putih, kekurangan mangan, dan virus keriting. GLCM digunakan untuk mengekstraksi fitur tekstur pada objek dalam citra.



Gambar 1. Tahapan metode yang diusulkan

Metode yang diusulkan tersebut menghasilkan akurasi sebesar 100% untuk penyakit karat putih, 90% untuk virus keriting, dan 90% untuk penyakit kekurangan pangan (Ishanan and Mustofa, 2019). Selanjutnya, dengan metode yang sama juga diterapkan guna mengklasifikasikan citra teks dalam penerjemahan bahasa daerah. Metode yang diusulkan dengan memanfaatkan model Jaringan Saraf Tiruan yang telah dilatih mampu mengklasifikasi 1.591 citra teks dengan benar (Fathurrahman, Santoni and Muliawati, 2020).

Selain itu, juga terdapat beberapa penelitian lainnya yang menggunakan metode berbeda. Salah satu penelitian lainnya menggunakan *Multiclass Support Vector Machine* (SVM). Pada penelitian tersebut sampel yang digunakan yaitu botol plastik berdasarkan label merek, dimana botol yang digunakan yaitu merek aqua, coca cola, fanta, sprite dan *mute maid pulpy* yang semuanya berukuran sedang. Hasil pengujian menunjukkan bahwa metode *Multiclass Support Vector Machine One* (MSVMO) vs *All* mencapai tingkat akurasi sebesar 56%, 70%, dan 84% untuk kombinasi data pelatihan dan pengujian yang berbeda.

Penelitian berikutnya, menggunakan teknologi berbasis sensor elektronik dan pengolahan citra untuk mengkategorikan jenis sampah. Pada penelitian tersebut, sampel yang digunakan yaitu berupa botol plastik, dan botol kaca. Hasil pengujian yang dilakukan menunjukkan bahwa teknik yang diusulkan memiliki kemampuan untuk mendeteksi dan mengenali jenis sampah dengan akurasi rata-rata sebesar 70% (Abdallah et al., 2020). Namun, beberapa penelitian tersebut di atas masih belum ada yang berfokus pada pengklasifikasian jenis sampah dengan memanfaatkan jaringan syaraf tiruan. Selain itu metode dan fitur yang diusulkan untuk mengklasifikasi sampah secara otomatis masih menunjukkan akurasi yang relatif rendah. Selain itu, jumlah kumpulan data yang digunakan agak terbatas baik pada data pelatihan maupun pengujian, sehingga memengaruhi keakuratan hasil klasifikasi.

Oleh karena itu, penelitian ini mengusulkan sistem klasifikasi sampah yang menggunakan kombinasi karakteristik warna dan tekstur menggunakan metode *Artificial Neural Network* berbasis pengolahan citra digital. Pada penelitian ini dilakukan klasifikasi atau pemilahan sampah organik (daun) dan sampah anorganik (plastik, kertas, dan kaleng) berdasarkan fitur kemiripan bentuk dan ukuran citra. Sampel yang digunakan sebanyak 400 citra, yang akan dibagi ke empat kelas.

2. METODE PENELITIAN

Metodologi yang disarankan dalam penelitian ini terdiri dari beberapa langkah yang harus diselesaikan secara berurutan, seperti akuisisi citra, pra-pemrosesan, melakukan segmentasi, melakukan operasi morfologi, mengekstraksi fitur, dan mengklasifikasikannya. Proses-proses tersebut ditampilkan pada Gambar 1.

2.1 Akuisisi Citra

Pada tahap ini dilakukan proses pengambilan dataset citra sampah. Jumlah citra sampah yang digunakan pada penelitian ini sebanyak 400 citra yang terdiri dari 100 sampah plastik, 100 sampah daun, 100 sampah kertas, dan 100 sampah kaleng.

Dalam proses pengambilan citra menggunakan kamera *smartphone* Poco X dengan pengaturan *manual ISO 200, focal length 5.43 mm, exposure time 1/20 sec, F-Stop f/1.89, Mode Pro* dan *no flash*. Hasil akuisisi citra yang dihasilkan berdimensi 4233 x 4233 piksel dengan resolusi 96 dpi. Selain itu selama proses pengambilan citra digunakan *box* berukuran 50 x 50 cm, dimana di dalam *box* tersebut terdapat kain berwarna hitam yang dijadikan sebagai *background*. Di dalam *box* tersebut juga terdapat 3 lampu. Bagian atas *box* terdapat lubang untuk meletakkan kamera untuk mengambil citra atau objek yang ada di dalam *box* tersebut. *Box* ini didesain menyerupai kotak perangkat pemilah sampah menggunakan konveyor. Penggunaan *box* tersebut dilakukan agar hasil citra yang dihasilkan konsisten

karena tidak terpengaruh oleh *noise* atau perubahan intensitas cahaya yang bervariasi dari luar *box* secara signifikan. Dengan memisahkan objek dari pengaruh cahaya luar dan memanfaatkan pencahayaan internal yang terkendali, maka masalah variasi tingkat kecerahan dapat diatasi secara lebih efisien.

2.2 Proses Preprocessing

Proses ini merupakan langkah yang dilakukan untuk meningkatkan citra. Contoh prosedur yang disebutkan adalah mengatur kecerahan dan kontras, menghilangkan *noise*, memulihkan dan mengubah gambar, serta mengidentifikasi wilayah citra yang perlu diamati. (Saifullah, 2020).

Pada metode yang diusulkan dalam penelitian ini, hasil dari pengambilan citra digital sampah menjadi masukan untuk sistem yang dibangun. Setelah citra berhasil dibaca oleh sistem, citra diubah menjadi citra *grayscale*. Ruang warna *grayscale* dipilih karena sampah pada dasarnya tidak hanya memiliki satu jenis warna melainkan memiliki warna yang beragam, sehingga dipilih citra *grayscale* untuk memisahkan antara objek dan *background* dengan harapan memperoleh akurasi yang lebih baik.

2.3 Proses Segmentasi

Tahap segmentasi merupakan prosedur yang digunakan untuk membagi bagian objek dan latar belakang gambar digital yang telah diproses. (Batubara, Widiyanto and Chamidah, 2020). Dalam penelitian ini, metode segmentasi Otsu thresholding diterapkan untuk memisahkan kedua bagian tersebut. Metode Otsu secara otomatis menentukan nilai *threshold* pada citra berdasarkan histogramnya untuk melakukan proses segmentasi.

Pada penelitian ini, langkah awal segmentasi melibatkan analisis histogram dari citra *grayscale* yang sudah dipilih pada tahap preprocessing. Hasilnya adalah citra biner di mana bagian yang berwarna putih (nilai 1) mewakili objek, sementara bagian yang hitam (nilai 0) menggambarkan *background*.

2.4 Proses Operasi Morfologi

Hasil segmentasi pada tahap sebelumnya memiliki kemungkinan ketidaksempurnaan. Oleh karena itu, untuk meningkatkan akurasi dalam mengidentifikasi objek, Sebelum mengekstraksi fitur dari wilayah objek citra, digunakan teknik operasi morfologi untuk melakukan langkah pembersihan *noise* pada gambar yang disegmentasi.

Operasi morfologi adalah suatu metode yang menggunakan topologi dan bentuk geometri sebagai dasar untuk menganalisis citra, dan metode ini sangat bermanfaat dalam mengekstrak struktur dan bentuk geometri dalam berbagai aplikasi (Susanto, 2019). Selain itu operasi ini juga banyak dimanfaatkan untuk meningkatkan akurasi hasil segmentasi. Adapun teknik operasi morfologi yang umum digunakan

seperti dilasi, erosi, *closing*, *opening*, *hole filling* dan *bwareaopen* (Yatim, Sari and Ningrum, 2019). Dalam operasi morfologi juga dikenal istilah *structuring element (strel)* yang memiliki 10 jenis bentuk. Adapun *strel* yang digunakan dalam penelitian ini adalah *strel* berbentuk disk.

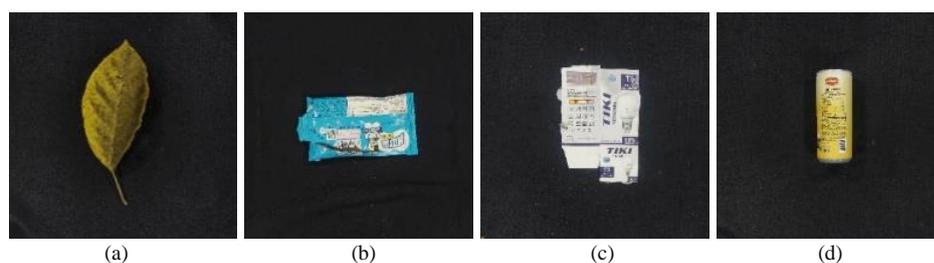
Erosi merupakan teknik pengurangan atau pemangkasan piksel objek dalam citra, sedangkan, dilasi merupakan teknik penambahan piksel objek dalam citra. Penerapan operasi dilasi setelah operasi erosi menghasilkan *opening*. Di sisi lain, *closing* adalah hasil dari prosedur erosi yang diterapkan setelah operasi dilasi. (Zendhaf, Magdalena and Fu'Adah, 2018). Operasi *hole filling* digunakan untuk mengisi lubang, bagian yang dianggap sebagai *background* di tengah area objek atau sebaliknya, yang mungkin ada dalam area objek pada citra. Selanjutnya, operasi *bwareaopen* dimanfaatkan untuk menghapus atau menghilangkan objek-objek tertentu yang ada dalam citra berdasarkan batasan nilai piksel yang telah ditentukan.

Dalam penelitian ini, teknik yang digunakan secara berurut yaitu dilasi, erosi, *closing*, *hole filling*, dan *bwareaopen*. Mulai dengan teknik dilasi menggunakan *strel* disk berukuran 10 *px* terhadap citra hasil segmentasi, kemudian pada hasil dilasi diterapkan teknik erosi yang juga menggunakan *strel* disk 10 *px*. Kemudian dilakukan teknik *closing* diterapkan pada citra hasil erosi menggunakan *strel* disk berukuran 5 *px*. Setelah itu, dilakukan teknik *hole filling* terhadap citra hasil *closing*, dan teknik yang terakhir yang dilakukan yaitu teknik *bwareaopen* dengan nilai parameternya sebesar 20000 *px*, dimana teknik *bwareaopen* tersebut akan menghapus item yang tidak diperlukan lagi dengan luas kurang dari 20.000 piksel. Hasil dari tahap ini adalah hasil segmentasi yang secara sempurna membagi citra ke dalam area objek dan *background*.

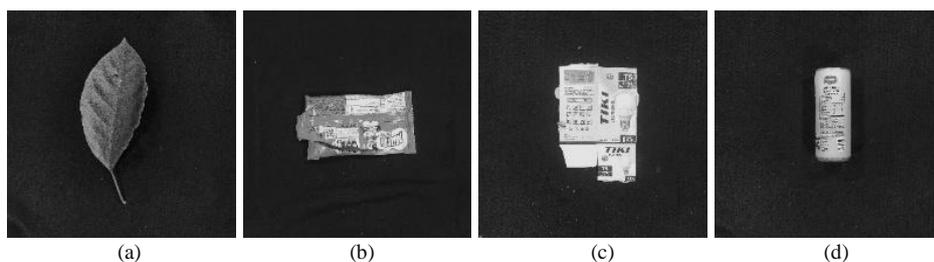
2.5 Proses Ekstraksi Fitur

Proses ekstraksi fitur mempunyai tujuan untuk mengekstrak atribut-atribut khas dari citra yang telah melalui proses segmentasi dan operasi morfologi. Atribut-atribut ini dapat berupa informasi tentang warna, bentuk, serta tekstur. Pemilihan fitur-fitur tersebut haruslah tepat dan menjadi parameter yang dapat membedakan antara kelas citra yang berbeda dalam proses klasifikasi, berperan sebagai ciri khas yang membedakan setiap kelas citra yang telah diakuisisi (Agung et al., 2023).

Dalam penelitian ini, fitur warna dan tekstur dijadikan sebagai fitur inputan pada tahap klasifikasi. Untuk fitur warna, ruang warna yang digunakan adalah *HSV* dan *LAB*. Dimana, *HSV* merupakan unsur warna yang mencakup *hue*, *saturation*, dan *value*. *Hue* berperan dalam menentukan tingkat kemerahan, kehijauan, dan aspek lain dari warna. *Saturation* berperan untuk menunjukkan sejauh mana warna tersebut bersih atau intens. Sedangkan *value* mencerminkan tingkat kecerahan, dimana nilai 0



Gambar 2. Contoh citra kelas (a) plastik, (b) kertas, (c) kaleng, dan (d) daun



Gambar 3. Contoh citra grayscale kelas (a) plastik, (b) kertas, (c) kaleng, dan (d) daun

menandakan warna hitam, dan semakin tinggi nilainya menunjukkan kecerahan yang lebih besar (Dzulhijjah, Anraeni and Sugiarti, 2021) dan (Suryadi, Putri and Febrianti, 2022). Sedangkan ruang warna *LAB* terdiri dari 3 komponen utama yaitu *L* (*Lightness*), *A* (*Axis of Green to Red*), dan *B* (*axis of Blue to Yellow*). Dimana *L* menunjukkan tingkat kecerahan atau kegelapan warna, *A* merupakan sumbu yang menggambarkan variasi dari hijau ke merah, sedangkan *B* merupakan sumbu yang menggambarkan variasi dari biru ke kuning (Sinaga, 2019).

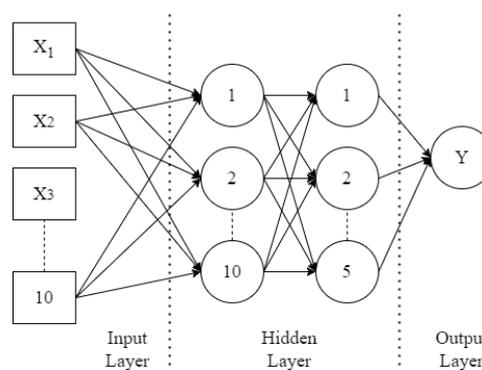
Dalam ekstraksi fitur warna *HSV*, dan *LAB*, langkahnya melibatkan perhitungan nilai piksel dari masing-masing *channel* *H*, *S*, *V*, *L*, *A*, dan *B* dalam objek citra yang telah ditandai. Selanjutnya, rata-rata, atau nilai piksel rata-rata setiap saluran, diambil. Sedangkan pendekatan *Gray-Level Co-occurrence Matrix* (*GLCM*) digunakan untuk mendapatkan nilai kontras, korelasi, energi, dan homogenitas pada data tekstur.

GLCM sendiri merupakan metode ekstraksi ciri yang didasarkan pada statistik. Ciri-ciri diperoleh dari nilai piksel dalam matriks yang memiliki hubungan tertentu dan pola arah tertentu (Nisa et al., 2022) dan (Riana et al., 2022).

2.6 Proses Klasifikasi

Pada proses klasifikasi sampah, langkah awalnya adalah membagi data citra menjadi dua dataset, yakni data latih sebesar 70% dan data uji sebesar 30% dari total keseluruhan citra. Setiap dataset tersebut terdiri dari empat kelas: citra plastik (1), citra daun (2), citra kertas (3), dan citra kaleng (4). Dataset latih digunakan untuk membuat model klasifikasi yang akan diuji dengan menggunakan dataset uji.

Metode klasifikasi yang diterapkan dalam penelitian ini yaitu menggunakan *JST* yang menggunakan algoritma *Feedforward Backpropagation*. Arsitektur *JST* yang diterapkan melibatkan 10 *neuron* pada lapisan *input*, sesuai dengan hasil skenario yang diperoleh. Selanjutnya, terdapat 2 lapisan tersembunyi dengan 10 *neuron* pada lapisan pertama dan 5 *neuron* pada lapisan kedua, yang masing-masing menggunakan fungsi aktivasi *log sigmoid*. Untuk lapisan *output*, terdapat 1 *neuron*. Selain itu, dalam model *JST* yang dikembangkan, jumlah *epoch* atau iterasi ditetapkan sebanyak 1000, dengan target *error* yang ditentukan sebesar $1e-6$. Proses pelatihan dilakukan menggunakan fungsi *train* yang mengadopsi algoritma *Levenberg-Marquardt* untuk mengoptimalkan bobot dan bias. Pendekatan ini bertujuan untuk mengurangi kesalahan kuadrat serta mencapai kombinasi bobot yang sesuai, sehingga



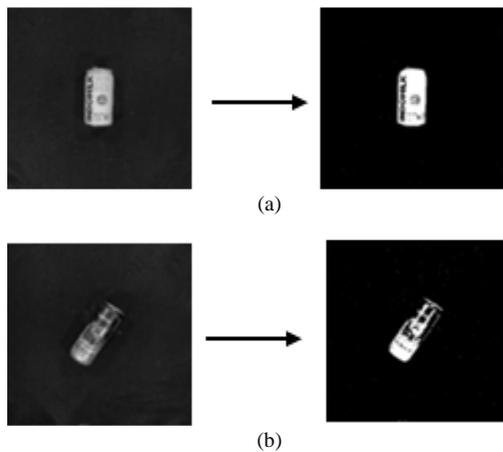
Gambar 4. Arsitektur Jaringan Syaraf Tiruan

dapat menghasilkan prediksi yang akurat. Adapun ilustrasi mengenai arsitektur *JST* yang dibangun dapat dilihat pada Gambar 4.

3. HASIL DAN PEMBAHASAN

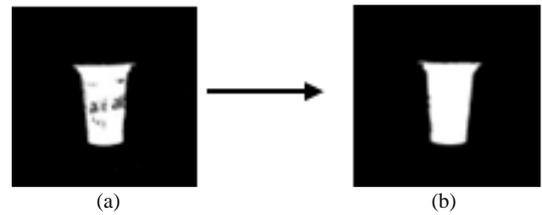
Untuk memulai penelitian ini, kami memisahkan 400 kumpulan data citra sampah menjadi dua kelompok yaitu citra pelatihan dan citra uji. Kumpulan data ini mencakup empat kelas plastik, kertas, kaleng, dan daun. Citra latih mencakup 70% dari total dataset, dengan masing-masing kelas memiliki 70 citra dan total keseluruhan data latih sebanyak 280 citra. Sementara itu, citra uji mencakup 30% dari total dataset, dengan masing-masing kelas memiliki 30 citra dan total keseluruhan citra uji yaitu sebanyak 120 citra. Adapun hasil akuisisi citra yang telah diperoleh berdasarkan kelasnya dapat dilihat pada Gambar 2.

Selanjutnya, Gambar 3 menunjukkan hasil dari tahap *preprocessing* berupa konversi warna *RGB* ke dalam ruang warna *grayscale*. Citra *grayscale* terpilih dikarenakan jenis sampah yang digunakan pada penelitian ini pada dasarnya tidak hanya memiliki satu jenis warna melainkan memiliki warna yang beragam, sehingga dipilih citra *grayscale* untuk lebih memudahkan pemisahan yang jelas antara objek dan latar belakang pada tahap segmentasi. Dimana metode yang digunakan dalam proses segmentasi yaitu metode segmentasi *otsu thresholding*. Adapun hasil segmentasi dari penerapan metode *Otsu* ditampilkan pada Gambar 5.

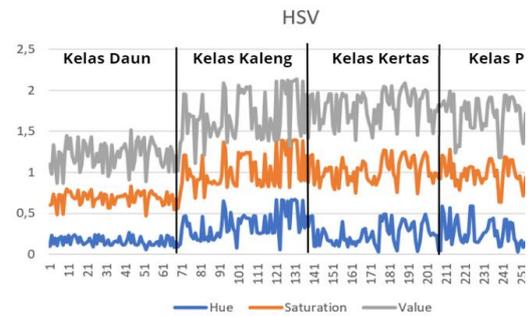


Gambar 5. Contoh hasil segmentasi (a) baik dan (b) kurang baik

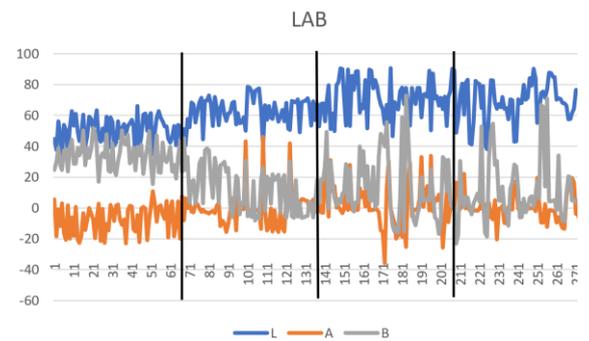
Bisa dilihat pada Gambar 5 merupakan hasil dari proses segmentasi yang menggunakan citra *grayscale*. Pada Gambar 5a merupakan hasil segmentasi yang baik, dimana piksel yang dilabeli dengan piksel berwarna putih merupakan objek, sedangkan piksel yang dilabeli warna hitam dianggap sebagai *background*. Hasil segmentasi yang akurat dapat diperoleh disebabkan oleh warna dari objek yang ada pada Gambar 5a lebih terang sehingga metode *otsu* mampu membedakan antara objek dan *background* dengan mudah.



Gambar 6. Contoh citra hasil (a) segmentasi, dan (b) operasi morfologi



Gambar 7. Grafik Nilai Fitur Warna Channel HSV

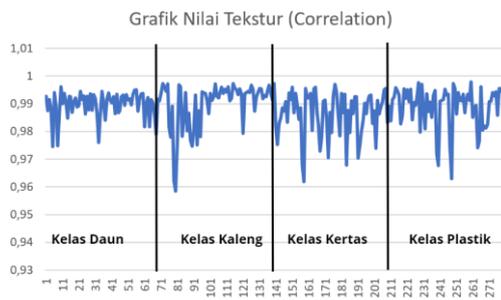


Gambar 8. Grafik Nilai Fitur Warna Channel LAB



Gambar 9. Grafik Nilai Fitur Tekstur Contrast

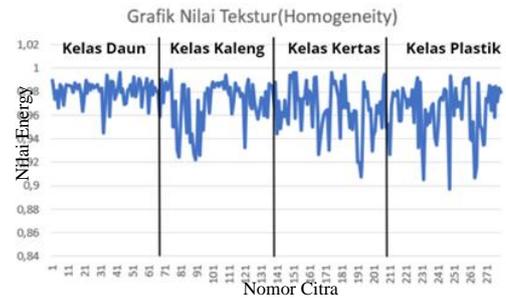
Sementara itu, Gambar 5b menunjukkan contoh temuan segmentasi yang kurang tepat, banyak bagian item terlihat di latar belakang, hal tersebut terjadi karena citra *grayscale* yang digunakan terdapat objek yang warnanya gelap yang hampir menyerupai warna dari *background*. Hal tersebut menyebabkan bagian dari objek tersebut di deteksi sebagai *background*, dan juga terdapat beberapa *noise* (objek kecil) yang terdeteksi sebagai objek

Gambar 10. Grafik Nilai Fitur *Correlation*Gambar 11. Grafik Nilai Fitur *Energy*

Hasil segmentasi yang tidak optimal dapat mengurangi akurasi ekstraksi fitur citra. Oleh karena itu, prosedur morfologi perlu diterapkan pada hasil segmentasi agar diperoleh ekstraksi ciri yang lebih representatif dan hasil segmentasi yang lebih baik. Proses dilasi, erosi, penutupan, pengisian lubang, dan *bwareaopen* adalah beberapa proses morfologi yang digunakan dalam penelitian ini. Selain itu, jenis *strel* yang digunakan juga merupakan faktor penting dalam proses ini. Dalam hal ini, *disk* berukuran 5 piksel digunakan untuk operasi dilasi, sedangkan *disk* 10 piksel digunakan untuk proses erosi dan *closing*.

Pada Gambar 6 dapat dilihat perbedaan antara hasil segmentasi sebelum dan setelah penerapan operasi morfologi. Hasil segmentasi sebelum di terapkannya operasi morfologi ditampilkan pada Gambar 6a, dimana pada gambar tersebut terlihat beberapa *noise* yang terdeteksi sebagai objek kecil dan sebaliknya, beberapa piksel yang seharusnya dianggap sebagai objek justru terdeteksi sebagai *background*. Sedangkan pada Gambar 6b merupakan hasil dari operasi morfologi yang dikembalikan ke nilai *channel* RGB, dimana objek kecil yang sebelumnya terdeteksi telah hilang sepenuhnya dan beberapa bagian objek yang terdeteksi sebagai *background* semakin mengecil sehingga didapatkan hasil segmentasi citra yang baik.

Setelah mendapatkan hasil segmentasi yang akurat, langkah berikutnya adalah melakukan ekstraksi fitur. Terdapat dua jenis fitur yang digunakan yaitu fitur warna, dan tekstur. Pemilihan kedua fitur tersebut didasarkan pada hasil percobaan dari beberapa skenario fitur yang ada. Hasil percobaan menunjukkan bahwa fitur warna *HSV* dan *LAB*, bersama dengan fitur tekstur, menunjukkan

Gambar 12. Grafik Nilai Fitur *Homogeneity*

nilai akurasi yang sangat tinggi dibandingkan dengan skenario gabungan fitur lainnya. Fitur warna diekstrak dengan menggunakan parameter dalam ruang fitur *HSV* dan *LAB*. Sementara itu, fitur tekstur yang diekstrak adalah fitur *energy* (keseragaman), *contrast* (kontras), *homogeneity* (kedekatan), serta *correlation* (korelasi) dengan menggunakan metode analisis fitur tekstur citra GLCM.

Untuk menunjukkan pola fitur yang digunakan, Gambar 7 menampilkan grafik temuan ekstraksi fitur warna untuk *HSV* dan Gambar 8 untuk *LAB*. Sementara itu, grafik hasil ekstraksi khusus untuk fitur tekstur dapat dilihat pada Gambar 9-12.

Berdasarkan grafik yang ditampilkan pada Gambar 7, dapat diperoleh informasi bahwa ada perbedaan signifikan antara kelas daun dan kelas sampah lainnya. Rata-rata intensitas piksel objek daun nilainya lebih rendah dibanding kelas kertas, kaleng dan plastik yang nilai intensitasnya cenderung lebih tinggi. Rata-rata nilai intensitas cahaya yang ada di setiap kelas yaitu, kelas daun sebesar 1,21, kaleng sebesar 1,7, kertas sebesar 1,80, dan plastik sebesar 1,73. Berdasarkan rata-rata nilai intensitas tersebut, dapat diketahui bahwa pada kelas daun memiliki nilai warna *HSV* yang rendah, sedangkan kelas kertas, kaleng dan plastik nilainya rata-ratanya hampir sama.

Selanjutnya, berdasarkan grafik pada Gambar 8 dapat diketahui perbedaan dari setiap kelas. Dimana *channel* A pada kelas daun lebih mengarah atau lebih menunjukkan ke warna hijau karna nilainya lebih banyak ke arah negative. Terdapat variasi lain yang terlihat pada setiap kelas, pada kelas daun mempunyai grafik naik-turun yang tidak terlalu signifikan, sedangkan kelas kertas, kaleng, dan plastik mempunyai grafik naik-turun yang cenderung signifikan, dimana yang berarti ketiga kelas tersebut mempunyai nilai warna yang beragam. Rata-rata nilai warna citra *LAB* yang ada di setiap kelas yaitu, kelas daun sebesar 77,58, kaleng sebesar 74,42, kertas sebesar 86,51, dan plastik sebesar 82,30. Berdasarkan nilai tersebut dapat diketahui bahwa kelas kertas memiliki nilai warna *LAB* yang tinggi dibanding kelas lainnya, hal tersebut terjadi karena pada kelas kertas memiliki warna yang lebih beragam dan lebih terang.

Tabel 1. Perbandingan Akurasi dan Waktu Komputasi Skenario Kombinasi Fitur

Fitur Terpilih	Akurasi (%)		Missclassification Error (%)		Waktu Komputasi (detik/citra)	
	Pelatihan	Pengujian	Pelatihan	Pengujian	Pelatihan	Pengujian
	RGB	82,9	51,6	17,1	82,9	0,75
HSV	62,1	61,7	37,9	62,1	0,72	0,68
LAB	56,1	40,8	43,9	56,1	0,77	0,69
Bentuk	41,8	40,0	58,2	41,8	0,83	0,65
Tekstur	38,6	37,5	61,4	38,6	0,73	0,67
RGB + Bentuk	57,9	50,0	42,1	57,9	0,79	0,64
HSV + Bentuk	70,7	60,0	29,3	70,3	0,79	0,65
LAB + Bentuk	80,0	79,2	20,0	80,0	0,80	0,67
RGB + Tekstur	71,8	51,7	28,2	71,8	0,73	0,64
HSV + Tekstur	76,4	73,3	23,6	76,4	0,79	0,69
LAB + Tekstur	73,2	58,3	26,8	73,2	0,74	0,66
HSV + LAB + Tekstur	91,4	84,0	9,00	16,0	0,77	0,69

Tabel 2. Hasil Klasifikasi Data Latih

	Daun	Kaleng	Kertas	Plastik	Precision	Recall	F1-Score
Daun	70	0	0	0	96%	100%	98%
Kaleng	1	64	5	0	94%	91%	92%
Kertas	2	2	65	1	80%	93%	86%
Plastik	0	2	11	57	98%	81%	89%

Tabel 3. Hasil Klasifikasi Data Uji

	Daun	Kaleng	Kertas	Plastik	Precision	Recall
Daun	30	0	0	0	96%	100%
Kaleng	0	25	3	1	78%	83%
Kertas	0	5	22	3	75%	73%
Plastik	1	2	4	24	86%	80%

Adapun fitur tekstur dapat dilihat pada grafik yang ditampilkan pada Gambar 9. Pada kelas daun nilai *contrast*-nya berada pada rentang 0,01 hingga 0,5, yang artinya nilai *contrast* pada kelas daun dianggap rendah, hal tersebut terjadi sebagai akibat dari intensitas seluruh citra pada kelas daun seragam dan memiliki struktur yang seragam pula sehingga nilai *contrast* pada kelas daun rendah dan grafik naik turunnya tidak berubah secara signifikan. Sedangkan kelas kertas, kaleng, dan plastik memiliki nilai grafik naik-turun yang signifikan, hal tersebut terjadi karena pada ketiga kelas tersebut memiliki nilai *contrast* yang sangat berbeda di setiap citranya. Adapun rata-rata nilai *contrast* dari setiap kelas yaitu, kelas daun sebesar 0,5, kaleng 0,08, kertas 0,11 dan plastik 0,11. Nilai *contrast* dari setiap kelas menunjukkan pola yang terbentuk pada grafik yaitu cenderung naik dari kelas daun hingga kelas plastik.

Berdasarkan grafik yang ditunjukkan pada Gambar 10, Dibandingkan dengan kelas kertas, kaleng, dan plastik, kelas daun mempunyai grafik korelasi yang kuat dengan pola grafik naik turun yang tidak terlalu signifikan. Berbeda dengan kelas daun, grafik naik dan turun pada ketiga kelas cukup signifikan, dan nilai grafiknya cenderung mendekati nilai intensitas terendah. Selain itu, rata-rata nilai *correlation* dari tiap kelas semuanya sama yaitu 0,99.

Berdasarkan grafik pada Gambar 11, terlihat pola grafik naik-turunnya sangat signifikan, hal tersebut terjadi karena nilai keberagaman yang saling berjauhan sehingga perubahan grafiknya sangat signifikan. Dimana nilai rata-rata disetiap kelasnya yaitu, kelas daun sebesar 0,37, kelas kaleng sebesar 0,32, kelas kertas sebesar 0,34 dan kelas plastik sebesar 0,26. Dari nilai rata-rata tiap kelas dapat dilihat bahwa kelas plastik mempunyai nilai rata-rata yang rendah dibanding kelas lainnya, hal tersebut terjadi karena kelas plastik memiliki data atau objek yang memiliki tingkat energi yang lebih rendah.

Berdasarkan grafik pada Gambar 12, dapat dilihat bahwa pola yang terbentuk pada kelas daun jarak atau *range* nilainya jauh lebih kecil dibanding kelas lainnya, hal tersebut terjadi karena variasi nilai piksel yang ada di kelas daun tersebut cenderung memiliki tekstur yang sangat seragam atau homogen. oleh karena itu grafik dari kelas daun menunjukkan nilai *homogeneity* yang sangat tinggi. Sedangkan pada kelas kaleng, kertas, dan plastik memiliki nilai grafik naik-turun yang memiliki *range* antara 0,9-0,99, hal tersebut terjadi karena pada ketiga kelas tersebut mempunyai variasi data yang banyak. Adapun rata-rata nilai *homogeneity* di tiap kelas yaitu, kelas daun sebesar 0,98, kelas kaleng sebesar 0,97, kelas kertas sebesar 0,96 dan kelas plastik sebesar 0,96. Dari nilai rata-rata di tiap kelas dapat

dilihat bahwa pola pada grafik *homogeneity* terus menurun disetiap kelasnya.

Setelah berhasil mengekstrak semua fitur, langkah selanjutnya adalah menjalankan skenario pelatihan dan pengujian dengan berbagai kombinasi dari kedua fitur yang tersedia. Tujuan utamanya adalah menemukan kombinasi fitur optimal yang memberikan akurasi tinggi dan meminimalkan waktu komputasi.

Berdasarkan perbandingan akurasi, *Missclassification Error* (ME), dan waktu komputasi yang telah dilakukan pada Tabel 1, dipilihlah skenario terbaik yang menggunakan kombinasi fitur warna (*HSV + LAB*) dan fitur tekstur. Kombinasi kedua fitur ini menghasilkan akurasi sebesar 91,4% pada tahap pelatihan dengan ME sebesar 8,6%, memerlukan waktu komputasi sekitar 0,77 detik per citra.

Setelah didapatkan fitur yang tepat untuk melakukan klasifikasi, dilakukan proses klasifikasi terhadap 280 citra latih dan 120 data uji. Hasil pelatihan dapat dilihat pada Tabel 2 untuk data latih dan Tabel 3 untuk data uji. Pada tahap pengujian, skenario ini menghasilkan akurasi sebesar 84% dengan ME 16% dan waktu komputasi sekitar 0,69 detik per citra. Karena mencapai akurasi tinggi dan ME yang rendah, skenario 12 dianggap memiliki parameter yang paling optimal untuk proses klasifikasi sampah.

Berdasarkan data yang ditunjukkan pada Tabel 2, dapat diperoleh informasi bahwa terdapat 4 kelas yang di dalamnya terdapat citra latih hasil klasifikasi di masing-masing *confusion matrix* kelas, yang disajikan dalam bentuk. Dari data pada tabel di atas, didapatkan hasil dari klasifikasi citra dengan jumlah prediksi yang benar di tiap kelasnya yaitu, 70 citra untuk kelas daun, 64 citra untuk kelas kaleng, 65 citra untuk kelas kertas dan 57 citra untuk kelas plastik. Dimana kelas daun merupakan kelas yang jumlah prediksinya sangat tepat atau mempunyai akurasi sebesar 100% sedangkan kelas plastik merupakan kelas yang memiliki jumlah prediksi yang sangat rendah dibanding kelas lainnya, dimana dapat dilihat pada kelas plastik cenderung di prediksi ke kelas kertas yang jumlahnya yaitu 11 citra.

Dari hasil *confusion matrix* di tingkat akurasi keseluruhan yaitu 91%, dimana dari akurasi yang di dapatkan dapat ditarik kesimpulan bahwa proses pelatihan telah berjalan dengan cukup baik. Oleh karena itu, model JST yang telah dikembangkan dapat diterapkan untuk melakukan pengujian pada citra uji.

Pada tabel hasil klasifikasi data uji, dapat diketahui bahwa kelas daun memiliki tingkat prediksi yang sangat tinggi dibanding kelas lainnya. Hal tersebut disebabkan karena beberapa faktor, salah satunya yaitu pada kelas daun memiliki data yang sebagian besar memiliki warna dan bentuk yang hampir sama. Berdasarkan Tabel 3, hasil pengujian secara keseluruhan di dapatkan hasil akurasi sebesar

84.2%, dengan nilai rata-rata *precision* sebesar 84.11%, *recall* sebesar 84.16%, dan *F1-Score* sebesar 84.08%.

Hasil pengujian yang telah dilakukan menunjukkan bahwa, metode yang diusulkan berhasil dalam mengklasifikasikan jenis sampah.

4. KESIMPULAN

Dalam penelitian ini, dibuat suatu sistem yang mampu mengklasifikasikan berbagai jenis sampah berdasarkan fitur warna *HSV* dan *LAB* serta fitur tekstur. Sistem ini mengelompokkan sampah ke dalam empat kategori: daun, kaleng, kertas, dan plastik, menggunakan algoritma *JST Feedforward Backpropagation*.

Proses pelatihan model JST dan pengujian sistem melibatkan 12 skenario untuk menemukan kombinasi fitur yang memberikan akurasi tertinggi dan waktu komputasi paling efisien. Kombinasi terbaik ditemukan menggunakan fitur warna *HSV* dan *LAB*, bersama dengan fitur tekstur seperti *contrast*, *correlation*, *energy*, dan *homogeneity*.

Hasil penelitian menunjukkan bahwa dengan melatih sistem menggunakan 280 citra latih, akurasinya mencapai puncak 91% dengan waktu komputasi rata-rata 0.77 detik per citra. Pada pengujian dengan menggunakan 90 citra uji, sistem mencapai tingkat akurasi 84% dengan waktu komputasi rata-rata 0.69 detik per citra. Kedepan sistem dapat dikembangkan untuk diimplementasikan secara realtime.

DAFTAR PUSTAKA

- ABDALLAH, M., ABU TALIB, M., FERAZ, S., NASIR, Q., ABDALLA, H. and MAHFOOD, B., 2020. Artificial Intelligence Applications in Solid Waste Management: A Systematic Research Review. *Waste Management*, 109, pp.231–246.
<https://doi.org/10.1016/j.wasman.2020.04.057>.
- AGUNG, A.S., Sr, A.F.D., HERSYAM, M.S., KASWAR, A.B. and ANDAYANI, D., 2023. Classification Of Tomato Quality Based On Color Features And Skin Characteristics Using Image Processing Based Artificial Neural Network. 4(5).
- AULIA, D.C., SITUMORANG, H.K., PRASETYA, A.F.H., FADILLA, A., NISA, S., KHOIRUNNISA, A., FARHAN, D., NINDYA, D.N., PURWANTARI, H., JASMIN, O.D. and AKBAR, J.A., 2021. Peningkatan Pengetahuan dan Kesadaran Masyarakat tentang Pengelolaan Sampah dengan Pesan Jepang. 1(1).
- BATUBARA, N.P., WIDIYANTO, D. and CHAMIDAH, N., 2020. Klasifikasi Rempah Rimpang Berdasarkan Ciri Warna RGB dan

- tekstur GLCM Menggunakan Algoritma Naive Bayes. *Informatik: Jurnal Ilmu Komputer*, 16(3), p.156. <https://doi.org/10.52958/iftk.v16i3.2196>.
- DZULHIJJAH, A.N., ANRAENI, S. and SUGIARTI, S., 2021. Klasifikasi Kematangan Citra Labu Siam Menggunakan Metode KNN (K-Nearest Neighbor) Dengan Ekstraksi Fitur HSV (Hue, Saturation, Value). *Buletin Sistem Informasi dan Teknologi Islam*, 2(2), pp.103–110. <https://doi.org/10.33096/busiti.v2i2.808>.
- FATHURRAHMAN, F., SANTONI, M.M. and MULIAWATI, A., 2020. Penerapan Artificial Neural Network Untuk Klasifikasi Citra Teks Dalam Penerjemahan Bahasa Daerah.
- ISHANAN, F. and MUSTOFA, Y.A., 2019. Deteksi Penyakit Tanaman Daun Bayam Menggunakan Metode GLCM dan Artificial Neural Network (ANN).
- MELANGI, S., 2020. Klasifikasi Usia Berdasarkan Citra Wajah Menggunakan Algoritma Artificial Neural Network dan Gabor Filter. *Jambura Journal of Electrical and Electronics Engineering*, 2(2), pp.60–67. <https://doi.org/10.37905/jjee.v2i2.6956>.
- NISA, I.Z., ENDAH, S.N., SASONGKO, P.S., KUSUMANINGRUM, R., KHADIJAH, K. and RISMIYATI, R., 2022. Klasifikasi Citra Sampah Menggunakan Support Vector Machine dengan Ekstraksi Fitur Gray Level Co-Occurrence Matrix dan Color Moments. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(5), pp.921–930. <https://doi.org/10.25126/jtiik.2022954868>.
- NUGROHO, A.S., UMAR, R. and FADLIL, A., 2021. Klasifikasi Botol Plastik Menggunakan Multiclass Support Vector Machine. *Jurnal Khatulistiwa Informatika*, [online] 9(2). <https://doi.org/10.31294/jki.v9i2.11058>.
- NUR ROHKHIM, A. and DARUJATI, C., 2020. Klasifikasi penyakit kalkulus (karang gigi) menggunakan pengolahan citra digital dengan metode jaringan saraf tiruan backpropagation. *Smart Comp :Jurnalnya Orang Pintar Komputer*, 9(2), pp.71–75. <https://doi.org/10.30591/smartcomp.v9i2.1944>.
- PAGEH, I.M. and ARYANA, I.G.M., 2019. Solusi Strategis Penangan Masalah Sampah Dengan Mengolah Sampah Dapur Menjadi Pupuk Organik Cair (POC): (Kasus Dua Desa Pinggir Kota di Kota Singaraja Bali). *Jurnal Ilmiah Ilmu Sosial*, [online] 4(2). <https://doi.org/10.23887/jiis.v4i2.16533>.
- PRASETYO, A.P.P., IRFANSYAH, M., EXAUDI, K. and SEPTIAN, T.W., 2023. Sistem Pemilah Sampah Organik Berbasis Raspberry Pi Menggunakan Klasifikasi CNN.
- RASIDI, A.I., PASARIBU, Y.A.H., ZIQRI, A. and ADHINATA, F.D., 2022. Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, [online] 8(1). <https://doi.org/10.28932/jutisi.v8i1.4314>.
- RIANA, D., RAHAYU, S., HADIANTI, S., FRIEYADIE, F., HASAN, M., KARIMAH, I.N. and PRATAMA, R., 2022. Identifikasi Citra Pap Smear RepoMedUNM dengan Menggunakan K-Means Clustering dan GLCM. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), pp.1–8. <https://doi.org/10.29207/resti.v6i1.3495>.
- SAIFULLAH, S., 2020. Analisis Perbandingan He Dan Clahe Pada Image Enhancement Dalam Proses Segmenasi Citra Untuk Deteksi Fertilitas Telur. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 9(1), p.134. <https://doi.org/10.23887/janapati.v9i1.23013>.
- SINAGA, A.S., 2019. Segmentasi Ruang Warna L^*A^*B . *Jurnal Mantik Penuasa*, 3(1).
- SURYADI, A., PUTRI, M.V. and FEBRIANTI, E.L., 2022. Pengolahan Citra Digital Dan Logika Fuzzy Dalam Identifikasi Tingkat Kematangan Buah. *Journal Of Science And Social Research*, 5(2), p.187. <https://doi.org/10.54314/jssr.v5i2.863>.
- YATIM, M.L.A.R.I., SARI, J.Y. and NINGRUM, I.P., 2019. Deteksi Area Wajah Manusia Pada Citra Berwarna Berbasis Segmentasi Warna YCbCr dan Operasi Morfologi Citra. *Ultimatics: Jurnal Teknik Informatika*, 11(1), pp.1–5. <https://doi.org/10.31937/ti.v11i1.1029>.
- ZENDHAF, A., MAGDALENA, R. and FU'ADAH, R.Y.N., 2018. Segmentasi Pembuluh Darah Pada Fundus Retina Menggunakan Deteksi Tepi Dan Operasi Morfologi.
- ZURAIDAH, Z., ROSYIDAH, L.N. and ZULFI, R.F., 2022. Edukasi Pengelolaan Dan Pemanfaatan Sampah Anorganik Di Mi Al Munir Desa Gadungan Kecamatan Puncu Kabupaten Kediri. *Budimas: Jurnal Pengabdian Masyarakat*, [online] 4(2). <https://doi.org/10.29040/budimas.v4i2.6547>.