



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 4 (2025) pp: 5486-5494

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Penerapan Multilayer Perceptron (MLP) untuk Klasifikasi Citra Kue Karawo Berdasarkan Fitur Tekstur GLCM dan Warna HSV di Viana Cookies

Mutiara Ilato¹, Lailany Yahya², Siti Nurmardia Abdussamad³

Program Studi Statistika, Fakultas MIPA, Universitas Negeri Gorontalo

Program Studi Pendidikan Matematika, Fakultas MIPA, Universitas Negeri Gorontalo

[1mutiarailato2@gmail.com](mailto:mutiarailato2@gmail.com), [2lailany.math@gmail.com](mailto:lailany.math@gmail.com), [3sitinurmardia@ung.ac.id](mailto:sitinurmardia@ung.ac.id)

Abstrak

Kue karawo merupakan salah satu produk pangan tradisional khas Provinsi Gorontalo yang memiliki nilai budaya sekaligus potensi ekonomi. Penilaian kualitas kue karawo selama ini masih dilakukan secara visual dan manual, sehingga sangat bergantung pada subjektivitas penilai dan berisiko menimbulkan ketidakkonsistenan hasil, terutama pada proses produksi dalam jumlah besar. Penelitian ini bertujuan untuk mengklasifikasikan kualitas kue karawo secara otomatis dengan memanfaatkan citra digital dan algoritma Multilayer Perceptron (MLP). Karakteristik kualitas kue direpresentasikan melalui fitur tekstur dan warna, di mana fitur tekstur diekstraksi menggunakan Gray Level Co-occurrence Matrix (GLCM) yang meliputi energi, contrast, correlation, dan homogeneity, sedangkan fitur warna diperoleh dari model Hue, Saturation, dan Value (HSV). Data citra yang digunakan berasal dari Viana Cookies dan telah melalui tahapan pra-proses serta normalisasi menggunakan metode Z-score sebelum dilakukan pelatihan dan pengujian model. Evaluasi kinerja klasifikasi dilakukan menggunakan confusion matrix dengan indikator akurasi, presisi, dan recall. Hasil pengujian menunjukkan bahwa model MLP mampu memberikan kinerja yang cukup baik dengan nilai akurasi sebesar 80,72%, presisi 72,73%, dan recall 77,42%. Hasil ini menunjukkan bahwa kombinasi fitur tekstur GLCM dan warna HSV efektif digunakan dalam mengklasifikasikan kualitas kue karawo. Secara praktis, penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan dalam pengendalian kualitas produk kue karawo secara objektif dan efisien.

Kata kunci: GLCM, HSV, Klasifikasi Citra, Kue Karawo, Multilayer Perceptron

1. Latar Belakang

Makanan tradisional merupakan manifestasi penting dari warisan budaya yang perlu dijaga keberadaannya. Upaya pelestarian tersebut memerlukan peran aktif pemerintah di tingkat daerah. Makanan tradisional mencakup berbagai jenis hidangan mulai dari makanan pokok hingga camilan yang umumnya dibuat dari bahan sederhana dengan teknik dan peralatan yang diwariskan secara turun-temurun [1]. Kue tradisional Indonesia diolah dari bahan alam yang mudah diperoleh dan memiliki proses pembuatan serta penyajian yang khas. Secara umum, kue didefinisikan sebagai produk olahan berbahan dasar tepung atau bahan bertekstur serupa yang dipadukan dengan berbagai bahan tambahan seperti perisa, pewarna, maupun cairan tertentu [2]. Setiap negara atau kelompok etnis memiliki ragam kue yang mencerminkan identitas dan sejarah budayanya; salah satu contohnya adalah kue karawo dari Provinsi Gorontalo [3].

Kue karawo merupakan salah satu produk pangan khas Gorontalo yang identik dengan perayaan lebaran dan sering dijadikan buah tangan karena ketersediaannya yang terbatas pada wilayah tersebut. Kekhasan kue ini terletak pada ornamen di permukaannya yang meniru motif karawo, yaitu seni sulam tradisional Gorontalo yang berkembang sejak abad ke-17. Motif tersebut umumnya berupa bentuk bunga dengan variasi warna menjadi dasar penamaan kue karawo. Berdasarkan hasil pra-survei melalui wawancara dengan produsen menunjukkan bahwa proses penilaian kualitas kue masih dilakukan secara manual dan sering menemui kendala, terutama ketika volume produksi tinggi dan waktu pengolahan terbatas. Kondisi tersebut berpotensi menimbulkan ketidaktepatan dalam pemeriksaan, misalnya ketidaksempurnaan tekstur atau ketidakraturan warna yang seharusnya terpantau. Evaluasi kualitas sangat dipengaruhi oleh beberapa kriteria utama, antara lain keseragaman warna, kerapian ukiran, serta tekstur renyah yang tetap harus terjaga setelah proses pemanggangan dan pengaplikasian hiasan.

Studi yang dikemukakan oleh [4] menggunakan pendekatan kualitatif melalui wawancara, observasi, serta penelaahan dokumen dan literatur. Temuan penelitian tersebut memperlihatkan bahwa pemberdayaan perempuan di Tanggilingo, Bone Bolango, tercermin melalui beberapa indikator, salah satunya kemampuan perempuan dalam memproduksi kue tradisional daerah. Produksi kue karawo bahkan mencapai 15.000 toples selama bulan Ramadan. Penelitian tersebut juga mencatat peningkatan pendapatan masyarakat sebagai dampak ekonomi yang signifikan, sekaligus menunjukkan penguatan peran perempuan dalam pelestarian budaya lokal. Selain itu, kreativitas dan inovasi dalam pengembangan produk berbasis kearifan lokal turut memberikan kontribusi terhadap pertumbuhan sektor pariwisata dan ekonomi kreatif di wilayah setempat. Penelitian yang dilakukan oleh [5] menggunakan metode deskriptif kualitatif untuk menelaah bagaimana pengelolaan IKM Sentra Karawo berkontribusi terhadap peningkatan pendapatan masyarakat. Data diperoleh melalui observasi lapangan dan wawancara dengan pihak terkait. Temuan penelitian mengidentifikasi beberapa faktor kunci, antara lain peningkatan kompetensi sumber daya manusia melalui program pelatihan, penyediaan fasilitas produksi yang semakin memadai, serta dukungan modal yang mampu menunjang operasional secara optimal. IKM Sentra Karawo juga tercatat menghasilkan pendapatan sekitar Rp 16 juta per bulan, yang menunjukkan kapasitas sektor tersebut dalam mendorong pertumbuhan ekonomi masyarakat Desa Tanggilingo. Selain itu, penelitian yang dilakukan oleh [6] menerapkan pendekatan kualitatif melalui wawancara mendalam dengan pemilik UMKM Li Maya serta observasi langsung terhadap aktivitas usaha untuk menelaah perubahan volume penjualan. Temuan studi tersebut menunjukkan bahwa UMKM Li Maya di Gorontalo menghadapi kondisi *sticky cost*, yakni situasi ketika komponen biaya tetap seperti upah tenaga kerja dan biaya utilitas tidak mengalami penurunan meskipun terjadi penurunan pada tingkat penjualan.

Sebagian besar penelitian terdahulu memanfaatkan metode kualitatif yang mengandalkan wawancara, observasi, dan analisis deskriptif, sehingga hasilnya sangat dipengaruhi oleh persepsi subjektif responden. Kondisi tersebut menunjukkan belum tersedianya evaluasi kualitas kue karawo yang bersifat objektif dan berbasis data. Untuk mengatasi keterbatasan tersebut, penelitian ini menerapkan algoritma *Multilayer Perceptron* (MLP) guna melakukan klasifikasi kualitas kue karawo melalui pengolahan ciri tekstur dan warna. Penggunaan MLP diharapkan mampu menghasilkan proses penilaian yang lebih akurat dan efisien dibandingkan prosedur pengecekan manual.

2. Metode Penelitian

Tahapan penelitian ini disusun secara sistematis untuk membangun model klasifikasi kualitas kue karawo menggunakan algoritma *Multilayer Perceptron* (MLP) dengan fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) serta fitur warna *Hue, Saturation, Value* (HSV). Alur metodologis sebagaimana ditampilkan pada Gambar 1 terdiri atas pelaksanaan pra-survei sebagai tahap awal, diikuti proses pengumpulan dan pra-pemrosesan data, ekstraksi serta normalisasi fitur, pemisahan dataset, penerapan algoritma MLP sebagai metode klasifikasi, dan diakhiri dengan evaluasi kinerja model.



Gambar 1. Tahapan Penelitian

Dataset

Pada penelitian ini, dataset yang digunakan merupakan data primer melalui observasi langsung di Viana Cookies, Bone Bolango. Data yang dikumpulkan berupa citra kue karawo berformat .jpg yang diambil menggunakan kamera telepon seluler selama satu minggu. Total 828 citra berhasil dikumpulkan, terdiri atas 508 citra dengan kualitas baik dan 320 citra dengan kualitas buruk. Proses pelabelan dilakukan secara manual dan selanjutnya divalidasi oleh ahli dari Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo.

Pre-processing Data

Pre-processing dilakukan untuk memastikan bahwa seluruh citra memiliki keseragaman ukuran, format, dan karakteristik sebelum masuk ke proses ekstraksi fitur. Langkah ini terdiri atas dua proses utama, yaitu *resizing* dan konversi citra.

Resizing citra ke resolusi 225×225 piksel guna memperoleh dimensi yang konsisten serta mempermudah perhitungan komputasi [7].

Konversi citra RGB menjadi citra keabuan (*grayscale*) menggunakan persamaan [8]:

$$\text{Grayscale} = (0.2989 \times R) + (0.5870 \times G) + (0.1440 \times B) \quad (1)$$

R adalah *Red*, G adalah *Green*, B adalah *Blue*.

Konversi ini dilakukan karena analisis tekstur GLCM hanya memerlukan informasi intensitas keabuan tanpa mempertimbangkan komponen warna [9].

Ekstraksi Fitur

Pada tahap ini dilakukan untuk memperoleh ciri atau karakteristik dari citra guna mengidentifikasi perbedaan kualitas kue karawo. Penelitian menggunakan dua jenis fitur, yaitu fitur tekstur dan fitur warna sebagai dasar dalam proses klasifikasi.

Ekstraksi Fitur Tekstur

Gray Level Co-occurrence Matrix (GLCM) merupakan pendekatan statistik untuk menggambarkan tekstur citra melalui perhitungan keterkaitan nilai intensitas antar piksel pada jarak dan arah tertentu. Metode ini menghasilkan matriks ko-occurrence yang merepresentasikan frekuensi kemunculan pasangan nilai keabuan. Dari matriks tersebut kemudian diturunkan empat indikator utama, yaitu *energy*, *contrast*, *correlation*, dan *homogeneity* [10].

Ekstraksi Fitur Warna

Selain fitur tekstur, komponen warna juga berperan signifikan dalam menentukan kualitas suatu produk. Penelitian ini menerapkan model warna *Hue*, *Saturation*, *Value* (HSV) karena dianggap lebih merepresentasikan persepsi visual manusia dibandingkan ruang warna RGB. Nilai HSV diperoleh melalui proses konversi dari ruang warna RGB menggunakan persamaan [11]:

$$H = 60^\circ \times \frac{G - B}{V_m}, \quad S = \frac{V_m}{V}, \quad V = \max(R, G, B) \quad (2)$$

R adalah *Red*, G adalah *Green*, B adalah *Blue*.

Fitur HSV memungkinkan identifikasi perbedaan citra kue karawo melalui variasi warna yang menunjukkan tingkat kematangan hasil pembakaran. Proses normalisasi kemudian diterapkan untuk menyesuaikan distribusi nilai fitur agar memiliki rata-rata 0 dan standar deviasi 1, sehingga tidak ada atribut berskala besar yang memengaruhi dominasi selama tahap pelatihan model.

Normalisasi

Perbedaan rentang nilai pada fitur hasil ekstraksi memerlukan proses normalisasi agar seluruh fitur berada pada skala yang konsisten. Penerapan normalisasi bertujuan mempercepat proses pelatihan serta meningkatkan stabilitas kinerja model MLP. Dalam penelitian ini digunakan metode *Z-Score Standardization*, yang dihitung menggunakan persamaan berikut. [12]:

$$x' = \frac{x_i - \text{mean}(x)}{\text{std}(x)} \quad (3)$$

x_i adalah nilai tertentu yang akan dinormalisasi, $mean(x)$ adalah nilai rata-rata dari sebuah atribut, $std(x)$ adalah nilai standar deviasi dari sebuah atribut.

Metode ini mengubah distribusi data menjadi memiliki rata-rata 0 dan standar deviasi 1 sehingga fitur dengan skala besar tidak mendominasi proses pelatihan [13].

Multilayer Perceptron

Multilayer Perceptron (MLP) merupakan model jaringan saraf tiruan yang terdiri atas tiga lapisan utama, yakni lapisan *input*, satu atau lebih lapisan tersembunyi, serta lapisan *output*. [14].

Neuron pada setiap lapisan menggunakan fungsi aktivasi *Rectified Linear Unit* (ReLU), yang dinyatakan melalui persamaan berikut. [15]:

$$f(x) = \max(0, x) \quad (4)$$

Proses pelatihan dilakukan menggunakan algoritma *backpropagation* yang terdiri dari tiga tahap utama, yaitu *feedforward*, perhitungan *error*, dan pembaruan bobot (*weight updating*) yang berlangsung secara berulang hingga model mencapai nilai *error* yang paling minimal. MLP digunakan karena memiliki kemampuan untuk mempelajari pola *non-linear* dan hubungan kompleks pada data citra, sehingga lebih efektif dalam membedakan kualitas kue Karawo berdasarkan fitur tekstur dan warna yang telah diekstraksi [15].

Confusion Matrix

Evaluasi kinerja model dilakukan dengan menggunakan *Confusion Matrix*, yakni matriks yang menampilkan perbandingan antara hasil prediksi model dan label aktual. Matriks ini memuat empat elemen penting: *True Positive* (TP), yang menunjukkan citra berkualitas baik yang berhasil dikenali dengan tepat; *True Negative* (TN), yaitu citra berkualitas buruk yang terklasifikasi secara benar; *False Positive* (FP), yaitu citra berkualitas buruk yang keliru diprediksi sebagai baik; serta *False Negative* (FN), yakni citra berkualitas baik yang salah diklasifikasikan sebagai buruk. Keempat nilai tersebut menjadi dasar perhitungan tiga indikator evaluasi utama [16]:

$$Akurasi = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (5)$$

$$Presisi = \frac{TP}{TP + FN} \times 100\% \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

Ketiga metrik ini menampilkan sejauh mana model mampu melakukan klasifikasi kualitas kue karawo secara akurat dan konsisten.

3. Hasil dan Diskusi

Pre-Processing Data


Pre-processing merupakan tahap awal dalam pengolahan citra yang dilakukan sebelum proses klasifikasi kualitas kue karawo. Tahap ini berfungsi menyiapkan citra agar siap diolah secara optimal pada proses lanjutan, termasuk ekstraksi fitur dan klasifikasi. Dalam penelitian ini, prosedur *pre-processing* yang diterapkan yaitu tahap *resizing* dan konversi citra *grayscale*.

Tahap *resizing* diterapkan untuk menyamakan ukuran seluruh citra kue karawo sehingga proses komputasi menjadi lebih efisien. Citra awal yang memiliki resolusi beragam diubah ke ukuran standar 255×255 piksel. Penyeragaman ini menurunkan beban komputasi namun tetap mempertahankan informasi visual yang relevan. Contoh hasil *resizing* ditampilkan pada Gambar 2.



Gambar 2. Citra kue setelah *resize*.

Setelah citra melalui tahap *resize*, dilakukan konversi ruang warna dari RGB ke grayscale. Konversi ini diterapkan pada setiap piksel menggunakan Persamaan 1, sehingga diperoleh citra keabuan yang sesuai untuk proses ekstraksi tekstur berbasis GLCM. Visualisasi hasil konversi grayscale ditunjukkan pada Gambar 3.



Gambar 3. Citra kue *grayscale*

Ekstraksi Ciri

Ekstraksi ciri yang diterapkan pada penelitian ini yaitu ekstraksi fitur tekstur dan ekstraksi fitur warna. Ekstraksi fitur tekstur dilakukan melalui metode *Gray Level Co-occurrence Matrix* (GLCM) dengan memanfaatkan empat parameter inti, yakni *energy*, *correlation*, *contrast*, dan *homogeneity*. Tahap ini bertujuan memperoleh karakteristik tekstur pada citra agar perbedaan antar objek dapat teridentifikasi dengan lebih jelas. Keempat nilai parameter tersebut berperan sebagai nilai *input* dalam proses klasifikasi karena masing-masing memberikan informasi unik terkait pola tekstur. Hasil perhitungan fitur GLCM disajikan pada Tabel 1.


Tabel 1. Hasil Ekstraksi Fitur Tekstur GLCM

File	Sudut	Energy	Cor	Con	Hom
baik (345).jpg	0	0,013	0,399	1512,92	0,057
	45	0,013	0,396	1530,65	0,053
	90	0,013	0,362	1606,21	0,053
	135	0,013	0,37	1597,34	0,054
...
buruk (320).jpg	0	0,019	0,806	1299,67	0,089
	45	0,018	0,778	1497,13	0,08
	90	0,018	0,818	1214,89	0,085
	135	0,018	0,807	1300,47	0,082

Berdasarkan Tabel 1, ditampilkan nilai dari fitur *energy*, *contrast*, *correlation*, dan *homogeneity* yang diperoleh melalui proses ekstraksi fitur tekstur menggunakan metode GLCM. Nilai pada sudut 0°, 45°, 90°, dan 135° menunjukkan orientasi arah yang digunakan dalam proses ekstraksi, dengan jarak antar piksel ditetapkan sebesar 5. Keempat fitur tersebut dihitung berdasarkan intensitas keabuan (*gray level*) pada citra untuk menggambarkan karakteristik tekstur secara lebih mendetail.

Ekstraksi ciri warna dilakukan dengan menggunakan ruang warna HSV. Proses dimulai dengan mengubah seluruh nilai piksel citra dari format RGB menjadi tiga komponen utama, yakni Hue (H), Saturation (S), dan

Value (V). Hasil transformasi warna dari ruang RGB ke HSV yang dihasilkan pada tahap ini ditampilkan pada gambar berikut.



Gambar 4. Citra HSV

Hasil perhitungan fitur HSV disajikan pada Tabel 2.

Tabel 2. Hasil Ekstraksi Fitur Warna HSV

File	Hue	Saturation	Value
baik (1).jpg	47,964	77,126	150,294
baik (10).jpg	52,925	65,228	150,294
baik (100).jpg	47,185	66,151	157,436
...
buruk (320).jpg	79,935	49,183	210,902

Berdasarkan Tabel 2, disajikan hasil ekstraksi tiga fitur warna pada ruang HSV, yaitu *Hue*, *Saturation*, dan *Value* yang diekstraksi dari citra kue karawo dan disimpan dalam format *Excel*. Ketiga parameter tersebut menunjukkan variasi nilai antar citra, sehingga perbedaan ini dapat digunakan sebagai acuan dalam proses klasifikasi kualitas kue karawo.

Normalisasi Data

Hasil ekstraksi fitur mengindikasikan bahwa setiap parameter memiliki rentang nilai yang tidak seragam. Oleh karena itu, dilakukan normalisasi menggunakan metode *Z-Score* (standarisasi) untuk menyetarakan skala seluruh fitur. Output dari proses normalisasi tersebut disajikan pada Tabel 3 dan Tabel 4.

Tabel 3. Normalisasi Hasil Ekstraksi Fitur Tekstur GLCM

File	Sudut	Energy	Cor	Con	Hom
	0	0,196	-1,548	-1,046	0,156
baik (345).jpg	45	0,091	-1,907	-0,931	0,066
	90	0,03	-2,186	-0,785	-0,076
	135	0,101	1,648	-1,126	0,068
...
buruk (320).jpg	0	1,199	1,025	-0,954	0,036
	45	1,172	0,908	-0,852	-0,112
	90	1,046	0,965	-0,987	-0,196
	135	1,174	1,164	-1,1	-0,097

Tabel 4. Normalisasi Hasil Ekstraksi Fitur Warna HSV

File	Hue	Saturation	Value
baik (1).jpg	0,021	1,651	-0,254
baik (10).jpg	0,288	0,588	0,022
baik (100).jpg	-0,021	0,671	-1,762
...
buruk (320).jpg	1,728	-0,845	2,088

Pembagian Data

Pembagian dataset dilakukan untuk memisahkan data menjadi dua kelompok, yaitu data latih dan data uji. Data latih berperan dalam membentuk model klasifikasi, sedangkan data uji digunakan untuk menilai kinerja serta kemampuan generalisasi model. Proses *splitting* diterapkan pada dataset yang telah melalui seluruh tahapan persiapan. Dari total 828 citra yang siap diproses, 90% dialokasikan sebagai data latih dan 10% sebagai data uji, sehingga diperoleh 745 data latih dan 83 data uji.

Multilayer Perceptron

Model klasifikasi yang diterapkan dalam penelitian ini menggunakan arsitektur *Multilayer Perceptron* (MLP) dengan pendekatan *sequential*, sehingga setiap lapisan disusun secara linear. Struktur jaringan terdiri atas tiga *dense layer*, masing-masing dengan 19 neuron pada lapisan *input*, 128 neuron pada lapisan tersembunyi 1, 64 neuron pada lapisan tersembunyi 2, dan 1 neuron pada lapisan *output*. Aktivasi ReLU diterapkan pada lapisan tersembunyi, sedangkan lapisan *output* menggunakan fungsi aktivasi Sigmoid.

Penelitian ini menerapkan beberapa hyperparameter utama, yaitu *learning rate*, *batch size*, dan *optimizer*. *Learning rate* memegang peran penting karena mengatur besaran perubahan bobot pada setiap iterasi pelatihan. Pemilihan nilai *learning rate* harus dilakukan secara cermat, nilai yang terlalu tinggi berpotensi membuat proses optimasi melewati titik minimum yang seharusnya, sedangkan nilai yang terlalu rendah dapat memperlambat konvergensi atau menyebabkan model berhenti pada *local minimum*.

Pemilihan *batch size* turut memengaruhi dinamika proses pelatihan. *Batch size* yang kecil mempercepat frekuensi pembaruan bobot, tetapi berpotensi menimbulkan fluktuasi yang tinggi selama pelatihan. Sebaliknya, *batch size* yang besar memberikan proses pembelajaran yang lebih stabil, meskipun membutuhkan waktu komputasi lebih lama. Sementara itu, *optimizer* berperan sebagai mekanisme yang mengatur langkah pembaruan bobot sehingga model dapat mencapai hasil pelatihan yang lebih optimal.

Pada penelitian ini, proses pelatihan dijalankan selama 100 *epoch* dengan menggunakan *learning rate* 0,001, *batch size* 32, serta *optimizer* Adam. Kombinasi hyperparameter tersebut dipilih untuk mendukung tercapainya performa model yang maksimal.

Confusion Matrix

Berdasarkan hasil klasifikasi yang telah diperoleh, perlu dilakukan analisis terhadap sejauh mana model mampu mengenali setiap kelas dengan benar. Untuk itu, digunakan *confusion matrix* yang menggambarkan perbandingan antara label sebenarnya dengan hasil prediksi model. Hasil klasifikasi tersebut disajikan dalam bentuk tabel *confusion matrix* berikut


Tabel 5. Confusion Matrix

Predicted Class	Actual Class	
	Baik	Buruk
Baik	43	9
Buruk	7	24

Tabel 5 menyajikan *confusion matrix* dari klasifikasi dua kelas, yaitu baik dan buruk. Nilai diagonal merepresentasikan jumlah prediksi yang sesuai dengan label asli (*True Positive*), sedangkan nilai di luar

diagonal menunjukkan kesalahan prediksi, baik berupa *False Positive* maupun *False Negative*. Untuk kelas Baik, sebanyak 43 data berhasil diklasifikasikan dengan benar, sedangkan 9 data salah dikategorikan sebagai buruk. Pada kelas buruk, 24 data diklasifikasikan secara tepat, sementara 7 data salah diklasifikasikan sebagai baik.

Hasil pengujian menunjukkan bahwa model mampu membedakan kualitas kue karawo dengan tingkat akurasi yang memadai. Untuk menilai kinerja model secara lebih rinci, digunakan *confusion matrix* yang menampilkan perbandingan antara prediksi dan label asli untuk setiap kelas. Visualisasi hasil pengujian ini disajikan pada Gambar 5



Gambar 5. Matrix Hasil Pengujian Model

Gambar 5 menunjukkan bahwa sebagian besar prediksi model berada pada diagonal utama *confusion matrix*, menandakan performa klasifikasi yang baik. Model berhasil mengklasifikasikan 43 dari 52 data kelas Baik dan 24 dari 31 data kelas Buruk dengan benar, menunjukkan kemampuan yang cukup akurat dalam membedakan kedua kelas tersebut.

Selanjutnya dilakukan valuasi model dengan *classification report* yang mencakup metrik *accuracy*, *precision*, dan *recall*. Ketiga metrik ini digunakan untuk menilai ketepatan klasifikasi, kemampuan model dalam mendeteksi data positif, serta keseimbangan antara presisi dan *recall*. Hasil evaluasi model tersebut ditampilkan pada Gambar 6

```
Classification Report:
              precision    recall  f1-score   support

   baik         0.86         0.83         0.84         52
   buruk         0.73         0.77         0.75         31

 accuracy              0.81         0.81         0.81         83
 macro avg              0.79         0.80         0.80         83
 weighted avg          0.81         0.81         0.81         83
```

Gambar 6. Hasil *Classification Report*

Berdasarkan *classification report* pada Gambar 6, sistem klasifikasi kualitas kue karawo mencapai akurasi keseluruhan sebesar 81% dari 83 data uji. Untuk kelas baik, model menunjukkan kinerja yang cukup tinggi dengan presisi 0,86 dan *recall* 0,83, menandakan bahwa sebagian besar kue berkualitas baik berhasil diprediksi secara tepat oleh model. Pada kelas buruk, model memperoleh presisi sebesar 0,73 dan *recall* 0,77, menunjukkan bahwa meskipun sebagian besar kue berkualitas buruk berhasil dikenali, tingkat ketepatan klasifikasi pada kelas ini sedikit lebih rendah dibandingkan dengan kelas baik. Nilai rata-rata presisi dan *recall* yang konsisten, baik pada *macro* maupun *weighted average* (0,79–0,81), mengindikasikan bahwa model mampu mempertahankan kinerja yang stabil saat mengklasifikasikan kedua kelas.

4. Kesimpulan

Berdasarkan hasil penelitian, penerapan algoritma Multilayer Perceptron (MLP) dengan kombinasi fitur tekstur GLCM dan fitur warna HSV mampu mengklasifikasikan kualitas kue karawo secara efektif. Pengujian menunjukkan bahwa model MLP mencapai akurasi tinggi dengan rata-rata 81%, serta mempertahankan nilai presisi dan *recall* yang konsisten pada berbagai rasio pembagian data. Kombinasi fitur tekstur dan warna terbukti efektif dalam merepresentasikan karakteristik visual kue karawo, khususnya untuk membedakan produk berkualitas baik dan buruk. Selain itu, penerapan tahap *pre-processing*, ekstraksi fitur, dan normalisasi berkontribusi signifikan dalam meningkatkan kinerja model dengan mengurangi noise dan memperkuat ciri-ciri utama citra. Berdasarkan hasil penelitian, pendekatan berbasis pembelajaran mesin terbukti potensial untuk mendukung proses *quality control* kue karawo secara otomatis dan objektif. Untuk pengembangan selanjutnya, disarankan agar variasi data citra ditingkatkan, serta metode optimasi seperti *Bayesian Optimization* atau *Genetic Algorithm* diterapkan pada MLP. Selain itu, membandingkan performa MLP dengan algoritma lain, seperti CNN atau SVM, dapat meningkatkan adaptabilitas dan keandalan sistem dalam penerapan nyata di industri pangan. Kesimpulan ini menyajikan rangkuman temuan penting dari penelitian dalam bentuk naratif, bukan numerikal, sehingga memberikan gambaran menyeluruh mengenai kontribusi penelitian terhadap pengembangan sistem klasifikasi kualitas kue karawo.

Referensi

- [1] R. Rosmayanti, E. Lasmanawati, and A. S. Nurani, "Pelestarian 'Kue Mayit' Sebagai Kue Tradisional Garut," *Media Pendidikan, Gizi, dan Kuliner*, vol. 8, no. 2, pp. 35–41, 2019, doi: 10.17509/boga.v8i2.21960.
- [2] Asep Supriatna, "Pelatihan Pengolahan Kue Tradisional Wajit Kawista Untuk Meningkatkan Ekonomi Keluarga Di Desa Sumurgede," *J. Bakti ...*, vol. 1, no. 3, pp. 283–297, 2023, [Online]. Available: <https://jurnal.rakeyansantang.ac.id/index.php/JBT/article/view/538%0Ahttps://jurnal.rakeyansantang.ac.id/index.php/JBT/article/download/538/233>
- [3] J. S. Iskandar and R. P. Kristianto, "Pengenalan dan Klasifikasi Ragam Kue Indonesia menggunakan Arsitektur ResNet50V2 pada Convolutional Neural Network (CNN)," *Pros. Semin. Nas. AMIKOM Surakarta*, vol. 1, no. November, pp. 81–92, 2023, [Online]. Available: <https://ojs.amikomsolo.ac.id/index.php/semnasa/article/view/53>
- [4] N. A. Sahi, S. R. Luawo, and M. A. Novriansyah, "Global Scientific Review Women's Empowerment Based on Local Wisdom (Karawo Cake Center, Tanggilingo Bone Bolango Village)," vol. 22, no. December, pp. 375–381, 2023.
- [5] S. Boki, "Increasing Income Through The Karwo Cake Center In Tanggilingo Village, Kabila Sub-District, Bone Bolango District," *J. ISO J. Ilmu Sos. Polit. dan Hum.*, vol. 4, no. 1, p. 6, 2024, doi: 10.53697/iso.v4i1.1756.
- [6] V. Monoarfa, I. Safitri, and C. Setiawati, "Perilaku Sticky Cost Terhadap Beban Usaha pada Aktivitas Penjualan Kue Karawo di UMKM Li Maya Gorontalo," *ManBiz J. Manag. Bus.*, vol. 3, no. 2, pp. 270–274, 2024, doi: 10.47467/manbiz.v3i2.6620.
- [7] I. P. Sari, F. Ramadhani, A. Satria, and D. Apdilah, "Implementasi Pengolahan Citra Digital dalam Pengenalan Wajah menggunakan Algoritma PCA dan Viola Jones," *Hello World J. Ilmu Komput.*, vol. 2, no. 3, pp. 146–157, 2023, doi: 10.56211/helloworld.v2i3.346.
- [8] I. Ilhamsyah, A. Y. Rahman, I. Istiadi, and others, "Klasifikasi Kualitas Biji Kopi Menggunakan MultilayerPerceptron Berbasis Fitur Warna LCH," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 6, pp. 1008–1017, 2021.
- [9] Y. Yunitasari, "Klasifikasi Gambar Menggunakan Metode K-Nearest Neighbor," in *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi (SENATIK)*, 2020, pp. 451–457.
- [10] H. H. Ullu, B. Baso, R. Risald, P. G. Manek, and D. Chrisinta, "Ekstraksi Fitur Berbasis Tekstur Pada Citra Tenun Timor Menggunakan Metode Gray Level Co-occurrence Matrix (GLCM)," *J. Inf. Technol.*, vol. 2, no. 2, pp. 70–74, 2022.
- [11] F. Febriana, L. S. Riva, R. Salomo, S. Piero, M. A. Ikramsyah, and M. M. Santoni, "Perbandingan Klasifikasi Naive-Bayes dan KNN untuk Mengidentifikasi Jenis Buah Apel dengan Ekstraksi Ciri LBP dan HSV," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, no. September, pp. 191–201, 2021.
- [12] I. Permana and F. N. S. Salisah, "Pengaruh Normalisasi Data Terhadap Performa Hasil Klasifikasi Algoritma Backpropagation," *Indones. J. Inform. Res. Softw. Eng.*, vol. 2, no. 1, pp. 67–72, 2022, doi: 10.57152/ijirse.v2i1.311.
- [13] Y. Miftahuddin and M. M. Faturrahman, "Penerapan Data Standardization dan Multilayer Perceptron pada Identifikasi Website Phishing," *J. MIND J. / ISSN*, vol. 7, no. 2, pp. 111–123, 2022.
- [14] I. Daniel, A. F. Limas Ptr, and A. Ichsan, "Klasifikasi Risiko Penyakit Jantung Dengan Multilayer Perceptron," *Data Sci. Indones.*, vol. 4, no. 1, pp. 78–82, 2024, doi: 10.47709/dsi.v4i1.4667.
- [15] S. H. Gulo and A. H. Lubis, "Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu, Application of Multi-Layer Perceptron to Classify Underprivileged Populations Happy," *J. Comput. Sci. Inf. Technol.*, vol. 4, no. 2, pp. 51–59, 2024.
- [16] A. M. Soemardi, R. Umilasari, and D. Lusiana, "Penerapan Multilayer Artificial Neural Network Untuk Klasifikasi Daun Berdasarkan Jenis Penyakitnya Sebagai Langkah Efektif Perawatan Tanaman Application of Multilayer Artificial Neural Network to Classify Leaves Based on Type of Disease as an Effective S," *J. Smart Teknol.*, vol. 5, no. 3, pp. 2774–1702, 2024, [Online]. Available: <http://jurnal.unmuhjember.ac.id/index.php/JST>