

# Klasifikasi Kualitas Mangga Harum Manis: Pendekatan Neural Network

M. Faisal Afiff Tarigan

Email: [afief.rider@gmail.com](mailto:afief.rider@gmail.com)

STIT Hamzah Al Fansuri Sibolga Baru (STIT HASIBA),

## ABSTRACT

**Mangga Harum Manis adalah salah satu komoditas ekspor Indonesia yang dapat dikategorikan menjadi tiga tingkat kualitas: Grade A, B, dan C. Penelitian ini mengimplementasikan algoritma multilayer perceptron (MLP) dengan fungsi aktivasi ReLU dan optimasi Adam, serta variasi jumlah neuron 10, 20, dan 30 pada masing-masing lapisan tersembunyi. Performa dari ketiga model yang dibangun dianalisis menggunakan nilai akurasi, presisi, dan recall yang diperoleh dari evaluasi menggunakan confusion matrix. Model dengan kombinasi 20-30-10 neuron dalam lapisan tersembunyi menunjukkan performa terbaik. Dengan akurasi = 82.5%, presisi = 82.2%, dan recall = 82.4% untuk klasifikasi data latih, dan akurasi = 77.4%, presisi = 78.1%, dan recall = 77.4% untuk klasifikasi data uji, kombinasi ini melampaui performa dua model lainnya. Dengan perbandingan rata-rata antara performa klasifikasi data latih dan data uji di bawah 5%, model yang dihasilkan menunjukkan ketahanan yang sangat baik terhadap perubahan data atau penambahan data selanjutnya. Kata kunci: Klasifikasi, multilayer perceptron, ReLU, Adam**

## 1. PENDAHULUAN

Pohon mangga, yang termasuk dalam keluarga Anacardiaceae, berasal dari India dan menyebar ke Indonesia [1]. Ciri-cirinya meliputi batang tegak, banyak cabang, dan tajuk yang lebat serta hijau [2]. Rasanya yang lezat dan kandungan gizinya yang tinggi menjadikan pohon mangga sebagai tanaman yang populer untuk dibudidayakan di Indonesia, baik dalam skala kecil maupun besar [3]. Berbagai varietas buah mangga yang populer di Indonesia, seperti Mangga Apel, Bacang, Budi Raja, Harum Manis, dan Manalagi, dapat diidentifikasi melalui tekstur dan bentuknya yang khas [4]. Sebagai salah satu komoditas ekspor Indonesia, mangga Harum Manis memiliki standar kualitas berdasarkan berat dan ukuran fisiknya [5]. Penelitian ini berfokus pada klasifikasi kualitas buah mangga Harum Manis berdasarkan berat, tinggi, dan lingkarannya, yang

kemudian dikategorikan menjadi tiga grade (A, B, dan C) menggunakan metode machine learning.

Pemilihan metode machine learning untuk mengklasifikasikan kualitas buah mangga Harum Manis dalam penelitian ini didasarkan pada penelitian-penelitian sebelumnya yang berhasil menciptakan model untuk mengkategorikan kualitas buah mangga menggunakan berbagai algoritma machine learning. Dengan menggunakan kategori Class I, Class II, dan Extra Class, implementasi Convolutional Neural Network (CNN) berbasis SqueezeNet untuk klasifikasi kualitas buah mangga berdasarkan citra digital berhasil menciptakan model dengan tingkat akurasi sebesar 93.33% [6]. Penelitian mengenai klasifikasi tingkat kematangan buah mangga Harum Manis dan Sala menggunakan algoritma Support Vector Machine (SVM) menunjukkan rata-rata akurasi sebesar 91.88% ketika membandingkan nilai HSV citra buah mangga [7]. Dengan memanfaatkan nilai geometri, tekstur, dan statistik yang diperoleh dari ekstraksi citra buah mangga, klasifikasi kualitas mangga ke dalam kategori Bad, Good, dan Very Good menggunakan algoritma SVM berhasil mencapai tingkat akurasi sebesar 97% [8]. Implementasi Convolutional Neural Network (CNN) berbasis AlexNet untuk klasifikasi grade buah mangga (grade pertama, grade kedua, grade ketiga, dan grade rendah) dari 234 sampel citra buah mangga menghasilkan hasil akurasi sebesar 97% [9]. Studi mengenai klasifikasi buah mangga berdasarkan warna dan ukuran fisiknya membandingkan tiga arsitektur CNN: VGG-16, ResNet152, dan Inception V3. Hasilnya menunjukkan bahwa arsitektur Inception V3 adalah model terbaik dengan akurasi tertinggi sebesar 99.2% [10]. Berdasarkan referensi dari penelitian-penelitian ini, dapat disimpulkan bahwa untuk mengklasifikasikan kualitas buah mangga, baik warna maupun ukuran fisik dapat digunakan sebagai fitur. Oleh karena itu, penulis memilih ukuran fisik sebagai fitur dalam penelitian ini.

Dalam algoritma MLP, fungsi aktivasi dan optimasi merupakan komponen penting yang menentukan output pada node lapisan input dan mengoptimalkan bobot berdasarkan input dan output yang diberikan [11]. Fungsi

aktivasi ReLU (Rectified Linear Unit) adalah pilihan populer untuk meningkatkan kecepatan konvergensi, dan optimasi adaptive moment (Adam) adalah alternatif efisien untuk meningkatkan efisiensi pelatihan [12]. Kedua fungsi ini sering digabungkan dalam arsitektur MLP, terutama untuk mengatasi masalah klasifikasi [13]. Berikut adalah beberapa referensi penelitian yang ditemukan oleh penulis, yang mengimplementasikan kombinasi fungsi aktivasi ReLU dan optimasi Adam dalam arsitektur MLP.

Dalam penelitian mengenai klasifikasi kesesuaian calon suami, kombinasi fungsi aktivasi ReLU dan optimasi Adam berhasil mencapai akurasi sebesar 71.3% [14]. Penelitian klasifikasi pasien Covid-19 juga menggunakan kombinasi fungsi aktivasi ReLU dan optimasi Adam, yang menghasilkan akurasi sebesar 98.05% [15]. Kombinasi fungsi aktivasi ReLU dan optimasi Adam berhasil diterapkan pada algoritma MLP untuk klasifikasi penyakit kanker payudara. Dalam penelitian ini, kombinasi tersebut menghasilkan nilai akurasi sebesar 97.4% [16]. Dalam pengenalan skrip Hanacaraka, kombinasi SqueezeNet dan MLP, dengan menggunakan fungsi aktivasi ReLU dan optimasi Adam, berhasil mencapai akurasi rata-rata sebesar 84.63% [17]. Dalam penelitian lain, kombinasi fungsi aktivasi ReLU dan optimasi Adam mencapai akurasi rata-rata sebesar 78.8% ketika diterapkan pada dataset Titanic Survivor [18]. Berdasarkan studi-studi ini, penulis memilih kombinasi fungsi aktivasi ReLU dan optimasi Adam untuk diimplementasikan dalam model klasifikasi kualitas mangga Harum Manis ini.

Dalam arsitektur MLP, lapisan tersembunyi memiliki peran penting dalam proses feed-forward dan backpropagation untuk mendapatkan nilai kesalahan yang berfungsi dalam pembaruan nilai bobot dengan mengaktifkan neuron-neuron di dalamnya [19]. Pemilihan jumlah neuron yang tepat dalam lapisan tersembunyi menjadi penting, karena dapat memengaruhi kinerja model yang dibangun, terutama selama proses pelatihan [20]. Beberapa penelitian yang ditemukan oleh penulis telah menyelidiki dampak pemilihan jumlah neuron dalam lapisan tersembunyi dari arsitektur MLP terhadap kinerja model yang dihasilkan.

Dalam penelitian identifikasi gambar ukiran tradisional Bali, perbandingan variasi jumlah neuron sebanyak 18, 20, dan 50 menunjukkan bahwa pemilihan 50 neuron menghasilkan nilai akurasi tertinggi sebesar 98% [21]. Studi lain yang membandingkan pemilihan 20, 30, dan 40 neuron dalam pengenalan tulisan tangan aksara Jawa menunjukkan bahwa model MLP dengan 40 neuron mencapai akurasi tertinggi, dengan nilai akurasi sebesar 77% [22]. Studi lain yang membandingkan pemilihan 20, 30, dan 40 neuron dalam pengenalan tulisan tangan aksara

Jawa menunjukkan bahwa model MLP dengan 40 neuron mencapai akurasi tertinggi, dengan nilai akurasi sebesar 77% [23]. Implementasi MLP untuk mengisi data yang hilang dari seri aliran rerata bulanan di DAS Rio do Carmo, dengan variasi jumlah neuron (1, 2, 3, dan 5), menunjukkan bahwa model dengan 2 neuron menghasilkan kinerja terbaik dengan nilai RMSE terendah sebesar 1,697 [24]. Variasi jumlah neuron dalam rentang 1 hingga 10 untuk memprediksi tingkat produksi mesin gergaji berantai menunjukkan bahwa model terbaik memiliki 3 neuron, menghasilkan nilai MSE terendah sebesar 0,0529 [25]. Berdasarkan penelitian-penelitian ini, terlihat bahwa pemilihan jumlah neuron dalam lapisan tersembunyi arsitektur MLP menghasilkan variasi kinerja model yang beragam. Oleh karena itu, penulis tertarik untuk menggabungkan berbagai variasi jumlah neuron untuk setiap model yang digunakan dalam penelitian ini.

Dalam penelitian ini, algoritma MLP diimplementasikan ke dalam model untuk mengklasifikasikan kualitas buah mangga Harum Manis. ReLU digunakan sebagai fungsi aktivasi, sedangkan Adam digunakan sebagai fungsi optimasi. Dalam arsitektur model ini, digunakan tiga variasi jumlah neuron untuk menilai dampaknya terhadap kinerja model. Evaluasi dilakukan menggunakan nilai akurasi, presisi, dan recall yang diperoleh dari tabel Confusion Matrix. Hasil dari penelitian ini adalah model MLP terbaik untuk memecahkan masalah klasifikasi kualitas buah mangga Harum Manis, beserta analisis pengaruh jumlah neuron terhadap kinerja model yang dibangun.

## 2. METODE PENELITIAN

### A. Dataset

Tahap pertama dalam penelitian ini melibatkan pengumpulan data yang diperoleh dari situs web kaggle.com. Data ini terdiri dari 105 pengukuran fisik buah mangga Harum Manis, termasuk berat, tinggi, dan keliling masing-masing buah. Tabel 1 menampilkan 10 sampel data yang digunakan dalam penelitian, beserta informasi fitur dan kelas target yang digunakan.

TABEL 1  
DATASET SAMPLES

Weight	Height	Circumference	Grade
486.5	14	27	A
388.4	12	26	A
387.9	12.4	26.2	A
465.5	14	25.5	B
338.2	12.6	22.8	B
342.4	11.7	24.2	B
332.6	12.5	23.5	B
240	10.2	20.8	C
268.4	10.7	20.9	C
275.3	10.8	21.2	C

Dalam proses klasifikasi, data penelitian sebanyak 105 ini dibagi menjadi data latih dan data uji, dengan rasio 70:30.

Dengan menggunakan metode stratified sampling, diperoleh 74 data latih yang terdiri dari 26 data kategori grade A, 23 data kategori grade B, dan 25 data kategori grade C. Untuk data uji, diperoleh 31 data, yang terdiri dari 8 data kategori grade A, 10 data kategori grade B, dan 13 data kategori grade C.

### B. Konfigurasi Model

Dalam penelitian ini, dirancang tiga model yang mengimplementasikan algoritma MLP untuk melakukan klasifikasi kualitas mangga Harum Manis. Setiap model menggunakan arsitektur 3-H-1, dimana 3 merepresentasikan jumlah fitur input, H adalah jumlah variasi neuron pada lapisan tersembunyi, dan 1 adalah keluaran klasifikasi.

Jumlah lapisan tersembunyi yang digunakan adalah tiga, dengan variasi H1 untuk jumlah neuron pada lapisan tersembunyi pertama, H2 untuk jumlah neuron pada lapisan tersembunyi kedua, dan H3 untuk jumlah neuron pada lapisan tersembunyi ketiga. Masing-masing dari nilai H1, H2, dan H3 berisi variasi nilai 10, 20, dan 30, yang digunakan dalam bentuk kombinasi berbeda dalam membangun model-model penelitian ini. Tabel 2 berikut ini memberikan informasi detail tentang konfigurasi masing-masing model yang digunakan dalam penelitian ini.

TABEL 2  
 MODEL CONFIGURATION

Model	H1	H2	H3
MLP 1	10	20	30
MLP 2	30	10	20
MLP 3	20	30	10

Model-model pada Tabel 2 dirancang menggunakan fungsi aktivasi ReLU dan fungsi optimasi Adam. ReLU merupakan salah satu fungsi aktivasi yang populer digunakan pada arsitektur MLP, karena berfungsi untuk mengoptimalkan output dari neuron-neuron berikutnya dengan menghasilkan nilai 0 atau nilai output dari node tersebut itu sendiri [26]. Optimasi Adam dipilih karena kemampuannya untuk mengoptimalkan algoritma neural network, sehingga mampu mengatasi sparse gradients dan noise pada data [27].

### D. Model Evaluation

Penelitian ini menggunakan tabel confusion matrix untuk mengevaluasi kinerja model, yang mencakup nilai-nilai true positive (TP), false positive (FP), true negative (TN), dan false negative (FN) dari setiap model. TP mewakili prediksi positif yang benar oleh model, FP menunjukkan prediksi positif yang salah ketika kelas

sebenarnya negatif, TN mengindikasikan prediksi negatif yang benar, dan FN mewakili prediksi negatif yang salah ketika kelas sebenarnya positif [28].

Dengan menggunakan nilai TP, FP, TN, dan FN dari tabel matriks kebingungan-an, penulis menghitung akurasi, presisi, dan recall menggunakan rumus-rumus berikut (1) hingga (3) [29]:

$$Accuracy = \frac{TP+TN}{TP+FN+FP+TN} * 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} * 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} * 100\% \quad (3)$$

## 3. HASIL DAN PEMBAHASAN

Dari ketiga model yang dibangun, klasifikasi dilakukan pada dataset buah Harum Manis, yang kemudian dievaluasi berdasarkan confusion matrix yang dihasilkan. Gambar 1 menggambarkan confusion matrix dari klasifikasi data latih, sementara Gambar 2 menggambarkan confusion matrix dari klasifikasi data uji.

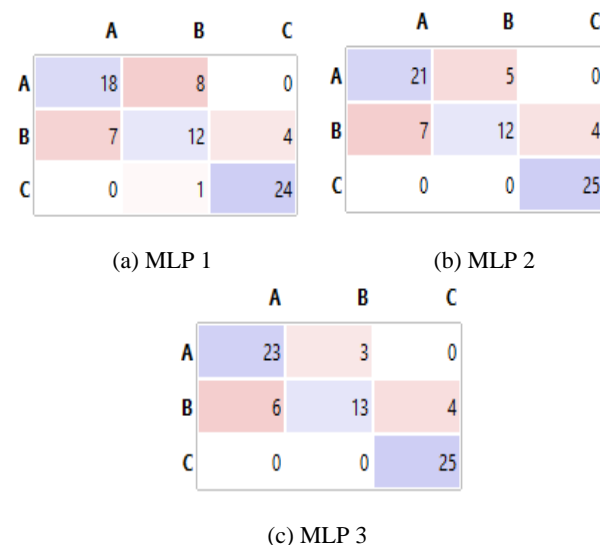


Fig. 1. Confusion Matrix of Training Data Classification

Dari Gambar 1, dapat dilihat bahwa MLP 3 lebih baik dalam mengklasifikasikan mangga dengan kualitas Grade A dibandingkan dengan MLP 1 dan MLP 2, dengan 23 prediksi yang benar. Demikian pula untuk kualitas Grade B, model ini unggul dibandingkan dua model lainnya, dengan 13 prediksi yang benar. Untuk kualitas Grade C, baik MLP 2 dan MLP 3 menghasilkan klasifikasi yang sama baik, dengan 25 prediksi yang benar.

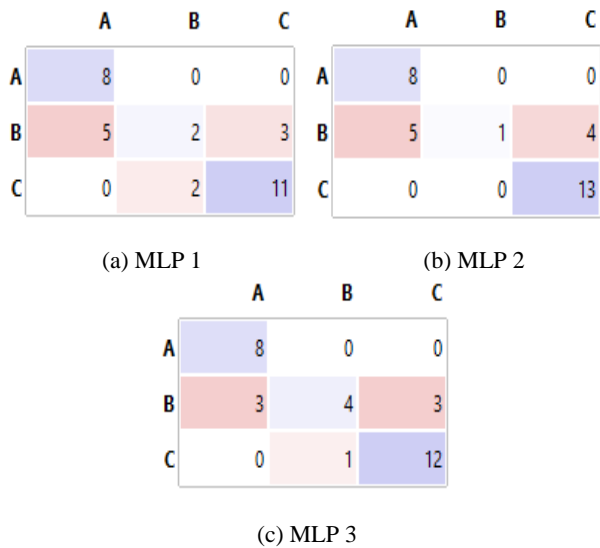


Fig. 2. Confusion Matrix of Testing Data Classification

Dari Gambar 2, terlihat bahwa semua model menghasilkan klasifikasi yang sama baik, dengan 13 prediksi yang benar. Untuk kualitas Grade B, MLP 3 lebih baik daripada model lainnya, dengan 4 prediksi yang benar. Terakhir, untuk kualitas Grade C, MLP 2 menghasilkan performa klasifikasi yang lebih baik, dengan 13 prediksi yang benar.

Berdasarkan nilai yang dihasilkan oleh confusion matrix dalam Gambar 1 dan Gambar 2, diperoleh nilai akurasi, presisi, dan recall untuk menganalisis model terbaik dalam mengklasifikasikan kualitas mangga Harum Manis. Tabel 3 menunjukkan performa masing-masing model pada klasifikasi data latih, sedangkan Tabel 4 menunjukkan performa model untuk data uji.

TABEL 3  
 TRAINING DATA CLASSIFICATION PERFORMANCE

Model	Accuracy	Precision	Recall
MLP 1	73	72	73
MLP 2	78,4	77,4	78,4
MLP 3	82,4	82,2	82,4

Hasil yang disajikan dalam Tabel 3 menunjukkan bahwa MLP 3 adalah model dengan performa terbaik dalam mengklasifikasikan data latih. Model ini mencapai akurasi sebesar 82,4%, presisi sebesar 82,2%, dan recall sebesar 82,4%. Hasil ini konsisten dengan temuan yang disajikan dalam confusion matrix sebelumnya, di mana untuk klasifikasi mangga Harum Manis dengan kualitas Grade A, B, dan C, MLP 3 adalah model yang mencapai nilai prediksi yang benar tertinggi.

TABEL 4

TESTING DATA CLASSIFICATION PERFORMANCE

Model	Accuracy	Precision	Recall
MLP 1	67,7	65	67,7
MLP 2	71	80,2	71
MLP 3	77,4	78,1	77,4

Hasil yang terdapat dalam Tabel 4 sekali lagi menunjukkan bahwa MLP 3 adalah model dengan kinerja klasifikasi terbaik, meskipun menghasilkan nilai presisi dan recall yang lebih rendah dibandingkan dengan MLP 2. Hal ini konsisten dengan nilai confusion matrix sebelumnya, di mana MLP 3 unggul dalam memprediksi kualitas Grade A dan B dengan benar tetapi kalah dari MLP 2 dalam prediksi kualitas Grade C.

Untuk menganalisis stabilitas model terhadap data baru, dilakukan perbandingan antara nilai akurasi, presisi, dan recall yang diperoleh dari klasifikasi data uji dan data latih. Tabel 5 menampilkan hasil perbandingan nilai-nilai ini, yang disimbolkan dengan tanda  $\Delta$ , di mana model dengan nilai  $\Delta$  terendah adalah model yang paling stabil.

TABEL 5  
 TRAINING-TESTING PERFORMANCE COMPARISON

Model	$\Delta$ Accuracy	$\Delta$ Precision	$\Delta$ Recall
MLP 1	5,3	7	5,3
MLP 2	7,4	2,8	7,4
MLP 3	5	4,1	5

Berdasarkan perbandingan nilai-nilai yang ditampilkan dalam Tabel 5, jelas bahwa MLP 3 menghasilkan nilai  $\Delta$  rata-rata yang terendah. Dengan nilai  $\Delta$  sebesar 5 untuk akurasi, 4.1 untuk presisi, dan 5 untuk recall, model ini memiliki kemungkinan yang lebih rendah untuk mengalami overfitting atau underfitting dibandingkan dengan dua model lainnya. Secara keseluruhan, dapat disimpulkan bahwa MLP 3 merupakan model yang paling optimal untuk mengklasifikasikan kualitas buah mangga Harum Manis berdasarkan dataset yang digunakan dalam penelitian ini.

#### 4. KESIMPULAN

Kombinasi fungsi aktivasi ReLU dan fungsi optimasi Adam pada algoritma MLP untuk mengklasifikasikan kualitas mangga Harum Manis dalam penelitian ini terbukti efektif, seperti yang dibuktikan oleh model terbaik yang mencapai nilai di atas 80% dalam klasifikasi data latih dan mendekati 80% dalam klasifikasi data uji. Konsisten dengan referensi penelitian sebelumnya, terlihat bahwa pemilihan jumlah neuron untuk masing-masing lapisan tersembunyi memengaruhi kinerja model klasifikasi. Dari ketiga model yang dibangun, berbagai tingkat kinerja diperoleh juga. Kombinasi 20 neuron pada lapisan tersembunyi pertama, 30 neuron pada lapisan tersembunyi kedua, dan 10 neuron pada lapisan tersembunyi ketiga menghasilkan kinerja

terbaik, dengan akurasi = 77,4%, presisi = 78,1%, dan recall = 77,4%. Selain mencapai nilai kinerja terbaik, model dengan kombinasi neuron 20-30-10 disimpulkan sebagai model yang paling stabil terhadap perubahan data atau penambahan data baru, dengan nilai perbandingan kinerja antara data uji dan data latih yang tidak melebihi 5%. Secara keseluruhan, penelitian ini berhasil menunjukkan bagaimana kombinasi fungsi aktivasi ReLU dan optimasi Adam dalam arsitektur algoritma MLP dengan tiga lapisan tersembunyi cocok digunakan sebagai solusi alternatif untuk mengklasifikasikan kualitas mangga Harum Manis berdasarkan berat, panjang, dan lingkaran buahnya.

### REFERENCES

- [1] S. Utami, K. Baskoro, L. K. Perwati, and M. Murningsih, "Keragaman Varietas Mangga (*Mangifera indica* L.) Di Kotamadya Semarang Jawa Tengah," *Bioma Berk. Ilm. Biol.*, vol. 21, no. 2, pp. 121–125, 2019, doi: 10.14710/bioma.21.2.121-125.
- [2] M. B. Sembiring, D. Rahmi, M. Maulina, V. Tari, R. Rahmayanti, and A. B. Suwardi, "Identifikasi Karakter Morfologi dan Sensoris Kultivar Mangga (*Mangifera Indica* L.) di Kecamatan Langsa Lama, Aceh, Indonesia," *J. Biol. Trop.*, vol. 20, no. 2, pp. 179–184, 2020, doi: 10.29303/jbt.v20i2.1876.
- [3] M. Maryati, A. Primaryani, and S. Irawati, "PENGEMBANGAN LEMBAR KERJA SISWA BERDASARKAN HASIL OBSERVASI KEANEKARAGAMAN MORFOLOGI TANAMAN MANGGA (*Mangifera Indica*)," *Diklabio J. Pendidik. dan Pembelajaran Biol.*, vol. 2, no. 1, pp. 68–75, 2018, doi: 10.33369/diklabio.2.1.68-75.
- [4] S. Hartiningtyas, I. Ruslianto, and R. Hidayati, "Klasifikasi Jenis Mangga Berdasarkan Fitur Bentuk Dan Warna Daun Dengan Menggunakan Metode K-Nearest Neighbor Berbasis Android," *J. Coding, Sist. Komput. Untan*, vol. 6, no. 1, pp. 12–23, 2018.
- [5] G. Widhiyoga, H. Wijayati, and R. Alma'unah, "Export Performance Of Indonesia's Leading Tropical Fruit Commodities To Main Destination Countries," *IQTISHADUNA J. Ilm. Ekon. Kita*, vol. 12, no. 1, pp. 128–148, 2023, doi: 10.46367/iqtishaduna.v12i1.1126.
- [6] V. Bhole and A. Kumar, "Mango Quality Grading using Deep Learning Technique: Perspectives from Agriculture and Food Industry," *SIGITE 2020 - Proc. 21st Annu. Conf. Inf. Technol. Educ.*, no. October, pp. 180–186, 2020, doi: 10.1145/3368308.3415370.
- [7] M. F. Mavi, Z. Husin, R. Badlishah Ahmad, Y. M. Yacob, R. S. M. Farook, and W. K. Tan, "Mango ripeness classification system using hybrid technique," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 14, no. 2, pp. 859–868, 2019, doi: 10.11591/ijeecs.v14.i2.pp859-868.
- [8] L. Agilandeewari, M. Prabukumar, and G. Shubham, "Automatic Grading System Mangoes Using Multiclass SVM Classifier," *Int. J. Pure Appl. Math.*, vol. 116, no. 23, pp. 515–523, 2017.
- [9] B. Zheng and T. Huang, "Mango Grading System Based on Optimized Convolutional Neural Network," *Math. Probl. Eng.*, vol. 2021, 2021, doi: 10.1155/2021/2652487.
- [10] H. M. Rizwan Iqbal and A. Hakim, "Classification and Grading of Harvested Mangoes Using Convolutional Neural Network," *Int. J. Fruit Sci.*, vol. 22, no. 1, pp. 95–109, 2022, doi: 10.1080/15538362.2021.2023069.
- [11] J. Kusuma, B. H. Hayadi, Wanayumini, and R. Rosnelly, "Comparison of Multi-Layer Perceptron (MLP) and Support Vector Machine (SVM) Methods for Breast Cancer Classification," *MIND (Multimedia Artif. Intell. Netw. Database) J.*, vol. 7, no. 1, pp. 51–60, 2022, [Online]. Available: <https://ejournal.itenas.ac.id/index.php/mindjournal/article/view/6909>
- [12] I. Firmansyah and R. Rosnelly, "Inception-V3 Versus VGG-16 : in Rice Classification Using Multilayer Perceptron," in *2nd International Conference on Information Science and Technology Innovatin (ICoSTEC)*, 2023, pp. 1–5.
- [13] K. F. Margolang, S. Riyadi, R. Rosnelly, and Wanayumini, "Pengenalan Masker Wajah Menggunakan VGG-16 dan Multilayer Perceptron," *J. Telemat.*, vol. 17, no. 2, pp. 80–87, 2023.
- [14] M. Handayani, M. Riandini, and Z. Zakarias, "Comparison of Neural Network Optimization Functions in Candidate Husband Eligibility Classification," *J. Inform.*, vol. 9, no. 1, pp. 78–84, Apr. 2022, doi: 10.31294/inf.v9i1.12318.
- [15] D. Pardede, I. Firmansyah, M. Handayani, M. Riandini, and R. Rosnelly, "Comparison Of Multilayer Perceptron's Activation And Optimization Functions In Classification Of Covid-19 Patients," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 8, no. 3, pp. 271–278, Aug. 2022, doi: 10.33330/jurteks.v8i3.1482.
- [16] M. S. Wibawa and I. M. D. Maysanjaya, "MULTI LAYER PERCEPTRON DAN PRINCIPAL COMPONENT ANALYSIS UNTUK DIAGNOSA KANKER PAYUDARA," *J. Nas. Pendidik. Tek. Inform.*, vol. 7, no. 1, p. 90, May 2018, doi: 10.23887/janapati.v7i1.12909.
- [17] Y. Franciska, T. S. Gunawan, and B. H. Hayadi, "Combination Of SqueezeNet And Multilayer Backpropagation Algorithm In Hanacaraka Script Recognition," *2nd Int. Conf. Information Sci. Technol. Innov.*, vol. 2, no. 2(1), pp. 163–170, 2023, [Online]. Available: <https://prosiding-icostec.respati.ac.id/index.php/icostec/article/view/51/51>
- [18] I. Firmansyah and B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron," *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 2, p. 200, 2022, doi: 10.26798/jiko.v6i2.600.
- [19] D. Pardede, B. H. Hayadi, and Iskandar, "Multi-Layer Perceptron Literature Review How Well This Algorithm Performs," *J. ICT Apl. Syst.*, vol. 1, no. 1, pp. 23–35, Jun. 2022, doi: 10.56313/jictas.v1i1.127.
- [20] K. L. Kohsasih, M. Dipo, A. Rizky, T. Fahriyani, V. Wijaya, and R. Rosnelly, "Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah," *J. TIMES*, vol. 10, no. 2, pp. 22–28, 2022, [Online]. Available: <http://ejournal.stmik-time.ac.id>
- [21] I. G. R. M. Putra, M. W. A. Kesiman, G. A. Pradnyana, and I. M. D. Maysanjaya, "Identifikasi Citra Ukiran Ornamen Tradisional Bali Dengan Metode Multilayer Perceptron," *SINTECH (Science Inf. Technol. J.)*, vol. 4, no. 1, pp. 29–39, 2021, doi: 10.31598/sintechjournal.v4i1.552.
- [22] A. N. Handayani, H. W. Herwanto, K. L. Chandrika, and K. Arai, "Recognition of Handwritten Javanese Script using Backpropagation with Zoning Feature

- Extraction,” *Knowl. Eng. Data Sci.*, vol. 4, no. 2, p. 117, 2021, doi: 10.17977/um018v4i22021p117-127.
- [23] I. Gunawan, “Optimasi Model Artificial Neural Network untuk Klasifikasi Paket Jaringan,” *Simetris*, vol. 14, no. 2, pp. 1–5, 2020, doi: 10.51901/simetris.v14i2.135.
- [24] G. R. de Souza, I. P. Bello, F. V. Corrêa, and L. F. C. de Oliveira, “Artificial Neural Networks for Filling Missing Streamflow Data in Rio do Carmo Basin, Minas Gerais, Brazil,” *Brazilian Arch. Biol. Technol.*, vol. 63, pp. 1–8, 2020, doi: 10.1590/1678-4324-2020180522.
- [25] J. Mohammadi, M. Ataei, R. Khalo Kakaei, R. Mikaeil, and S. Shaffiee Haghshenas, “Prediction of the Production Rate of Chain Saw Machine using the Multilayer Perceptron (MLP) Neural Network,” *Civ. Eng. J.*, vol. 4, no. 7, p. 1575, 2018, doi: 10.28991/cej-0309196.
- [26] D. Pardede and B. H. Hayadi, “Klasifikasi Sentimen Terhadap Gelaran MotoGP Mandalika 2022 Menggunakan Machine Learning,” *J. Transform.*, vol. 20, no. 2, pp. 42–50, 2023.
- [27] S. Mandasari, D. Irfan, W. Wanayumini, and R. Rosnelly, “COMPARISON OF SGD, ADADELTA, ADAM OPTIMIZATION IN GENDER CLASSIFICATION USING CNN,” *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 9, no. 3, pp. 345–354, Jun. 2023, doi: 10.33330/jurteksi.v9i3.2067.
- [28] D. Pardede, Wanayumini, and R. Rosnelly, “A Combination Of Support Vector Machine And Inception-V3 In Face-Based Gender Classification,” *Int. Conf. Inf. Sci. Technol. Innov.*, vol. 2, no. 1, pp. 34–39, Mar. 2023, doi: 10.35842/icostec.v2i1.30.
- [29] S. Riyadi, Hartono, and Wanayumini, “Predicting Children’s Talent Based On Hobby Using C4.5 Algorithm And Random Forest,” in *International Conference on Information Science and Technology Innovation (ICoSTEC)*, Mar. 2023, pp. 182–186. doi: 10.35842/icostec.v2i1.54.