

Analisis Kinerja Arsitektur *ResNet50* untuk Klasifikasi Varietas Mangga Berbasis Citra Digital

^{*1}Mohamad Fajar A'la Udin, ²Daniel Swanjaya, ³Resty Wulanningrum

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ^{*1}mohamadfajaraludin@gmail.com ²daniel@unpkdr.ac.id ³restyw@unpkdr.ac.id

Penulis Korespondens : Mohamad Fajar A'la Udin

Abstrak—Penelitian ini membahas penerapan arsitektur *ResNet50* untuk klasifikasi varietas mangga berbasis citra digital. Identifikasi varietas mangga secara manual masih memiliki keterbatasan karena kemiripan visual antar kelas. Penelitian ini menggunakan pendekatan *transfer learning* dengan model *ResNet50* berbobot awal *ImageNet*. Dataset terdiri dari tiga kelas, yaitu GADUNG, MANALAGI, dan PODANG, yang dibagi menjadi data *training*, *validation*, dan *testing*. Tahap *preprocessing* dilakukan melalui *resize* citra menjadi 224×224 piksel, normalisasi, dan augmentasi data. Untuk mengurangi *overfitting*, diterapkan *dropout*, *batch normalization*, regularisasi L2, dan *early stopping*. Hasil pengujian menunjukkan bahwa model memperoleh akurasi *testing* sebesar 93,64%. Hasil ini menunjukkan bahwa *ResNet50* efektif digunakan untuk klasifikasi varietas mangga berbasis citra digital dengan performa yang stabil.

Kata Kunci—citra digital, klasifikasi, mangga, *ResNet50*, *transfer learning*

Abstract—This study investigates the implementation of the *ResNet50* architecture for mango variety classification using digital images. Manual identification of mango varieties remains challenging due to visual similarities among classes. The study employed a *transfer learning* approach using a *ResNet50* model pretrained on the *ImageNet* dataset. The dataset consisted of three mango varieties, namely GADUNG, MANALAGI, and PODANG, which were divided into training, validation, and testing sets. Preprocessing included image resizing to 224×224 pixels, normalization, and data augmentation. To reduce overfitting, dropout, batch normalization, L2 regularization, and early stopping were applied. Experimental results showed that the model achieved a testing accuracy of 93.64%. These findings indicate that *ResNet50* is effective for mango variety classification using digital images with stable performance.

Keywords—classification, digital image, mango, *ResNet50*, *transfer learning*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Mangga adalah salah satu komoditas hortikultura unggulan di daerah tropis yang bernilai ekonomis tinggi dan telah lama menjadi tanaman budidaya utama di Indonesia. Besarnya volume produksi dan luasnya jaringan distribusi buah mangga menjadikan kemampuan mengenali varietas secara akurat sebagai kebutuhan mendasar dalam menunjang proses pemilahan, pengiriman, serta penjagaan mutu hasil panen. Sayangnya, pengenalan varietas yang masih mengandalkan pengamatan manual menghadapi sejumlah kendala, mulai dari keterbatasan keahlian individu, ketidakkonsistenan dalam penilaian visual, hingga tingginya risiko salah pengelompokan akibat kemiripan ciri fisik di antara berbagai varietas mangga. Kondisi ini

mendorong kebutuhan akan sistem klasifikasi otomatis berbasis citra digital yang mampu mengenali varietas mangga secara lebih akurat dan konsisten [1].

Perkembangan teknologi *computer vision* dan *deep learning* memberikan kontribusi besar dalam menyelesaikan berbagai permasalahan klasifikasi citra digital. Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network (CNN)*, yaitu metode *deep learning* yang mampu melakukan ekstraksi fitur visual secara otomatis dari citra digital [2]. CNN telah menunjukkan performa yang baik pada berbagai penelitian klasifikasi objek pertanian, seperti identifikasi penyakit tanaman, klasifikasi buah, dan pengenalan varietas tanaman [3]. Dibandingkan metode *machine learning* konvensional yang memerlukan ekstraksi fitur manual, CNN mampu menghasilkan representasi fitur yang lebih kompleks dan adaptif sehingga meningkatkan akurasi klasifikasi.

Salah satu arsitektur CNN modern yang banyak digunakan pada bidang klasifikasi citra adalah *ResNet50*. Arsitektur ini diperkenalkan dengan konsep *residual learning* yang memungkinkan jaringan saraf memiliki lapisan yang lebih dalam tanpa mengalami permasalahan *vanishing gradient* [4]. Melalui *residual connection*, *ResNet50* mampu mempertahankan aliran informasi pada proses pelatihan sehingga menghasilkan kemampuan ekstraksi fitur yang lebih baik dibandingkan CNN konvensional. Selain itu, *ResNet50* juga banyak digunakan dalam pendekatan *transfer learning* karena telah dilatih menggunakan dataset *ImageNet* dan terbukti efektif pada berbagai kasus klasifikasi citra [5], [6].

Beberapa penelitian sebelumnya menunjukkan bahwa arsitektur CNN berbasis *deep learning* mampu memberikan performa tinggi pada klasifikasi objek pertanian. Penelitian yang dilakukan oleh Ahmad et al. menunjukkan bahwa *deep feature extraction* berbasis CNN mampu menghasilkan klasifikasi varietas mangga dengan tingkat akurasi yang tinggi [1]. Penelitian lain oleh Ratha et al. juga menunjukkan bahwa pendekatan serupa menggunakan arsitektur *MobileNet-v2* efektif diterapkan untuk klasifikasi varietas mangga India secara otomatis [7]. Penelitian lain oleh Yehulu et al. menunjukkan bahwa model CNN modern efektif digunakan dalam proses klasifikasi penyakit buah mangga berbasis citra digital [8]. Selain itu, penelitian oleh Auni dan Sugiharti menunjukkan bahwa *transfer learning* menggunakan arsitektur CNN dapat meningkatkan performa klasifikasi citra tanaman mangga secara signifikan [9]. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada peningkatan akurasi model tanpa melakukan analisis lebih lanjut terhadap pengaruh kemiripan visual antar kelas terhadap performa klasifikasi.


Kemiripan visual antar varietas mangga, seperti warna kulit, tekstur permukaan, dan bentuk buah, menjadi tantangan utama dalam proses klasifikasi citra digital. Kondisi pencahayaan, sudut pengambilan gambar, dan kompleksitas latar belakang juga dapat memengaruhi kestabilan proses pelatihan model *deep learning* [10]. Oleh karena itu, diperlukan model CNN yang mampu melakukan ekstraksi fitur secara lebih mendalam untuk meningkatkan kemampuan klasifikasi terhadap objek dengan karakteristik visual yang serupa.

Berdasarkan permasalahan tersebut, penelitian ini mengimplementasikan arsitektur *ResNet50* berbasis *transfer learning* untuk klasifikasi varietas mangga menggunakan citra digital. Penelitian difokuskan pada analisis performa model *ResNet50* dalam mengenali tiga varietas mangga, yaitu

GADUNG, MANALAGI, dan PODANG. Selain itu, penelitian ini juga menerapkan teknik augmentasi data, *dropout*, *batch normalization*, dan *early stopping* untuk mengurangi *overfitting* selama proses pelatihan model. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* untuk mengetahui kemampuan model dalam mengklasifikasikan varietas mangga secara optimal.

Berbeda dengan penelitian sebelumnya yang sebagian besar berfokus pada peningkatan akurasi klasifikasi menggunakan berbagai arsitektur CNN, penelitian ini menitikberatkan pada analisis kemampuan *ResNet50* dalam membedakan varietas mangga yang memiliki tingkat kemiripan visual tinggi, khususnya antara varietas GADUNG dan MANALAGI. Selain itu, penelitian ini juga menerapkan kombinasi strategi regularisasi berupa data *augmentation*, *batch normalization*, *dropout*, dan *early stopping* untuk mengurangi *overfitting* selama proses pelatihan model. Dengan pendekatan tersebut, penelitian ini tidak hanya mengevaluasi performa klasifikasi, tetapi juga menganalisis kemampuan generalisasi model terhadap varietas mangga yang memiliki karakteristik visual serupa.

II. METODE



Gambar 1. Tahapan penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang saling berurutan sebagaimana ditunjukkan pada Gambar 1. Tahap pertama adalah pengumpulan dataset citra mangga yang terdiri dari varietas GADUNG, MANALAGI, dan PODANG. Selanjutnya dilakukan tahap *preprocessing* untuk menyeragamkan ukuran citra menjadi 224×224 piksel serta normalisasi data agar sesuai dengan kebutuhan input model *ResNet50*. Setelah itu, dilakukan augmentasi data untuk meningkatkan variasi data pelatihan dan mengurangi risiko *overfitting*. Tahap berikutnya adalah pembentukan model menggunakan arsitektur *ResNet50* berbasis *transfer learning* yang dilengkapi dengan *BatchNormalization*, *Dropout*, dan *L2 regularization*. Model kemudian dilatih menggunakan data training dan divalidasi menggunakan data *validation* dengan menerapkan *callback* berupa *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint*. Setelah proses pelatihan selesai, model dievaluasi menggunakan data *testing* melalui metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.

A. Dataset Penelitian

Dataset yang digunakan terdiri dari tiga varietas mangga yaitu GADUNG, MANALAGI, dan PODANG. Distribusi data training, validation, dan testing ditunjukkan Tabel 1. Setiap kelas memiliki jumlah data seimbang untuk menjaga objektivitas proses pelatihan dan evaluasi model.

Tabel 1. Distribusi Dataset Mangga

Kelas	Training	Validation	Testing	Total
GADUNG	520	110	110	740
MANALAGI	520	110	110	740
PODANG	520	110	110	740
Total	1.560	330	330	2.220



GADUNG MANALAGI PODANG

Gambar 2. Tipe Dataset Mangga

Gambar 2 menunjukkan contoh citra dari masing-masing varietas mangga yang digunakan dalam penelitian.

B. *Preprocessing Data*

Tahap *preprocessing* dilakukan dengan mengubah seluruh citra menjadi ukuran 224×224 piksel dan menerapkan normalisasi menggunakan fungsi *preprocess_input* dari ResNet50. Proses ini bertujuan untuk menyeragamkan dimensi citra serta menyesuaikan distribusi nilai piksel dengan standar model *pre-trained ImageNet*.



Gambar 3. Tahap *preprocessing* citra. (a) citra asli, (b) citra hasil *resize* 224×224 piksel

Gambar 3 menunjukkan perbandingan antara citra asli dan citra hasil *preprocessing*. Pada tahap ini, citra asli yang memiliki ukuran beragam diseragamkan menjadi 224×224 piksel agar sesuai dengan ukuran input arsitektur ResNet50. Penyeragaman tersebut dilakukan untuk memastikan seluruh data memiliki dimensi yang konsisten sebelum masuk ke proses pelatihan model.

C. *Augmentasi Data*


Penelitian ini menerapkan teknik augmentasi data untuk meningkatkan variasi data pelatihan dan mengurangi risiko overfitting. Teknik augmentasi yang digunakan meliputi horizontal flip, random rotation, random zoom, random contrast, dan Gaussian noise. Proses augmentasi hanya diterapkan pada data training sehingga proses evaluasi tetap menggunakan citra asli.

D. *Arsitektur ResNet50*

Penelitian ini menggunakan arsitektur ResNet50 berbasis transfer learning dengan bobot *pre-trained ImageNet*. ResNet50 merupakan arsitektur CNN modern yang menggunakan residual learning untuk mengatasi permasalahan vanishing gradient pada jaringan yang dalam. Konsep residual learning memungkinkan model mempertahankan aliran informasi selama proses pelatihan melalui residual connection.

Residual learning pada *ResNet50* dinyatakan menggunakan Persamaan (1).

$$H(x) = F(x) + x \quad (1)$$



Gambar 4. Arsitektur *ResNet50* [11]

Gambar 4 menunjukkan arsitektur *ResNet50* yang digunakan pada penelitian. Pada penelitian ini, seluruh layer utama *ResNet50* dibekukan (*trainable=False*), sedangkan *classifier head* tambahan digunakan untuk proses klasifikasi varietas mangga. Selain itu, diterapkan *BatchNormalization*, *Dropout* sebesar 0,5, serta regularisasi *L2* untuk mengurangi *overfitting* selama proses pelatihan model.

E. Proses Training

Proses pelatihan model dilakukan menggunakan konfigurasi parameter sebagaimana ditunjukkan pada Tabel 2. Model dilatih menggunakan *optimizer Adam* dengan *learning rate* sebesar 5×10^{-5} dan fungsi *loss sparse categorical crossentropy*. Untuk mengurangi risiko *overfitting* diterapkan *BatchNormalization*, *Dropout* sebesar 0,5, serta regularisasi *L2* pada layer klasifikasi. Selain itu, digunakan *callback* berupa *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint* untuk menjaga stabilitas proses pelatihan.

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
Arsitektur	<i>ResNet50</i>
Input Size	224×224
Batch Size	32
Epoch Maksimum	15
Optimizer	Adam
Learning Rate	5×10^{-5}
Loss Function	Sparse Categorical Crossentropy
Dropout	0,5
Regularisasi	L2 (0,001)
EarlyStopping	Patience = 4
ReduceLROnPlateau	Factor = 0,2
ModelCheckpoint	Save Best Model

Selanjutnya, proses pelatihan dihentikan secara otomatis menggunakan mekanisme *EarlyStopping* ketika nilai *validation loss* tidak mengalami peningkatan dalam beberapa *epoch* berturut-turut. Strategi ini digunakan untuk mencegah terjadinya *overfitting* dan menjaga kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

F. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. *Accuracy* digunakan untuk mengukur ketepatan klasifikasi secara keseluruhan, sedangkan *precision*, *recall*, dan *F1-score* digunakan untuk mengevaluasi performa model pada masing-masing kelas. Perhitungan metrik evaluasi ditunjukkan pada Persamaan (2)–(5). Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan klasifikasi antar kelas.

Accuracy digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi secara keseluruhan. Nilai *accuracy* diperoleh dari perbandingan jumlah data yang berhasil diklasifikasikan dengan benar terhadap seluruh data pengujian. *Accuracy* dihitung menggunakan Persamaan (2).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi suatu kelas. *Precision* dihitung menggunakan Persamaan (3).

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

Recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data yang termasuk ke dalam suatu kelas. *Recall* dihitung menggunakan Persamaan (4).

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

F1-score digunakan untuk mengevaluasi keseimbangan antara nilai *precision* dan *recall*. Nilai *F1-score* dihitung menggunakan Persamaan (5).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

Selain menggunakan metrik kuantitatif, penelitian ini juga memanfaatkan *confusion matrix* untuk menganalisis distribusi hasil klasifikasi pada setiap kelas varietas mangga. *Confusion matrix* digunakan untuk mengidentifikasi pola kesalahan klasifikasi yang terjadi antar kelas sehingga dapat diketahui kelas yang memiliki tingkat kemiripan visual tinggi dan berpotensi menyebabkan kesalahan prediksi. Melalui kombinasi *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*, performa model dapat dievaluasi secara lebih komprehensif baik dari sisi ketepatan klasifikasi maupun distribusi kesalahan prediksi pada masing-masing kelas.


III. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model

Model *ResNet50* dilatih menggunakan dataset citra mangga yang terdiri dari tiga kelas, yaitu GADUNG, MANALAGI, dan PODANG. Proses pelatihan dilakukan menggunakan pendekatan *transfer learning* dengan bobot awal dari ImageNet serta menerapkan teknik regularisasi berupa *data augmentation*, *BatchNormalization*, *Dropout*, dan *L2 regularization* untuk mengurangi risiko *overfitting*. Selain itu, digunakan *callback* berupa *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint* untuk menjaga stabilitas proses pelatihan.

Berdasarkan hasil pelatihan, model menunjukkan peningkatan performa yang konsisten pada data pelatihan maupun validasi. Mekanisme *EarlyStopping* menghentikan proses pelatihan secara otomatis ketika *validation loss* tidak mengalami peningkatan yang signifikan, sehingga membantu mencegah terjadinya *overfitting* dan menjaga kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

B. Analisis Accuracy dan Loss



Gambar 5. (a) Grafik *training accuracy* dan *validation accuracy*, (b) Grafik *training loss* dan *validation loss*

Berdasarkan Gambar 5, nilai *training accuracy* dan *validation accuracy* mengalami peningkatan selama proses pelatihan, dengan *training accuracy* meningkat dari 54,68% hingga lebih dari 90%, sedangkan *validation accuracy* mencapai kisaran 87–88%. Pada saat yang sama, nilai *training loss* dan *validation loss* menunjukkan tren penurunan yang stabil tanpa adanya peningkatan signifikan pada akhir pelatihan. Perbedaan yang relatif kecil antara kurva pelatihan dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik serta tidak mengalami *overfitting* yang berarti. Hasil ini menunjukkan bahwa arsitektur ResNet50 mampu mempelajari karakteristik visual varietas mangga secara efektif dengan performa pelatihan yang stabil.

C. Evaluasi Kinerja Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan data testing untuk mengukur kemampuan klasifikasi terhadap data yang tidak pernah digunakan selama proses training maupun validation. Tabel 3 menunjukkan hasil evaluasi model berdasarkan metrik accuracy dan loss.

Tabel 3. Hasil Evaluasi Model *ResNet50*

Parameter	Nilai
Test Accuracy	93,64%
Test Loss	0,4108

Berdasarkan hasil pengujian, model *ResNet50* berhasil memperoleh akurasi sebesar 93,64% pada data testing. Nilai tersebut menunjukkan bahwa sebagian besar citra mangga dapat

diklasifikasikan dengan benar oleh model. Hasil ini juga menunjukkan bahwa pendekatan transfer learning menggunakan ResNet50 efektif digunakan untuk klasifikasi varietas mangga berbasis citra digital.


Tabel 4. *Classification Report*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
GADUNG	0,94	0,86	0,90
MANALAGI	0,87	0,95	0,91
PODANG	1,00	1,00	1,00

Berdasarkan Tabel 4, kelas PODANG memperoleh nilai precision, recall, dan F1-score sempurna sebesar 1,00. Hal ini menunjukkan bahwa seluruh citra PODANG berhasil diklasifikasikan dengan benar oleh model. Sementara itu, kelas GADUNG dan MANALAGI masih menunjukkan beberapa kesalahan klasifikasi akibat adanya kemiripan karakteristik visual antara kedua varietas tersebut.

D. Analisis *Confusion Matrix*

Analisis lebih lanjut dilakukan menggunakan confusion matrix untuk mengetahui distribusi kesalahan klasifikasi yang terjadi pada setiap kelas.



Gambar 6. *Confusion Matrix ResNet50*

Berdasarkan Gambar 6, kesalahan klasifikasi dominan terjadi antara varietas GADUNG dan MANALAGI. Dari 110 citra GADUNG, sebanyak 95 citra berhasil diklasifikasikan dengan benar dan 15 citra salah diklasifikasikan sebagai MANALAGI. Sementara itu, pada kelas MANALAGI terdapat 104 citra yang berhasil dikenali dengan benar dan 6 citra salah diklasifikasikan sebagai GADUNG. Kondisi ini menunjukkan bahwa kedua varietas memiliki karakteristik visual yang relatif serupa, terutama pada dominasi warna hijau pada permukaan kulit buah, bentuk buah yang cenderung oval, serta tekstur kulit yang hampir sama. Kemiripan karakteristik tersebut menyebabkan model mengalami kesulitan dalam membedakan batas fitur antar kelas secara sempurna.

Berbeda dengan kedua kelas tersebut, seluruh citra PODANG berhasil diklasifikasikan dengan benar tanpa kesalahan prediksi. Hasil ini menunjukkan bahwa varietas PODANG memiliki karakteristik visual yang lebih khas, terutama pada warna kulit buah yang didominasi warna kuning hingga jingga sehingga lebih mudah dikenali oleh model ResNet50. Kemampuan model dalam mengklasifikasikan seluruh citra PODANG dengan benar menunjukkan bahwa fitur warna menjadi salah satu faktor penting dalam proses ekstraksi fitur yang dilakukan oleh arsitektur ResNet50.

Hasil pengujian menunjukkan bahwa penggunaan ResNet50 mampu menghasilkan performa klasifikasi yang tinggi dengan akurasi pengujian sebesar 93,64%. Selain itu, penerapan data augmentation, batch normalization, dropout, dan early stopping berhasil menjaga kestabilan proses pelatihan sehingga perbedaan antara training accuracy dan validation accuracy tetap relatif kecil. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan arsitektur *ResNet50* untuk klasifikasi varietas mangga berbasis citra digital. Berdasarkan hasil pengujian, model mampu mengenali tiga varietas mangga, yaitu GADUNG, MANALAGI, dan PODANG dengan performa yang baik. Penerapan *transfer learning*, data augmentation, batch normalization, dropout, serta *early stopping* terbukti membantu proses pelatihan model sehingga menghasilkan performa yang stabil dan mengurangi risiko *overfitting*. Hasil evaluasi menunjukkan bahwa model memperoleh akurasi pengujian sebesar 93,64%, dengan performa terbaik pada kelas PODANG yang mencapai nilai *precision*, *recall*, dan *F1-score* sebesar 1,00.

Meskipun demikian, model masih mengalami beberapa kesalahan klasifikasi pada varietas GADUNG dan MANALAGI. Kesalahan tersebut disebabkan oleh kemiripan karakteristik visual kedua varietas, terutama pada warna kulit, bentuk buah, dan tekstur permukaan yang relatif serupa. Kondisi ini menunjukkan bahwa objek dengan tingkat kemiripan visual yang tinggi masih menjadi tantangan dalam proses klasifikasi menggunakan *ResNet50*.

Penelitian selanjutnya dapat difokuskan pada penambahan jumlah dataset, peningkatan variasi kondisi pengambilan citra, serta penerapan *fine-tuning* pada layer *ResNet50* untuk meningkatkan kemampuan ekstraksi fitur. Selain itu, perbandingan dengan arsitektur *deep learning* lainnya juga dapat dilakukan untuk memperoleh performa klasifikasi yang lebih optimal pada varietas mangga dengan karakteristik visual yang mirip.

DAFTAR PUSTAKA

- [1] I. Ahmad *et al.*, “Automated Mango Variety Classification Using Deep Feature Extraction and Machine Learning Classifier Integration,” *Foods*, vol. 15, no. 3, Feb. 2026, doi: 10.3390/foods15030414.
- [2] M. M. A. Zaid, A. A. Mohammed, and P. Sumari, “Remote Sensing Image Classification Using Convolutional Neural Network (CNN) and Transfer Learning Techniques,” *Journal of Computer Science*, vol. 21, no. 3, pp. 635–645, 2025, doi: 10.3844/jcssp.2025.635.645.
- [3] L. Chuquimarca, B. Vintimilla, and S. Velastin, “Classifying healthy and defective fruits with a multi-input architecture and CNN models,” in 2024 14th International Conference

- on Pattern Recognition Systems (ICPRS), IEEE, 2024, pp. 1–7. doi: 10.1109/ICPRS62101.2024.10677833.
- [4] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
 - [5] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, and T. Ganslandt, “Transfer learning for medical image classification: a literature review,” *BMC Med. Imaging*, vol. 22, no. 1, p. 69, 2022.
 - [6] J. Plested, M. Phiri, and T. Gedeon, “Deep transfer learning for image classification: a survey,” Dec. 2025, doi: 10.1007/s10462-026-11491-z.
 - [7] A. K. Ratha, N. K. Barpanda, P. K. Sethy, and S. K. Behera, “Automated Classification of Indian Mango Varieties Using Machine Learning and MobileNet-v2 Deep Features.,” *Traitement du Signal*, vol. 41, no. 2, 2024.
 - [8] G. Yehulu et al., “Mango Fruit Disease Detection and Classification Using MobileNetV3_large Model,” *Sci. Afr.*, vol. 30, p. e03061, Oct. 2025, doi: 10.1016/j.sciaf.2025.e03061.
 - [9] A. Auni and E. Sugiharti, “Optimization of Mango Plant Leaf Disease Classification Using Concatenation Method of MobileNetV2 and DenseNet201 CNN Architectures,” *Scientific Journal of Informatics*, vol. 11, pp. 1023–1034, Feb. 2025, doi: 10.15294/sji.v11i4.15169.
 - [10] B. Peón, J. Torres Gómez, and A. Márquez, CNN-based solution for mango classification in agricultural environments. 2025. doi: 10.48550/arXiv.2507.23174.
 - [11] R. Sujana, P. Indah, N. Vinta, and R. Setiaji, “Evaluasi Model Klasifikasi Motif Batik Lasem Menggunakan Xgboost, Lightgbm, Resnet50, dan Efficientnet-B0,” *Jurnal Ilmiah Teknik Informatika dan Komunikasi*, vol. 6, pp. 76–93, Apr. 2026, doi: 10.55606/juitik.v6i2.2137.