



KLASIFIKASI PENYAKIT PADA BUAH JERUK BERDASARKAN CITRA DENGAN PENDEKATAN TRANSFER LEARNING MENGGUNAKAN ARSITEKTUR DENSENET-121

Sheli Agustina¹⁾, Asep Toyib Hidayat²⁾, Satrianansyah³⁾, Rudi Kurniawan⁴⁾

¹ Program Studi Informatika, Universitas Bina Insan

² Program Studi Informatika, Universitas Bina Insan

³ Program Studi Informatika, Universitas Bina Insan

⁴ Program Studi Informatika, Universitas Bina Insan

email: ¹sheliagustina16@gmail.com, ²asepfighter@gmail.com, ³satrianansyah@univbinainsan.ac.id,

⁴rudi.kurniawan@univbinainsan.ac.id

ARTICLE INFO

Article History:

Received : 3 Mei 2025

Accepted : 5 Juni 2025

Published : 13 Juli 2025

Keywords:

Klasifikasi Citra

Penyakit Jeruk

Pengolahan Citra Digital

Machine Learning

Densenet-121

IEEE style in citing this article:

S. Agustina, A. T. Hidayat, Satrianansyah, R. Kurniawan, "Klasifikasi Penyakit Pada Buah Jeruk Berdasarkan Citra Dengan Pendekatan Transfer Learning Menggunakan Arsitektur Densenet-121", *jurnal.ilmiah.informatika*, vol. 10, no. 1, pp. 42-47, Jul. 2025.

Corresponding Author:

Sheli Agustina

Universitas Bina Insan

ABSTRACT

This study aims to develop a classification system for citrus fruit diseases based on digital images using a machine learning approach. The primary challenge in citrus cultivation is disease attacks that affect both the quality and quantity of production. In this research, image processing techniques were applied to extract color, shape, and texture features from citrus fruit images, which were then used as input for classification algorithms. This study uses the DenseNet-121 architecture for orange fruit image classification. The dataset used consisted of images of healthy citrus fruits and those affected by various diseases, such as blackspot, canker, and greening. The testing results showed that the DenseNet-121 architecture achieved the highest accuracy in classifying citrus diseases, with an accuracy rate of up to 99%. This system is expected to assist farmers and relevant stakeholders in early disease detection and in taking appropriate control measures.

1. PENDAHULUAN

Perkembangan teknologi saat ini memungkinkan petani meminimalisir kesalahan dalam menentukan penyakit pada tanaman dengan memanfaatkan Artificial Intelligence (AI). AI merupakan cabang ilmu komputer yang mempelajari bagaimana mesin (komputer) dapat melakukan pekerjaan seperti manusia, bahkan lebih baik. Salah satu turunan AI adalah machine learning, yang kemudian berkembang lebih lanjut menjadi deep learning [1].

Machine learning merupakan cabang dari Deep Learning yang telah berbasis Jaringan Syaraf Tiruan (JST) sehingga memungkinkan komputer memiliki kemampuan seperti manusia dalam berpikir dan bertindak [2]. Deep learning sering digunakan untuk klasifikasi data berbasis gambar, suara, dan teks. Dalam penerapannya, komputer dilatih menggunakan dataset berlabel dalam jumlah besar. Data ini diolah menjadi representasi internal, seperti feature vector, untuk proses pengklasifikasian yang dapat digunakan pada berbagai aplikasi, termasuk deteksi penyakit tanaman [3].

Jeruk merupakan salah satu komoditas penting dalam industri pertanian, memberikan kontribusi signifikan terhadap perekonomian global. Namun, ancaman penyakit pada tanaman jeruk, seperti blackspot, canker, dan greening, dapat menurunkan kualitas dan kuantitas hasil panen, serta berdampak buruk pada pendapatan petani. Oleh karena itu, pemantauan kesehatan tanaman jeruk secara cermat sangatlah penting.

Penggunaan teknologi informatika dan kecerdasan buatan menawarkan solusi efektif untuk memantau dan mengidentifikasi penyakit tanaman secara cepat dan akurat. Dalam hal ini,


pengembangan aplikasi klasifikasi penyakit berbasis citra dapat membantu petani mengambil tindakan pencegahan lebih dini, mengurangi kerugian panen, dan meningkatkan produktivitas.

Convolutional Neural Network (CNN) merupakan metode deep learning yang paling efektif dalam melakukan klasifikasi gambar [4]. CNN menggunakan arsitektur berlapis untuk mengekstraksi dan mempelajari fitur kompleks dari data. Salah satu arsitektur populer adalah DenseNet121, yang dirancang untuk mengatasi masalah gradien yang hilang dengan memanfaatkan koneksi yang padat antara lapisan-lapisan jaringan. Arsitektur ini sangat cocok untuk meningkatkan akurasi meskipun dataset yang digunakan terbatas [5].

Sistem deteksi penyakit ini dirancang untuk mengklasifikasikan kondisi buah jeruk, apakah sehat (*fresh*) atau terkena penyakit seperti blackspot, canker, dan greening. Dengan menggunakan DenseNet121 dan konsep transfer learning, sistem ini mampu mempelajari fitur kompleks dari citra buah jeruk secara efektif meskipun menggunakan data terbatas. Diharapkan sistem ini dapat membantu petani mengidentifikasi penyakit lebih cepat dan akurat, menghemat waktu, biaya, dan tenaga, serta menjaga kualitas dan kuantitas produksi buah jeruk.

Berdasarkan uraian di atas, peneliti tertarik untuk melakukan dengan judul "Klasifikasi Penyakit Pada Buah Jeruk Berdasarkan Citra Dengan Pendekatan Transfer Learning Menggunakan Arsitektur DenseNet121". Tujuan dari penelitian ini adalah untuk membangun model klasifikasi yang mampu mendeteksi penyakit pada jeruk berdasarkan citra yang menggunakan arsitektur *Densenet121*. Dalam melakukan pendekatan transfer learning.

2. METODE PENELITIAN



Gambar 1. Rancangan Sistem

Gambar 1. merupakan rancangan sistem klasifikasi penyakit buah jeruk berdasarkan citra dengan pendekatan *transfer learning* menggunakan arsitektur *dense121*.

2.1 Data Collection

Penelitian ini diawali dengan pengumpulan data menggunakan dataset citra penyakit buah jeruk, yang diperoleh dari platform *Kaggle*. Dataset mencakup berbagai kondisi buah jeruk, seperti sehat (fresh) dan terinfeksi penyakit, yaitu *blackspot*, *canker*, dan *greening*. Data yang terkumpul diperiksa kelengkapan dan kualitasnya sebelum diproses lebih lanjut.

2.2 Pre-processing

Setelah data terkumpul, dilakukan pemrosesan data dengan dataset dibagi menjadi tiga kelompok utama, yaitu training (data latih), validation (data validasi) dan testing (data uji). Ketiga data ini memiliki peranannya masing masing. Training (data latih) berfungsi untuk membentuk model, validation (data validasi) berfungsi memantau performa model selama pelatihan dan data validasi untuk memvalidasi data, dan testing (data uji) berfungsi mengevaluasi performa model setelah pelatihan selesai.

2.3 Training dengan model DenseNet121

Selanjutnya model transfer learning berbasis DenseNet121 dilatih menggunakan data latih. DenseNet121

dipilih karena keunggulannya dalam mengekstraksi fitur kompleks dan memanfaatkan koneksi padat antar lapisan jaringan. Proses pelatihan bertujuan agar hyperparameter seperti, *batch size*, *learning rate* dan jumlah epoch dapat mencapai kinerja terbaik. Data validasi digunakan secara bersamaan selama pelatihan untuk mencegah *overfitting* dan memantau performa model. Hasil dari pelatihan ini adalah model sementara yang memiliki bobot optimal berdasarkan data latih.

2.4 Evaluasi Model

Setelah model dilatih, dilakukan evaluasi menggunakan data uji untuk mengukur performa model. Evaluasi dilakukan dengan *confusion matrix*. Dengan *confusion matrix* tingkat kebingungan nilai dari algoritma pada setiap kelas yang berbeda dapat divisualisasikan tanpa tergantung pada algoritma klasifikasi [6]. *Confusion matrix* dapat dilihat pada Tabel 1 [7].

Tabel 1. Confusion Matrix

	Predicted Negative	Predicted Positive
Actual Negative	True Negative (TN)	False Positive (FP)
Actual Positive	False Negative (FN)	True Positive (TP)

Dengan *confusion matrix* mampu mengevaluasi nilai hasil secara akurasi, presisi, recall, dan F1-score dapat memastikan bahwa model mampu mengklasifikasikan citra buah jeruk dengan baik. Persentase ketepatan sebuah record data yang diklasifikasikan secara tepat setelah melalui pengujian pada hasil klasifikasi disebut dengan istilah nilai akurasi. Proporsi dalam kasus yang diprediksi hasilnya positif benar pada data yang sebenarnya disebut dengan istilah presisi atau *confidence*. selanjutnya proporsi kasus positif yang sebenarnya yang diprediksi positif secara benar

disebut dengan *recall* atau *sensitivity* [8]. Sedangkan *F1-Score* merupakan perbandingan rata-rata presisi dan *recall*. Akurasi, presisi, *recall*, dan *F1-Score* dihitung menggunakan persamaan (1)-(4) [9].

$$\text{Akurasi} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (1)$$

$$\text{Presisi} = \frac{(TP)}{(TP+FP)} \quad (2)$$

$$\text{Recall} = \frac{(TP)}{(TP+FN)} \quad (3)$$

$$\text{F1-Score} = 2 * \frac{(\text{Recall} * \text{Presisi})}{(\text{Recall} + \text{Presisi})} \quad (4)$$

2.5 Deployment

Setelah mendapat model dengan performa tinggi maka model akan siap dipakai dan dibundel dalam ekstensi h5.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Klasifikasi Penyakit Buah Jeruk


Berdasarkan proses percobaan yang telah dilakukan, dalam melatih model pembelajaran secara mendalam menerapkan dataset penyakit cacar monyet selama 100 epoch. Pelatihan model *DenseNet121* bertujuan untuk mendapatkan akurasi yang maksimal dalam mengklasifikasi data dengan tepat, serta memperkecil nilai *loss*, yang menunjukkan bahwa model baik dalam menyesuaikan diri terhadap data pelatihan. Pelatihan yang telah dihasilkan saat 5 epoch terakhir dilakukan, ditunjukkan pada Tabel 2.

Tabel 2 Tampilan 5 Terakhir dari Hasil Pelatihan

Epoch	Accuracy Training	Loss Training	Akurasi Validasi	Loss Validasi
1	0.9956	0.0148	0.9848	0.0776
2	0.9913	0.0267	0.9899	0.0727
3	0.9977	0.0071	0.9747	0.1245
4	0.9916	0.0409	0.9899	0.0548
5	0.9923	0.0156	0.9899	0.0956

Berdasarkan Tabel 2. data 5 epoch terakhir dari total 100 epoch dengan callback yang berhenti di epoch ke-17, model menunjukkan performa yang stabil, meskipun terdapat sedikit fluktuasi. Pada epoch pertama, akurasi training mencapai 99,56% dengan loss training 0,0148, sedangkan akurasi validasi sebesar 98,48% dengan loss validasi 0,0776, menunjukkan generalisasi yang baik. selanjutnya epoch kedua, menunjukkan akurasi validasi mengalami peningkatan menjadi 98,99% dengan loss validasi yang menurun menjadi 0,0727. Namun, pada epoch ketiga, meskipun akurasi training mencapai puncaknya di 99,77% dan loss training sangat rendah (0,0071), akurasi validasi justru turun menjadi 97,47% dengan peningkatan loss validasi ke 0,1245, indikasi potensi overfitting.

Dari hasil pelatihan tersebut didapat grafik akurasi pelatihan yang terdapat pada Gambar 2.




Gambar 2. Hasil Akurasi Pelatihan

Pada Gambar 2. Dapat diketahui bahwa nilai performa luar biasa dari model selama 17 epoch pelatihan, dengan akurasi yang konsisten cukup tinggi baik pada data training maupun validasi. Akurasi training (garis biru) dengan cepat mencapai hampir 100% pada epoch awal dan tetap stabil hingga akhir. Dengan demikian menunjukkan bahwa model mampu menganalisis pola dalam data training dengan cukup baik. Akurasi validasi (garis merah) juga meningkat pesat pada epoch awal, mencapai puncak

terbaik di epoch ke-2, sebagaimana ditunjukkan oleh tanda hijau. Akurasi validasi tetap berada di sekitar angka 98% hingga akhir pelatihan, yang mencerminkan kemampuan model untuk melakukan generalisasi pada data baru dengan baik.

Dengan akurasi validasi yang konsisten di atas 98%, model ini sangat andal untuk diterapkan pada data baru. Kelebihan lain yang ditunjukkan adalah kestabilan performa setelah epoch ke-2, mengindikasikan bahwa callback yang digunakan berhasil mencegah pelatihan berlebih. Secara keseluruhan, model ini menunjukkan keunggulan dalam kemampuan belajar, generalisasi, dan stabilitas, yang menjadikannya sangat cocok untuk diterapkan pada tugas prediktif. Untuk grafik loss (kesalahan) dari pelatihan dapat dilihat pada Gambar 3.



Gambar 3. Hasil Loss Pelatihan

Gambar 3. menunjukkan perkembangan loss training dan loss validasi selama 17 epoch pelatihan. Loss training (garis biru) menurun tajam pada epoch pertama dan tetap rendah hingga akhir pelatihan, menandakan bahwa model dengan cepat belajar dari data training dan mempertahankan performanya. Pada epoch ke-2, yang ditandai sebagai epoch terbaik (titik hijau), loss validasi (garis merah) mencapai nilai terendah, mencerminkan keseimbangan optimal antara akurasi dan generalisasi model pada data validasi.

3.2 Pengujian Hasil Klasifikasi

Setelah proses pelatihan, model akan mulai diujikan dengan data testing seperti terlihat pada Gambar 4.

* 📊 * Train Loss and Accuracy * 📊 *


```
# evaluate the model
loss, acc = model.evaluate(validation_ds)

7/7 ————— 2s 220ms/step - accuracy: 0.9931 - loss: 0.0323
```

Gambar 4. Hasil Evaluasi Model

Berdasarkan Gambar 4, menunjukkan model DenseNet121 yang digunakan untuk klasifikasi buah jeruk memberikan hasil evaluasi yang sangat memuaskan pada data validasi. Akurasi model mencapai 99,31%, menunjukkan bahwa model mampu mengenali hampir semua data validasi dengan benar. Nilai loss yang terbilang cukup rendah, yaitu 0,0323, mencerminkan tingkat kesalahan prediksi yang sangat kecil, yang menunjukan bahwa pemahaman model terhadap pola-pola dalam data cukup baik.

Hasil dari penelitian sudah cukup baik, namun perlu dilakukan evaluasi tambahan pada dataset pengujian yang benar-benar baru tetap diperlukan. Tujuan dari evaluasi lanjutan ini adalah untuk memastikan kemampuan model dalam menggeneralisasi pola dari data baru yang tidak pernah dilihat sebelumnya. Dengan akurasi yang mendekati sempurna, model ini memiliki potensi besar untuk diterapkan dalam aplikasi nyata, seperti sistem otomatisasi klasifikasi buah untuk industri agrikultur atau manajemen kualitas produk. Selanjutnya akan digunakan confusion matrix untuk melakukan evaluasi seperti pada Gambar 5.

Gambar 5. Hasil *Confusion Matrix*

Berdasarkan Gambar 5, *Confusion matrix* yang dihasilkan menunjukkan kinerja model DenseNet121 dalam mengklasifikasikan buah jeruk ke dalam empat kategori: blackspot, canker, fresh, dan grenning. Model berhasil mengklasifikasikan sebagian besar data dengan benar, dengan hanya sedikit kesalahan pada beberapa kelas. Untuk kelas blackspot, model secara akurat memprediksi 28 sampel, namun terdapat 2 sampel yang salah diklasifikasikan sebagai canker. Demikian pula, pada kelas canker, model mengklasifikasikan 28 sampel dengan benar, tetapi 1 sampel salah diprediksi sebagai blackspot. Pada kelas fresh, model menunjukkan akurasi sempurna dengan mengklasifikasikan semua 33 sampel dengan benar. Hasil serupa juga terlihat pada kelas grenning, di mana semua 22 sampel diklasifikasikan dengan benar tanpa kesalahan.

Hasil pengujian dengan data gambar langsung secara individual ditunjukkan pada Gambar pada Gambar 6.



Gambar 6. Hasil Prediksi

Berdasarkan Gambar 6, menunjukkan perkiraan hasil dari model DenseNet121 pada sebuah gambar jeruk. Model berhasil mengklasifikasikan gambar sebagai kelas fresh dengan tingkat kepercayaan (*confidence*) sebesar 1.00 atau 100%. Hal ini menunjukkan bahwa model sangat yakin terhadap prediksi yang dibuat. Prediksi ini mencerminkan kemampuan model dalam mengenali fitur visual seperti tekstur kulit jeruk yang segar, warna cerah, dan bentuknya, yang merupakan karakteristik dari kelas fresh. Hasil ini memperkuat temuan dari confusion matrix, di mana kelas fresh menunjukkan akurasi sempurna tanpa adanya kesalahan klasifikasi. Hasil prediksi ini juga menunjukkan potensi penerapan model dalam klasifikasi otomatis pada sistem pemrosesan hasil panen untuk memastikan kualitas produk. Evaluasi lebih lanjut pada gambar dari kelas lain tetap diperlukan untuk mengukur konsistensi model dalam situasi yang berbeda.

4. KESIMPULAN

Penelitian menunjukkan bahwa model dikembangkan untuk klasifikasi penyakit buah jeruk mencapai performa yang sangat baik. Pada fase pelatihan, model menunjukkan akurasi yang sangat tinggi sebesar 99.00%. Model yang dikembangkan sangat efektif dalam

mengidentifikasi dan mengklasifikasikan setiap kelas secara tepat, dengan hampir tidak ada kesalahan klasifikasi untuk setiap label yang diuji. Kemampuan model dalam memberikan prediksi juga sangat akurat dan konsisten.

5. REFERENSI

- [1] R. Soekarta, N. Nurdjan, and A. Syah, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)," *INSECT*, vol. 8, no. 2, pp. 143–151, 2023.
- [2] S. Nurmaini, A. Darmawahyun, A. I. Sapit, M. N. Rachmatullah, Firdaus, and B. Tutuko, *Pengenalan Deep Learning dan Implementasinya*. UPT. Penerbit dan Percetakan Universitas Sriwijaya, 2021.
- [3] M. I. Anshori, R. A. Yaqin, M. A. Z. Sidiq, and I. W. P. Agung, "Klasifikasi Jenis Jerawat Secara Otomatis Dengan Convolutional Neural Network Menggunakan Arsitektur Resnet-50," *J. Manaj. Inform.*, vol. 15, no. 1, pp. 73–84, 2025.
- [4] William and C. Lubis, "Klasifikasi Penyakit Mata menggunakan CNN," *J. Ilmu Komput. dan Sist. Inf.*, vol. 10, no. 1, pp. 1–4, 2022.
- [5] J. Pardede and D. A. L. Putra, "Implementasi DenseNet Untuk Mengidentifikasi Kanker Kulit Melanoma," *J. Tek. Inform. dan Sist. Inf. Vol.*, vol. 6, no. 3, pp. 425–433, 2020.
- [6] Arnita, F. Marpaung, F. Aulia, Nita Suryani, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. Surabaya, Jawa Timur: Pustaka Aksara, 2022.
- [7] N. Fadhilah and A. Desiani, "Klasifikasi Nyeri Punggung Bawah Menggunakan Algoritma K-Nearest Neighbor Dan Support Vector Machine," *J. Tek. Elektro dan Komputasi Vol.*, vol. 7, no. 1, pp. 91–98, 2025.
- [8] Y. Amrozi, D. Yuliati, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *J. SISFOKOM (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 394–399, 2022.
- [9] P. L. Romadloni, B. A. Kusuma, W. M. Baihaqi, F. I. Komputer, and U. A. Purwokerto, "Komparasi Metode Pembelajaran Mesin untuk Implementasi Pengambilan Keputusan dalam Menentukan Promosi Jabatan Karyawan," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 2, pp. 622–628, 2022.