

RESEARCH ARTICLE

Open Access

Penerapan Teknik Transformasi untuk Meningkatkan Kualitas Citra Penyakit *Ganoderma* pada Tanaman Kelapa Sawit Menggunakan *CNN-Based Enhancement* dan *Gamma Correction*

Aditya^{1*}, Amanda², Dini Gustiningsih³

^{1*,2,3} Program Studi Teknologi Rekayasa Perangkat Lunak, Politeknik Kelapa Sawit Citra Widya Edukasi, Kabupaten Bekasi, Provinsi Jawa Barat, Indonesia.

*Correspondence email:
aditya@politeknik.ac.id.

Received: 22 July 2026.
Revised: 22 August 2026.
Accepted: 28 August 2026.
Published: 30 August 2026.

Full list of author information is
available at the end of the article.

Abstract

Ganoderma disease is one of the most destructive diseases affecting oil palm plants, causing basal stem rot, reduced productivity, plant mortality, and substantial financial losses. This study proposes an image enhancement pipeline for Ganoderma disease identification by combining Gamma Correction and CNN-Based Enhancement. Gamma Correction is applied to improve illumination and pixel intensity, while CNN-Based Enhancement is used to enhance structural and textural details through a deep learning approach. After enhancement, the processed images are classified into three categories: Healthy, Infected, and Initial Infection. The model achieved a test accuracy of 0.7714 with a test loss of 0.4165. For each class, the F1-scores of Healthy, Infected, and Initial Infection were 0.8571, 0.7500, and 0.7200, respectively. The results indicate that image transformation techniques can effectively support Ganoderma disease identification in oil palm plants. By improving image quality prior to classification, the model becomes more stable in emphasizing disease-relevant visual features under diverse lighting conditions. Overall, the proposed enhancement process, which integrates intensity correction with CNN-based reconstruction, offers a promising direction for developing automated detection systems that are more accurate, adaptive, and suitable for field deployment.

Keywords: Oil Palm; Gamma Correction; Ganoderma Disease; Cnn-Based Enhancement; Image Quality.

Abstrak

Penyakit Ganoderma merupakan salah satu penyakit yang merugikan tanaman kelapa sawit karena menyebabkan busuk pangkal batang, penurunan produktivitas, kematian tanaman, dan kerugian finansial. Penelitian ini menerapkan Gamma Correction dan CNN-Based Enhancement untuk meningkatkan kualitas citra kelapa sawit dalam proses identifikasi penyakit Ganoderma. Gamma Correction digunakan untuk memperbaiki pencahayaan dan intensitas citra, sedangkan CNN-Based Enhancement meningkatkan detail struktur melalui pendekatan pembelajaran mendalam. Model memperoleh akurasi pengujian sebesar 0,7714 dan test loss sebesar 0,4165. Kelas Healthy, Infected, dan Initial Infection masing-masing memperoleh F1-score sebesar 0,8571, 0,7500, dan 0,7200. Hasil penelitian menunjukkan bahwa teknik transformasi citra dapat mendukung identifikasi penyakit Ganoderma pada tanaman kelapa sawit. Dengan peningkatan kualitas citra sebelum klasifikasi, model menjadi lebih stabil dalam menonjolkan karakteristik visual penyakit pada kondisi pencahayaan yang bervariasi. Proses enhancement yang menggabungkan perbaikan intensitas dan peningkatan berbasis CNN berpotensi mendukung pengembangan sistem deteksi otomatis yang lebih akurat, adaptif, dan sesuai untuk penerapan di lapangan.

Kata Kunci: Kelapa Sawit; Gamma Correction; Penyakit Ganoderma; Cnn-Based Enhancement; Kualitas Citra.




1. Pendahuluan

Penyakit *Ganoderma* merupakan salah satu penyakit yang paling merugikan pada tanaman kelapa sawit karena menyebabkan busuk pangkal batang yang dapat berdampak pada penurunan produktivitas, kematian tanaman, serta kerugian finansial yang signifikan di sektor perkebunan (Santoso, 2020). Penyakit ini menjadi salah satu permasalahan penting dalam pengelolaan perkebunan kelapa sawit karena perkembangan penyakit dapat berlangsung secara bertahap sehingga gejala yang muncul pada tahap awal relatif sulit dikenali. Deteksi awal penyakit *Ganoderma* tetap menjadi tantangan karena gejala visualnya sering kali tidak terlihat secara jelas dan dapat disalahartikan sebagai gejala akibat kondisi stres tanaman lainnya (Sabrina, 2023). Kondisi tersebut menunjukkan pentingnya pengembangan metode berbasis teknologi yang mampu membantu proses identifikasi penyakit secara lebih objektif dan konsisten. Salah satu faktor yang berpengaruh dalam proses identifikasi berbasis citra adalah kualitas gambar yang digunakan. Citra dengan pencahayaan, kontras, dan detail visual yang kurang baik dapat menyulitkan proses pengenalan karakteristik objek dan gejala penyakit. Kualitas citra yang baik diperlukan dalam aplikasi pengolahan citra karena dapat memengaruhi akurasi analisis dan hasil diagnosis (Mandiri et al., 2025). Pada citra tanaman kelapa sawit, perubahan warna, tekstur, bentuk daun, maupun karakteristik bagian tanaman yang berkaitan dengan infeksi *Ganoderma* dapat menjadi informasi penting dalam proses identifikasi. Apabila informasi visual tersebut kurang jelas akibat kondisi pencahayaan atau kualitas citra yang rendah, proses ekstraksi dan pengenalan fitur dapat menjadi kurang optimal. Peningkatan kualitas citra dapat dilakukan melalui teknik transformasi citra sebelum citra digunakan dalam proses klasifikasi atau deteksi. Salah satu pendekatan yang dapat digunakan adalah *Gamma Correction*, yaitu teknik yang digunakan untuk menyesuaikan tingkat kecerahan dan intensitas citra. Teknik ini dapat membantu meningkatkan visibilitas fitur tertentu pada citra yang terlalu gelap atau terlalu terang sehingga informasi visual menjadi lebih mudah diamati (Abdillah et al., 2025). Selain itu, pendekatan berbasis *Convolutional Neural Network* (CNN) dapat digunakan untuk meningkatkan kualitas struktur dan detail citra. *CNN-Based Enhancement* memanfaatkan kemampuan jaringan saraf dalam mempelajari pola dan karakteristik citra melalui proses pembelajaran mendalam sehingga berpotensi menghasilkan citra dengan informasi visual yang lebih representatif (Sungai et al., 2024).

Penerapan teknik transformasi citra dalam penelitian ini diarahkan untuk meningkatkan kualitas citra tanaman kelapa sawit yang berkaitan dengan kondisi sehat maupun terinfeksi *Ganoderma*. Penggunaan *Gamma Correction* dan *CNN-Based Enhancement* dilakukan untuk memperoleh citra yang memiliki informasi visual lebih jelas sebelum digunakan dalam proses identifikasi. Proses tersebut diharapkan dapat membantu model dalam mengenali karakteristik visual dari setiap kondisi tanaman, khususnya dalam membedakan tanaman sehat, tanaman terinfeksi, dan tanaman yang berada pada tahap awal infeksi. Dengan demikian, peningkatan kualitas citra tidak hanya dipandang sebagai proses perbaikan tampilan gambar, tetapi juga sebagai tahap pendukung dalam memperoleh informasi yang lebih sesuai untuk proses klasifikasi. Penelitian ini bertujuan untuk menerapkan dan mengevaluasi teknik transformasi citra melalui kombinasi *Gamma Correction* dan *CNN-Based Enhancement* dalam mendukung identifikasi penyakit *Ganoderma* pada tanaman kelapa sawit. Evaluasi dilakukan dengan melihat kualitas citra sebelum dan sesudah proses transformasi serta menilai performa klasifikasi berdasarkan *accuracy*, *precision*, *recall*, dan *F1-score*. Pendekatan tersebut diharapkan dapat memberikan gambaran mengenai kemampuan teknik transformasi citra dalam mendukung proses identifikasi penyakit *Ganoderma* (Pertumbuhan et al., 2024). Selain itu, evaluasi performa diperlukan untuk mengetahui sejauh mana peningkatan kualitas citra dapat mendukung proses pengenalan karakteristik penyakit menggunakan pendekatan berbasis CNN (Suwaryo & Basri, 2025). Penerapan pendekatan berbasis transformasi citra dan pembelajaran mendalam diharapkan dapat memberikan kontribusi terhadap pengembangan teknologi pengolahan citra di bidang pertanian. Sistem yang mampu memanfaatkan citra dengan kualitas yang lebih baik berpotensi membantu proses identifikasi penyakit secara lebih cepat dan konsisten. Dalam jangka panjang, pendekatan tersebut dapat mendukung pengembangan sistem deteksi *Ganoderma* secara otomatis yang lebih adaptif terhadap kondisi citra dan dapat dikembangkan untuk mendukung penerapan teknologi pertanian presisi. Selain itu, proses *enhancement* diharapkan dapat mengurangi pengaruh variasi kondisi pencahayaan dan noise yang sering muncul pada pengambilan citra di lapangan. Dengan demikian, kualitas fitur visual yang masuk ke model CNN menjadi lebih konsisten, sehingga berpotensi meningkatkan kemampuan identifikasi, terutama pada gejala infeksi awal. Oleh karena itu, penelitian mengenai peningkatan kualitas citra melalui *Gamma Correction* dan *CNN-Based Enhancement* menjadi penting sebagai salah satu tahapan dalam pengembangan sistem deteksi penyakit *Ganoderma* pada tanaman kelapa sawit.

2. Metode

Penelitian menggunakan metode *CNN-Based Enhancement* dan *Gamma Correction* untuk meningkatkan kualitas gambar daun kelapa sawit (Anindyati *et al.*, 2025). Proses peningkatan kualitas citra dilakukan dengan memperhatikan kondisi citra sebelum dan sesudah transformasi. Kualitas citra dievaluasi menggunakan beberapa parameter objektif, seperti kontras, kejernihan, serta atribut visual lainnya. Selanjutnya, hasil transformasi digunakan untuk menilai dampak peningkatan kualitas gambar daun sawit terhadap kinerja *CNN-Based Enhancement* dan *Gamma Correction*, terutama berdasarkan *accuracy*, *precision*, *recall*, dan *F1-score* dalam mendeteksi penyakit *Ganoderma*. Tahapan pengujian dilakukan untuk mengetahui perubahan kualitas citra setelah proses transformasi serta kemampuan model dalam mengidentifikasi kondisi tanaman kelapa sawit. Hasil pengujian tersebut digunakan sebagai dasar untuk membangun model deteksi penyakit *Ganoderma* yang lebih tepat dan terpercaya serta mendukung pengembangan sistem pertanian presisi berbasis teknologi digital.



Gambar 1. Tahapan Pengujian

Tahapan pengujian pada Gambar 1 menunjukkan proses penelitian yang dilakukan untuk meningkatkan kualitas citra dan mengevaluasi hasil deteksi penyakit *Ganoderma*. Proses dimulai dengan citra daun kelapa sawit yang digunakan sebagai data pengujian. Citra kemudian melalui tahap *Gamma Correction* untuk melakukan penyesuaian intensitas dan pencahayaan. Setelah itu, citra diproses menggunakan *CNN-Based Enhancement* untuk meningkatkan kualitas struktur dan detail visual. Citra hasil transformasi selanjutnya digunakan dalam proses deteksi penyakit *Ganoderma*. Tahap akhir dilakukan dengan mengevaluasi hasil deteksi menggunakan *accuracy*, *precision*, *recall*, dan *F1-score*, serta membandingkan kualitas citra sebelum dan sesudah transformasi berdasarkan parameter visual yang digunakan.

3. Hasil dan Pembahasan

3.1 Hasil

Penelitian ini bertujuan untuk menerapkan teknik transformasi citra dalam memperbaiki kualitas gambar daun serta bagian tanaman kelapa sawit yang menunjukkan gejala penyakit *Ganoderma*. Metode yang diterapkan meliputi *Gamma Correction* dan *CNN-Based Enhancement*. Tahapan penelitian mencakup pengumpulan gambar, pra-pemrosesan, transformasi gambar, peningkatan kualitas gambar, ekstraksi fitur visual, dan penilaian hasil perbaikan. Citra tanaman kelapa sawit yang digunakan memiliki variasi kondisi pencahayaan, ketajaman, kontras, warna, dan tingkat gangguan visual. Kondisi tersebut dapat

menyebabkan ciri-ciri visual penyakit *Ganoderma* menjadi kurang jelas. Oleh karena itu, peningkatan kualitas citra diperlukan agar bagian gambar yang menunjukkan tanda-tanda penyakit dapat terlihat lebih jelas dan lebih mudah dianalisis menggunakan sistem berbasis *Convolutional Neural Network* (CNN).

Tabel 1. Exploratory Data Analysis (EDA)

No	Nama	Keterangan
TRAIN		
1	Healthy	127 images
	Infected	215 images
	Initial Infection	150 images
	Subtotal	492 images
VALID		
2	Healthy	7 images
	Infected	9 images
	Initial Infection	9 images
	Subtotal	25 images
TEST		
3	Healthy	10 images
	Infected	12 images
	Initial Infection	13 images
	Subtotal	35 images
GRAND TOTAL		552 images


Berdasarkan Tabel 1, dataset penelitian terdiri atas 552 citra yang terbagi menjadi tiga kelas, yaitu *Healthy*, *Infected*, dan *Initial Infection*. Dataset terdiri atas 492 citra *training*, 25 citra *validation*, dan 35 citra *testing*. Jumlah citra pada setiap kelas menunjukkan adanya perbedaan distribusi data. Kelas *Infected* memiliki jumlah citra paling banyak, sedangkan kelas *Healthy* memiliki jumlah citra paling sedikit. Kondisi tersebut perlu diperhatikan karena ketidakseimbangan jumlah data antarkelas dapat memengaruhi proses pembelajaran dan hasil klasifikasi model. Citra yang digunakan dalam penelitian memiliki kondisi visual yang beragam, terutama pada pencahayaan, ketajaman, kontras, warna, dan tingkat gangguan visual. Variasi tersebut dapat memengaruhi kejelasan informasi pada citra. Oleh karena itu, tahap *image enhancement* dilakukan untuk membantu memperjelas karakteristik visual yang berkaitan dengan kondisi tanaman kelapa sawit.



Gambar 2. Daun Kelapa Sawit

Gambar 2 menunjukkan contoh citra daun kelapa sawit yang digunakan sebagai data awal penelitian. Citra tersebut selanjutnya diproses melalui tahapan peningkatan kualitas. Perbedaan kondisi pencahayaan dan

kualitas visual pada citra menjadi dasar penerapan *Gamma Correction* dan *CNN-Based Enhancement*. Proses tersebut dilakukan untuk menghasilkan citra dengan informasi visual yang lebih baik sebelum digunakan dalam proses klasifikasi. Pada tahap peningkatan kualitas citra, *Gamma Correction* digunakan untuk menyesuaikan tingkat kecerahan dan intensitas gambar. Beberapa citra menunjukkan pencahayaan yang tidak merata, kontras rendah, warna yang kurang jelas, serta gangguan berupa *noise*. Kondisi tersebut dapat menyulitkan proses identifikasi ciri penyakit *Ganoderma*. Gejala visual yang perlu diperhatikan meliputi perubahan warna pada bagian tanaman, kerusakan jaringan, perubahan tekstur, serta pola visual yang berbeda antara tanaman sehat dan tanaman yang terindikasi penyakit. *Gamma Correction* dilakukan dengan memodifikasi intensitas piksel berdasarkan nilai gamma. Dalam penelitian ini digunakan variasi gamma sebesar 0,8, 1,0, dan 1,2. Penggunaan variasi tersebut bertujuan untuk menghasilkan perubahan tingkat pencahayaan sehingga informasi visual pada citra yang terlalu gelap atau terlalu terang dapat terlihat lebih jelas.



Gambar 3. Gamma Correction

Gambar 3 menunjukkan hasil penerapan *Gamma Correction* pada citra tanaman kelapa sawit. Perubahan nilai gamma menghasilkan perbedaan tingkat kecerahan pada citra sehingga bagian objek dapat terlihat dengan tingkat pencahayaan yang berbeda. Hasil transformasi tersebut selanjutnya digunakan sebagai bagian dari proses peningkatan kualitas citra sebelum dilakukan analisis berbasis CNN. Peningkatan kualitas citra kemudian dilanjutkan menggunakan *CNN-Based Enhancement* dengan model *autoencoder*. Pendekatan ini memanfaatkan kemampuan CNN dalam mempelajari karakteristik visual citra. Model *autoencoder* terdiri atas bagian *encoder* dan *decoder*. Bagian *encoder* digunakan untuk mempelajari representasi fitur citra, sedangkan bagian *decoder* digunakan untuk melakukan rekonstruksi citra. Arsitektur *autoencoder* yang digunakan terdiri atas beberapa lapisan *Conv2d*, *ReLU*, dan *MaxPool2d* pada bagian *encoder*, serta *ConvTranspose2d*, *ReLU*, dan *Sigmoid* pada bagian *decoder*. Model tersebut memiliki total 156.259 parameter.


```
EnhancementAutoencoder(
  (encoder): Sequential(
    (0): Conv2d(3, 32, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (1): ReLU(inplace=True)
    (2): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (3): Conv2d(32, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (4): ReLU(inplace=True)
    (5): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (6): Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (7): ReLU(inplace=True)
    (8): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  )
  (decoder): Sequential(
    (0): ConvTranspose2d(64, 64, kernel_size=(4, 4), stride=(2, 2), padding=(1, 1))
    (1): ReLU(inplace=True)
    (2): ConvTranspose2d(64, 32, kernel_size=(4, 4), stride=(2, 2), padding=(1, 1))
    (3): ReLU(inplace=True)
    (4): ConvTranspose2d(32, 3, kernel_size=(4, 4), stride=(2, 2), padding=(1, 1))
    (5): Sigmoid()
  )
)
Total parameters: 156,259
```

Output tersebut menunjukkan arsitektur *Enhancement Autoencoder* yang digunakan dalam proses *CNN-Based Enhancement*. Model terdiri atas bagian *encoder* dan *decoder*. Bagian *encoder* menggunakan tiga lapisan *Conv2d* yang disertai fungsi aktivasi *ReLU* dan *MaxPool2d*, sedangkan bagian *decoder* menggunakan tiga lapisan *ConvTranspose2d* yang disertai fungsi aktivasi *ReLU* dan *Sigmoid*. Arsitektur tersebut memiliki total 156.259 parameter dan digunakan untuk mempelajari serta merekonstruksi karakteristik visual citra tanaman kelapa sawit. Hasil proses tersebut selanjutnya digunakan untuk membantu memperjelas informasi visual sebelum citra masuk ke proses klasifikasi. Proses tersebut digunakan untuk meningkatkan struktur, ketajaman, detail tekstur, dan representasi pola objek pada citra tanaman kelapa sawit. Hasil peningkatan berbasis CNN menunjukkan bahwa informasi visual yang sebelumnya kurang jelas dapat direkonstruksi dengan lebih baik. Peningkatan tersebut digunakan untuk membantu proses pengenalan pola yang berkaitan dengan kondisi tanaman *Healthy*, *Infected*, dan *Initial Infection*. Selanjutnya, citra hasil *enhancement* digunakan dalam proses klasifikasi untuk mengetahui kemampuan model dalam membedakan ketiga kelas tersebut.

MODEL EVALUATION									
TRAIN SET									
Loss: 0.3024 Accuracy: 0.9329									
CLASSIFICATION REPORT (Train)									
	precision	recall	f1-score	support					
Healthy	0.9370	0.9370	0.9370	127					
Infected	0.9163	0.9674	0.9412	215					
Initial Infection	0.9565	0.8800	0.9167	150					
accuracy	0.9329			492					
macro avg	0.9366	0.9281	0.9316	492					
weighted avg	0.9339	0.9329	0.9326	492					
DETAILED METRICS (Train): precision, sensitivity, specificity, fpr, fnr, f1-score, pwc, accuracy, support									

class	precision	sensitivity	specificity	fpr	fnr	f1-score	pwc	accuracy	support
Healthy	0.9370	0.9370	0.9781	0.0219	0.0630	0.9370	3.2520	0.9675	127
Infected	0.9163	0.9674	0.9314	0.0686	0.0326	0.9412	5.2846	0.9472	215
Initial Infection	0.9565	0.8800	0.9825	0.0175	0.1200	0.9167	4.8780	0.9512	150

Output evaluasi pada data *training* menunjukkan bahwa model memperoleh *loss* sebesar 0,3024 dan *accuracy* sebesar 0,9329. Berdasarkan *classification report*, kelas *Healthy* memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,9370. Kelas *Infected* memperoleh *precision* sebesar 0,9163, *recall* sebesar 0,9674, dan *F1-score* sebesar 0,9412. Sementara itu, kelas *Initial Infection* memperoleh *precision* sebesar 0,9565, *recall* sebesar 0,8800, dan *F1-score* sebesar 0,9167. Pada *detailed metrics*, kelas *Healthy* memiliki *sensitivity* sebesar 0,9370 dan *specificity* sebesar 0,9781, dengan *false positive rate* (FPR) sebesar 0,0219 dan *false negative rate* (FNR) sebesar 0,0630. Kelas *Infected* memiliki *sensitivity* sebesar 0,9674 dan *specificity* sebesar 0,9314, dengan FPR sebesar 0,0686 dan FNR sebesar 0,0326. Sementara itu, kelas *Initial Infection* memiliki *sensitivity* sebesar 0,8800 dan *specificity* sebesar 0,9825, dengan FPR sebesar 0,0175 dan FNR sebesar 0,1200. Hasil tersebut menunjukkan bahwa model memberikan performa yang tinggi pada data *training*, meskipun kemampuan mengenali kelas *Initial Infection* berdasarkan nilai *sensitivity* masih lebih rendah dibandingkan kelas lainnya. Selain melihat nilai *loss* dan akurasi, analisis performa model pada tahap *training* juga perlu dilakukan secara lebih detail menggunakan *confusion matrix*. *Confusion matrix* menggambarkan hasil prediksi model dalam bentuk matriks yang membandingkan kelas aktual (*ground truth*) dengan kelas prediksi. Dengan demikian, kita dapat mengetahui berapa banyak data dari tiap kelas yang berhasil diprediksi dengan benar, sekaligus melihat pola kesalahan yang mungkin terjadi ketika model melakukan klasifikasi. Melalui *confusion matrix*, kesalahan model tidak hanya dinilai sebagai "benar" atau "salah", tetapi juga dapat dilacak pada pasangan kelas mana yang paling sering tertukar. Misalnya, apakah citra yang seharusnya masuk ke kelas *Initial Infection* lebih sering diprediksi sebagai *Infected* atau justru sebagai *Healthy*. Informasi seperti ini penting untuk memahami seberapa stabil model dalam membedakan setiap kategori, terutama pada kelas yang memiliki karakter visual yang lebih mirip. Oleh karena itu, *confusion matrix* pada data *training* digunakan untuk menilai distribusi prediksi dan memberikan gambaran yang lebih komprehensif mengenai kemampuan model sebelum dievaluasi pada data *validation* dan *testing*.




Gambar 4. Confusion Matrix (Train)

Gambar 4 menunjukkan *confusion matrix* pada data *training*. *Confusion matrix* digunakan untuk melihat distribusi hasil prediksi model terhadap masing-masing kelas. Hasil evaluasi menunjukkan bahwa model mampu memberikan performa klasifikasi yang tinggi pada data *training*, dengan tingkat akurasi sebesar 0,9329. Nilai tersebut menunjukkan bahwa sebagian besar citra pada data pelatihan dapat diklasifikasikan sesuai dengan kelasnya. Pada data *validation*, model memperoleh *loss* sebesar 0,3414 dan *accuracy* sebesar 0,9200. Kelas *Healthy* memperoleh *precision*, *recall*, dan *F1-score* sebesar 1,0000. Kelas *Infected* memperoleh *precision*, *recall*, dan *F1-score* sebesar 0,8889. Sementara itu, kelas *Initial Infection* juga memperoleh *precision*, *recall*, dan *F1-score* sebesar 0,8889.

```
Confusion matrix (Train) saved to ./results/confusion_matrix_train.png
=====
VALID SET
=====
Loss: 0.3414 | Accuracy: 0.9200
CLASSIFICATION REPORT (Valid)
      precision  recall  f1-score  support
Healthy      1.0000    1.0000    1.0000         7
Infected      0.8889    0.8889    0.8889         9
Initial Infection 0.8889    0.8889    0.8889         9
accuracy                    0.9200        25
macro avg      0.9259    0.9259    0.9259        25
weighted avg    0.9200    0.9200    0.9200        25
DETAILED METRICS (Valid): precision, sensitivity, specificity, fpr, fnr, f1-score, pwc, accuracy, support
      class precision sensitivity specificity  fpr  fnr  f1-score  pwc  accuracy  support
Healthy      1.0000      1.0000      1.0000 0.0000 0.0000      1.0000 0.0000      1.0000         7
Infected      0.8889      0.8889      0.9375 0.0625 0.1111      0.8889 8.0000      0.9200         9
Initial Infection 0.8889      0.8889      0.9375 0.0625 0.1111      0.8889 8.0000      0.9200         9
```

Pada data *validation*, model memperoleh *loss* sebesar 0,3414 dan *accuracy* sebesar 0,9200. Berdasarkan *classification report*, kelas *Healthy* memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 1,0000. Kelas *Infected* memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,8889. Sementara itu, kelas *Initial Infection* juga memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,8889. Berdasarkan *detailed metrics*, kelas *Healthy* memperoleh *sensitivity* dan *specificity* masing-masing sebesar 1,0000, dengan *false positive rate* (FPR) dan *false negative rate* (FNR) sebesar 0,0000. Kelas *Infected* memiliki *sensitivity* sebesar 0,8889 dan *specificity* sebesar 0,9375, dengan FPR sebesar 0,0625 dan FNR sebesar 0,1111. Kelas *Initial Infection* juga memiliki *sensitivity* sebesar 0,8889 dan *specificity* sebesar 0,9375, dengan FPR sebesar 0,0625 dan FNR sebesar 0,1111. Hasil evaluasi tersebut menunjukkan bahwa model memberikan kinerja yang baik pada data *validation*, meskipun jumlah data validasi hanya terdiri atas 25 citra.



Gambar 5. Confusion Matrix (Valid)

Gambar 5 menunjukkan *confusion matrix* pada data *validation*. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan data validasi dengan akurasi sebesar 0,9200. Namun, jumlah data validasi yang relatif sedikit, yaitu 25 citra, perlu dipertimbangkan dalam menginterpretasikan hasil tersebut. Keberhasilan proses peningkatan kualitas citra tidak hanya dilihat berdasarkan perubahan visual, tetapi juga berdasarkan dampaknya terhadap proses identifikasi penyakit *Ganoderma*. Hasil *enhancement* citra digunakan sebagai input dalam proses klasifikasi menggunakan CNN. Evaluasi klasifikasi dilakukan menggunakan parameter *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui kemampuan model dalam membedakan citra tanaman sehat, terinfeksi, dan mengalami infeksi awal. Model akhir yang digunakan dalam proses klasifikasi adalah *GanodermaCNN* dengan *ResNet50* sebagai *backbone*. Model menggunakan tiga kelas, yaitu *Healthy*, *Infected*, dan *Initial Infection*, dengan ukuran input citra 160×160 piksel. Model menggunakan *pretrained* dengan total 24.689.219 parameter. Konfigurasi pelatihan menggunakan *batch size* 4, jumlah *epoch* 100, *learning rate* 0,0001, optimizer AdamW, *CrossEntropyLoss*, dan *early stopping* dengan *patience* 8 *epoch*. Setelah proses peningkatan kualitas citra dan evaluasi pada data *training* serta *validation*, tahap berikutnya dilakukan untuk mengevaluasi kinerja model pada data *testing*. Model klasifikasi yang digunakan adalah *GanodermaCNN* dengan *ResNet50* sebagai *backbone*. Model ini digunakan untuk mengklasifikasikan citra ke dalam tiga kelas, yaitu *Healthy*, *Infected*, dan *Initial Infection*. Konfigurasi model meliputi ukuran input 160×160 piksel dan penggunaan model *pretrained* dengan total 24.689.219 parameter. Informasi konfigurasi dan hasil evaluasi model selanjutnya ditampilkan pada *model summary*.

MODEL SUMMARY

=====

```

model_type..... GanodermaCNN
backbone..... resnet50
num_classes..... 3
classes..... ['Healthy', 'Infected', 'Initial Infection']
image_size..... (160, 160)
pretrained..... True
test_accuracy..... 0.7714285714285715
test_loss..... 0.4165080388387044
training_date..... 2026-08-12T01:56:59.426496
total_parameters..... 24689219


```

Files saved:

- confusion_matrix.png (0.04 MB)
- confusion_matrix_test.png (0.04 MB)
- gamma_correction_demo.png (1.00 MB)
- confusion_matrix_train.png (0.04 MB)
- training_history.png (0.13 MB)
- best_model.pth (94.49 MB)
- confusion_matrix_valid.png (0.04 MB)

- model_info.json (0.00 MB)
- model_jit.pt (44.35 MB)
- model.onnx (44.14 MB)
- research_report.txt (0.00 MB)
- eda_samples.png (2.95 MB)
- enhancement_comparison.png (1.57 MB)
- batch_inference_results.csv (0.00 MB)
- inference_samples.png (3.10 MB)

Berdasarkan *model summary*, model *GanodermaCNN* menggunakan *ResNet50* sebagai *backbone* dengan tiga kelas klasifikasi dan ukuran input 160×160 piksel. Model menggunakan bobot *pretrained* dan memiliki total 24.689.219 parameter. Hasil evaluasi akhir menunjukkan bahwa model memperoleh *test accuracy* sebesar 0,7714 dan *test loss* sebesar 0,4165. Informasi tersebut menunjukkan bahwa model masih mampu melakukan klasifikasi pada data yang belum digunakan selama proses pelatihan, meskipun tingkat akurasi lebih rendah dibandingkan hasil pada data *training* dan *validation*. Selain informasi model dan hasil evaluasi, proses penelitian juga menghasilkan beberapa berkas pendukung berupa model terlatih, visualisasi, serta data hasil inferensi yang digunakan untuk analisis dan dokumentasi penelitian.



Gambar 6. Analyzing Enhancement Impact

Gambar 6 menunjukkan analisis dampak *enhancement* terhadap citra yang digunakan dalam proses klasifikasi. *Gamma Correction* diterapkan sebagai tahap awal untuk memperbaiki intensitas cahaya dengan variasi gamma 0,8, 1,0, dan 1,2. Selanjutnya, *CNN-Based Enhancement* digunakan untuk meningkatkan kualitas visual berdasarkan pola yang dipelajari oleh model. Hasil *enhancement* kemudian digunakan sebagai input pada proses klasifikasi. Selain menghasilkan model klasifikasi, penelitian ini juga menghasilkan beberapa keluaran yang mendukung proses analisis dan dokumentasi penelitian.

Berdasarkan hasil *report*, dataset yang digunakan berjumlah 552 citra, sedangkan kelas terdiri atas 144 citra *Healthy*, 236 citra *Infected*, dan 172 citra *Initial Infection*. Proses peningkatan citra menggunakan *Gamma Correction* dengan gamma 0,8, 1,0, dan 1,2, *Convolutional Autoencoder Enhancement*, serta *data augmentation* berupa *flip*, *rotate*, dan perubahan *brightness-contrast*. Model klasifikasi menggunakan *ResNet50 pretrained* sebagai *backbone* dengan tiga kelas dan ukuran input 160×160 piksel. Model memiliki total 24.689.219 parameter. Konfigurasi pelatihan menggunakan *batch size* 4, *epoch* maksimum 100, *learning rate* 0,0001, optimizer AdamW, *CrossEntropyLoss*, serta *early stopping* dengan *patience* 8 *epoch*. Output penelitian juga mencakup *best_model.pth* sebagai model PyTorch terlatih, *model_jit.pt* sebagai model TorchScript, dan *model.onnx* sebagai model dalam format ONNX. Selain itu, dihasilkan beberapa visualisasi, yaitu *eda_samples.png* untuk sampel citra setiap kelas, *gamma_correction_demo.png* untuk menunjukkan efek *Gamma Correction*, *training_history.png* untuk melihat riwayat pelatihan, serta *confusion_matrix_train.png*, *confusion_matrix_valid.png*, dan *confusion_matrix_test.png* untuk melihat hasil klasifikasi pada setiap pembagian dataset. Output lainnya berupa *inference_samples.png*, *enhancement_comparison.png*, *batch_inference_results.csv*, dan *model_info.json* yang digunakan untuk mendukung analisis hasil, prediksi, dan penyimpanan informasi model. Berdasarkan hasil pengujian pada data *testing*, model memperoleh *test accuracy* sebesar 0,7714 dan *test loss* sebesar 0,4165. Kelas *Healthy* memperoleh *precision* sebesar 0,8182, *recall* sebesar 0,9000, dan *F1-score* sebesar 0,8571. Kelas *Infected* memperoleh *precision* sebesar 0,7500, *recall* sebesar 0,7500, dan *F1-score* sebesar 0,7500. Sementara itu, kelas *Initial Infection* memperoleh *precision* sebesar 0,7500, *recall* sebesar 0,6923, dan *F1-score* sebesar 0,7200. Hasil tersebut menunjukkan bahwa model memiliki kemampuan dalam membedakan tiga kondisi

tanaman kelapa sawit. Kelas *Healthy* memperoleh nilai *recall* paling tinggi, yaitu 0,9000, sedangkan kelas *Initial Infection* memiliki nilai *recall* paling rendah, yaitu 0,6923. Kondisi tersebut menunjukkan bahwa identifikasi infeksi awal masih menjadi tantangan dalam proses klasifikasi karena karakteristik visualnya relatif lebih sulit dibedakan oleh model.

4.2 Pembahasan

Berdasarkan hasil penelitian, penerapan *Gamma Correction* dan *CNN-Based Enhancement* menggunakan *autoencoder* memberikan pendekatan bertahap dalam meningkatkan kualitas citra tanaman kelapa sawit sebelum dilakukan klasifikasi penyakit *Ganoderma*. *Gamma Correction* digunakan untuk menyesuaikan tingkat kecerahan citra, sedangkan *CNN-Based Enhancement* memanfaatkan *autoencoder* untuk mempelajari representasi dan melakukan rekonstruksi citra. Pendekatan tersebut memungkinkan proses peningkatan kualitas citra dilakukan berdasarkan karakteristik visual yang dipelajari oleh model, sehingga informasi berupa struktur, tekstur, dan pola pada citra dapat dipertahankan selama proses rekonstruksi. Hasil evaluasi menunjukkan bahwa model klasifikasi memperoleh *accuracy* sebesar 0,9329 pada data *training* dengan *loss* sebesar 0,3024. Nilai tersebut menunjukkan bahwa model mampu mempelajari pola dari data pelatihan dengan baik. Berdasarkan *classification report*, kelas *Healthy* memperoleh *precision*, *recall*, dan *F1-score* sebesar 0,9370. Kelas *Infected* menghasilkan *precision* sebesar 0,9163, *recall* sebesar 0,9674, dan *F1-score* sebesar 0,9412, sedangkan kelas *Initial Infection* memperoleh *precision* sebesar 0,9565, *recall* sebesar 0,8800, dan *F1-score* sebesar 0,9167. Nilai *recall* yang lebih tinggi pada kelas *Infected* menunjukkan bahwa model relatif baik dalam mengenali citra yang termasuk dalam kategori terinfeksi. Sebaliknya, nilai *sensitivity* kelas *Initial Infection* sebesar 0,8800 dan FNR sebesar 0,1200 menunjukkan bahwa sebagian citra infeksi awal masih berpotensi tidak dikenali oleh model. Pada data *validation*, model memperoleh *accuracy* sebesar 0,9200 dengan *loss* sebesar 0,3414. Kelas *Healthy* memperoleh nilai *precision*, *recall*, dan *F1-score* sebesar 1,0000, sedangkan kelas *Infected* dan *Initial Infection* masing-masing memperoleh nilai sebesar 0,8889. Hasil ini menunjukkan bahwa model tetap mampu mempertahankan kinerja yang baik ketika digunakan pada data validasi. Namun, interpretasi hasil validasi perlu dilakukan secara hati-hati karena jumlah data validasi hanya 25 citra. Dengan jumlah data yang relatif kecil, perubahan prediksi pada beberapa citra saja dapat memberikan pengaruh yang cukup besar terhadap nilai metrik yang diperoleh. Perbandingan antara hasil *training* dan *validation* menunjukkan bahwa perbedaan akurasi relatif kecil, yaitu 0,9329 pada *training* dan 0,9200 pada *validation*. Kondisi tersebut menunjukkan bahwa model tidak mengalami penurunan performa yang besar ketika diterapkan pada data validasi. Meskipun demikian, hasil tersebut belum cukup untuk menyatakan kemampuan generalisasi model secara kuat karena jumlah data validasi dan keseluruhan dataset masih terbatas. Evaluasi pada data *testing* menjadi bagian yang lebih penting untuk melihat kemampuan model terhadap data yang tidak digunakan dalam proses pembelajaran maupun validasi.

Hasil pengujian pada data *testing* menunjukkan bahwa model memperoleh *accuracy* sebesar 0,7714 dengan *loss* sebesar 0,4165. Nilai tersebut lebih rendah dibandingkan *accuracy* pada data *training* sebesar 0,9329 dan *validation* sebesar 0,9200. Penurunan performa tersebut menunjukkan bahwa kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah digunakan selama proses pelatihan masih terbatas. Salah satu hal yang perlu diperhatikan adalah ukuran dataset yang relatif kecil, yaitu 552 citra, serta distribusi data yang berbeda antar kelas. Selain itu, karakteristik visual antara kelas *Healthy*, *Infected*, dan terutama *Initial Infection* dapat memiliki kemiripan sehingga meningkatkan kesulitan model dalam membedakan setiap kelas. Berdasarkan hasil per kelas pada data *testing*, kelas *Healthy* memberikan performa terbaik dengan *precision* sebesar 0,8182, *recall* sebesar 0,9000, dan *F1-score* sebesar 0,8571. Kelas *Infected* memperoleh *precision*, *recall*, dan *F1-score* sebesar 0,7500. Sementara itu, kelas *Initial Infection* memperoleh *precision* sebesar 0,7500, *recall* sebesar 0,6923, dan *F1-score* sebesar 0,7200. Rendahnya *recall* pada kelas *Initial Infection* menunjukkan bahwa identifikasi infeksi pada tahap awal merupakan bagian yang masih sulit bagi model. Kondisi tersebut penting karena kesalahan dalam mengenali infeksi awal dapat menyebabkan citra yang sebenarnya menunjukkan gejala awal dikategorikan sebagai kelas lain. Hasil tersebut menunjukkan bahwa keberhasilan sistem tidak cukup dinilai hanya berdasarkan perubahan visual setelah proses *enhancement*, tetapi juga perlu dilihat dari kemampuan model dalam mempertahankan informasi yang relevan untuk klasifikasi. *Gamma Correction* membantu mengatasi variasi intensitas pencahayaan, sedangkan *CNN-Based Enhancement* dengan *autoencoder* digunakan untuk melakukan rekonstruksi berdasarkan representasi fitur yang dipelajari. Dengan demikian, kedua tahap tersebut berperan sebagai bagian dari rangkaian *preprocessing* yang menghasilkan citra untuk proses klasifikasi menggunakan *GanodermaCNN* dengan *ResNet50* sebagai *backbone*. Temuan penelitian juga menunjukkan bahwa proses *enhancement* menghasilkan keluaran yang dapat digunakan untuk mendukung

analisis visual, seperti perbandingan citra sebelum dan sesudah peningkatan kualitas. Namun, berdasarkan hasil pengujian akhir yang memperoleh *accuracy* sebesar 77,14%, peningkatan kualitas citra belum dapat dipastikan secara kuantitatif sebagai satu-satunya faktor yang menyebabkan peningkatan kemampuan klasifikasi. Oleh karena itu, hasil *enhancement* perlu dipandang sebagai bagian dari keseluruhan pipeline pengolahan citra, sedangkan keberhasilan klasifikasi dipengaruhi oleh kombinasi kualitas data, proses *preprocessing*, *data augmentation*, arsitektur model, serta konfigurasi pelatihan. Secara keseluruhan, hasil penelitian menunjukkan bahwa kombinasi *Gamma Correction* dan *CNN-Based Enhancement* dapat digunakan sebagai pendekatan untuk pengolahan citra tanaman kelapa sawit yang berkaitan dengan penyakit *Ganoderma*. Model mampu memberikan performa yang baik pada data *training* dan *validation*, tetapi performanya menurun pada data *testing*. Hal ini menunjukkan bahwa masih terdapat ruang untuk meningkatkan kemampuan generalisasi model, khususnya dalam mengenali kelas *Initial Infection*. Pengembangan selanjutnya dapat diarahkan pada penambahan dan diversifikasi dataset, peningkatan kualitas anotasi, serta evaluasi *enhancement* menggunakan metrik kualitas citra yang bersifat objektif agar hubungan antara peningkatan kualitas citra dan kinerja klasifikasi dapat dianalisis secara lebih terukur.

4. Kesimpulan

Penerapan teknik transformasi citra melalui *Gamma Correction* dan *CNN-Based Enhancement* digunakan untuk meningkatkan kualitas citra tanaman kelapa sawit yang digunakan dalam proses identifikasi penyakit *Ganoderma*. *Gamma Correction* diterapkan untuk menyesuaikan pencahayaan dan intensitas citra, sedangkan *CNN-Based Enhancement* menggunakan pendekatan *autoencoder* untuk mempelajari dan merekonstruksi karakteristik visual citra. Proses peningkatan citra tersebut kemudian digunakan sebagai bagian dari tahapan klasifikasi menggunakan model *GanodermaCNN* dengan *ResNet50* sebagai *backbone*. Berdasarkan hasil evaluasi, model memperoleh *test accuracy* sebesar 0,7714 dan *test loss* sebesar 0,4165. Pada tingkat kelas, *Healthy* memperoleh *precision* sebesar 0,8182, *recall* sebesar 0,9000, dan *F1-score* sebesar 0,8571. Kelas *Infected* memperoleh *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,7500. Sementara itu, kelas *Initial Infection* memperoleh *precision* sebesar 0,7500, *recall* sebesar 0,6923, dan *F1-score* sebesar 0,7200. Hasil tersebut menunjukkan bahwa model mampu membedakan tiga kondisi tanaman kelapa sawit, dengan kemampuan pengenalan kelas *Healthy* yang paling baik, sedangkan kelas *Initial Infection* masih menjadi kelas yang paling sulit dikenali. Hasil evaluasi juga menunjukkan adanya perbedaan performa antara data *training*, *validation*, dan *testing*. Model memperoleh *accuracy* sebesar 0,9329 pada data *training* dan 0,9200 pada data *validation*, sedangkan *test accuracy* sebesar 0,7714. Perbedaan tersebut menunjukkan bahwa performa model pada data *testing* masih lebih rendah dibandingkan data *training* dan *validation*. Oleh karena itu, hasil penelitian menunjukkan bahwa pendekatan *image enhancement* dan klasifikasi berbasis CNN dapat digunakan sebagai salah satu pendekatan dalam pengembangan sistem identifikasi penyakit *Ganoderma*, tetapi masih diperlukan pengembangan dan pengujian lebih lanjut untuk meningkatkan kemampuan generalisasi model, khususnya dalam mengenali kondisi *Initial Infection*. Pengembangan selanjutnya dapat dilakukan dengan menambah jumlah dan keragaman dataset, khususnya citra *Initial Infection*, serta melakukan pengujian pada citra dengan kondisi pencahayaan dan lingkungan lapangan yang lebih beragam. Selain itu, penelitian berikutnya dapat membandingkan performa model sebelum dan sesudah penerapan *Gamma Correction* dan *CNN-Based Enhancement* secara kuantitatif untuk mengetahui kontribusi masing-masing teknik terhadap peningkatan performa klasifikasi.

Referensi

- Abdillah, M. H., Rahmawati, L., Lukmana, M., & Zakiah, N. (2025). Identifikasi penyakit dominan kelapa sawit menggunakan pendekatan visual pada tanaman belum menghasilkan, tanaman menghasilkan, serta pengendaliannya yang bisa dilakukan di perkebunan PT. XY. *Jurnal Hama dan Penyakit Tumbuhan*, 13(1), 1–17. <https://doi.org/10.21776/ub.jurnalhpt.2025.013.1.1>
- Anindyati, L., Utama, A. W., Arifin, K. Q., P., R. A., & Fariz, A. (2025). Visualizing data palm oil plantation in Indonesia: Interactive map prototype. *Jurnal Teknologi*, 17(1), 1–12.

- Dutta, M., Islam Sujan, M. R., Mojumdar, M. U., Chakraborty, N. R., Marouf, A. A., Rokne, J. G., & Alhaji, R. (2024). Rice leaf disease classification—A comparative approach using convolutional neural network (CNN), cascading autoencoder with attention residual U-Net (CAAR-U-Net), and MobileNet-V2 architectures. *Technologies*, 12(11), 214. <https://doi.org/10.3390/technologies12110214>
- Gopikrishna, P. B., Devika, M. M., & Rubell Marion Lincy, G. (2026). A comparative study on the performance of deep learning-based denoising models for noisy plant disease images. In *2026 IEEE International Conference on Emerging Computing and Intelligent Technologies (ICoECIT)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICoECIT68303.2026.11497055>
- Kaur, B., Gupta, S. K., Janarthan, M., Alsekait, D. M., & AbdElminaam, D. S. (2025). Precision diagnosis of citrus leaf diseases using image enhancement and nonlinear fuzzy ranking ensemble approach NLFuRBe. *Scientific Reports*, 15(1), 32296. <https://doi.org/10.1038/s41598-025-16923-4>
- Mandiri, T. P., Dharmawan, B. B., Ibn, F. S., & Untoro, M. C. (2025). Identifikasi penyakit pada daun kelapa sawit dengan pendekatan CNN AlexNet. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(3), 781–788. <https://doi.org/10.30591/jpit.v10i3.8456>
- Sabrina, T., Wahyuni, M., Mukhlis, M., & Santoso, H. (2022). Aplikasi support vector machine pada deteksi penyakit busuk pangkal batang Ganoderma tanaman kelapa sawit. *Prosiding Seminar Nasional INSTIPER*, 1(1), 105–115. <https://doi.org/10.55180/pro.v1i1.247>
- Santoso, H. (2020). Pengamatan dan pemetaan penyakit busuk pangkal batang di perkebunan kelapa sawit menggunakan unmanned aerial vehicle (UAV) dan kamera multispektral. *Jurnal Fitopatologi Indonesia*, 16(2), 69–80. <https://doi.org/10.14692/jfi.16.2.69-80>
- Saeedi, J., & Giusti, A. (2023). Semi-supervised visual anomaly detection based on convolutional autoencoder and transfer learning. *Machine Learning with Applications*, 11, 100451. <https://doi.org/10.1016/j.mlwa.2023.100451>
- Sungai, K., Divisi, D., Sumber, I. P. T., & Agung, T. (2024). Kajian serangan penyakit busuk pangkal batang (*Ganoderma boninense*) terhadap produktivitas tanaman kelapa sawit (*Elaeis guineensis* Jacq.) di Kebun Sungai Dua Divisi I PT. Sumber Tani Agung Resources. *Prosiding Seminar Nasional Pembangunan dan Pendidikan Vokasi Pertanian*, 5(1), 1489–1507.
- Suwaroyo, N., Koniasari, K., & Basri, A. (2025). Tongue detection for identification of syndrome diagnosis in heart disease using convolutional neural network. *Tech-E*, 8(2). <https://doi.org/10.31253/te.v8i2.3285>
- Syafira, R., Nasution, Z., & Charloq. (2024). Analisis kendala program peremajaan sawit rakyat (PSR) terhadap potensi pertumbuhan ekonomi petani sawit rakyat. *Jurnal Ilmiah Global Education*, 5(1), 431–441. <https://doi.org/10.55681/jige.v5i1.2469>

How Cites

Aditya, A., Amanda, A., & Gustiningsih, D. (2026). Penerapan Teknik Transformasi untuk Meningkatkan Kualitas Citra Penyakit Ganoderma pada Tanaman Kelapa Sawit Menggunakan CNN-Based Enhancement dan Gamma Correction. *Computer Journal*, 4(2), 257–268. <https://doi.org/10.58477/cj.v4i2.499>.

Publisher's Note

Yayasan Pendidikan Mitra Mandiri Aceh (YPPMA) remains neutral with regard to jurisdictional claims in published maps and institutional affiliations. Submit your manuscript to YPMMA Journal and *benefit* from: <https://journal.ypmma.org/index.php/cj>.