

ANALISIS KORELASI RESTORASI VISUAL DAN PERFORMA KLASIFIKASI
METODE IMAGE SHARPENING PADA DAUN TOMATMuhamad Agil Fadila¹, Bambang Irawan², Ahmad Faqih³, Raditnya Danar Dana⁴, Adi Rizki Renaldi⁵.Program Studi Teknik Informatika¹²³
Program Studi Manajemen Informasi⁴
Program Studi Rekayasa Perangkat Lunak⁵STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
muhamadagilf111@gmail.com(*) Corresponding Author : muhamadagilf111@gmail.com
Published : 30 Januari 2026

Abstract—Low image quality poses a significant challenge in automated plant disease detection based on Deep Learning. This study aims to analyze the correlation between objective visual restoration and CNN classification performance through the application of image sharpening methods on tomato leaf images. Three methods were tested: Basic Sharpening Kernel (BSK), Unsharp Masking (USM), and High Boost Filtering (HBF) on the MobileNetV2 architecture using a transfer learning approach. Evaluation was conducted using two perspectives: image quality metrics (Peak Signal-to-Noise Ratio/PSNR and Structural Similarity Index Measure/SSIM) and model performance metrics (Accuracy and Loss). The results revealed an anomalous finding of a negative correlation between visual quality and model accuracy. The HBF method recorded the best visual restoration (PSNR 35.36 dB) but yielded the lowest accuracy (97.73%). Conversely, USM, with the lowest visual restoration, achieved the highest accuracy of 98.95%, followed by BSK at 98.78%, which offered the best model stability with the lowest loss value (0.0348). These findings demonstrate that standard visual metrics (PSNR/SSIM) cannot serve as sole predictors for CNN classification performance, where sharpening artifacts produced by USM effectively highlight disease features for the model.

Keywords: Image Sharpening, PSNR, SSIM, Classification Performance, Negative Correlation, MobileNetV2, Plant Disease Detection.

Abstrak-Kualitas citra yang rendah sering menjadi hambatan signifikan dalam deteksi otomatis penyakit tanaman berbasis Deep Learning. Penelitian ini bertujuan untuk menganalisis korelasi antara restorasi visual objektif dan performa klasifikasi model CNN melalui penerapan metode image sharpening pada citra daun tomat. Tiga metode diuji: Basic Sharpening Kernel (BSK), Unsharp Masking (USM), dan High Boost Filtering (HBF) pada arsitektur MobileNetV2 dengan pendekatan transfer learning. Evaluasi dilakukan menggunakan dua perspektif: metrik kualitas citra (Peak Signal-to-Noise Ratio/PSNR dan Structural Similarity Index Measure/SSIM) serta metrik performa model (Akurasi dan Loss). Hasil penelitian mengungkapkan temuan anomali berupa korelasi negatif antara kualitas visual dan akurasi model. Metode HBF mencatat restorasi visual terbaik (PSNR 35.36) namun menghasilkan akurasi terendah (97.73%). Sebaliknya, USM dengan restorasi visual terendah justru mencapai akurasi tertinggi sebesar 98.95%, diikuti oleh BSK sebesar 98.78% yang menawarkan stabilitas model terbaik dengan nilai loss terendah (0.0348). Temuan ini membuktikan bahwa metrik visual standar (PSNR/SSIM) tidak dapat dijadikan prediktor tunggal untuk performa klasifikasi CNN, di mana artefak penajaman yang dihasilkan USM justru memperjelas fitur penyakit bagi model.

Kata kunci: Penajaman Citra, PSNR, SSIM, Performa Klasifikasi, Korelasi Negatif, MobileNetV2, Deteksi Penyakit Tanaman.

INTRODUCTION

Penerapan computer vision dan deep learning telah menjadi standar dalam pengembangan sistem deteksi penyakit tanaman untuk mendukung pertanian presisi, yang kian diadopsi untuk mengatasi berbagai tantangan tradisional, seperti deteksi dini patogen tanaman, identifikasi gulma,

dan pemantauan kondisi pertumbuhan vegetasi. Arsitektur Convolutional Neural Network (CNN) terbukti sangat efektif untuk tugas klasifikasi citra, namun kinerjanya sangat bergantung pada kualitas data masukan (Ferentinos & Ferentinos, 2020). Di lapangan, akuisisi citra daun sering menghadapi tantangan, menghasilkan gambar dengan kualitas

yang kurang optimal seperti buram (*blur*), kontras rendah, atau resolusi rendah [1]. Kualitas citra yang buruk ini secara langsung menghambat proses ekstraksi fitur oleh *CNN*, karena detail krusial seperti tekstur lesi atau tepian daun menjadi kabur.

Sejumlah penelitian telah dilakukan dalam lima tahun terakhir untuk mengatasi tantangan deteksi penyakit tanaman menggunakan *Deep Learning* dan pengolahan citra. Penelitian ([2]) berhasil mencapai akurasi sempurna pada dataset tanaman kapulaga menggunakan arsitektur *EfficientNetV2*, namun penelitian tersebut berfokus pada arsitektur model tanpa menekankan pada perbaikan kualitas citra input. Penelitian [3] membuktikan bahwa pendekatan *transfer learning* menggunakan kombinasi *ResNet50* dan *MobileNetV2* sangat efektif untuk klasifikasi penyakit daun tomat, namun studi ini juga belum mengeksplorasi dampak teknik restorasi visual spesifik. Penelitian [4] mengkonfirmasi bahwa penerapan teknik prapemrosesan, seperti reduksi *noise*, secara signifikan dapat meningkatkan akurasi *CNN* hingga 4,17% pada studi kasus pengenalan wajah, membuka peluang penerapan serupa pada citra tanaman.

Secara spesifik terkait teknik peningkatan citra, Penelitian [5] menemukan bahwa kombinasi *Contrast Limited Adaptive Histogram Equalization (CLAHE)* dengan *image sharpening* mampu menghasilkan akurasi rata-rata 97,69% pada arsitektur *ResNet-50* untuk deteksi penyakit tanaman. Temuan ini mendukung hipotesis bahwa penajaman citra bermanfaat. Namun, terdapat kontradiksi dalam literatur, di mana Penelitian [6] justru melaporkan bahwa teknik *image sharpening* menurunkan performa model pada dataset mikroskop karena variabilitas sampel yang besar, dan menyarankan untuk menghindari teknik tersebut pada kondisi tertentu.

Berdasarkan tinjauan literatur di atas, teridentifikasi kesenjangan penelitian yang signifikan. Mayoritas studi cenderung berfokus pada perbaikan kontras (seperti *CLAHE*) atau modifikasi arsitektur model. Studi yang secara spesifik mengisolasi dan membandingkan efektivitas berbagai metode *image sharpening* (seperti *Basic Sharpening Kernel*, *Unsharp Masking*, dan *High Boost Filtering*) masih terbatas. Selain itu, adanya temuan kontradiktif antara [7] menunjukkan perlunya investigasi lebih lanjut mengenai jenis filter penajaman yang tepat. Belum ada studi komparatif yang secara sistematis mengukur korelasi antara dampak restorasi visual

objektif (menggunakan metrik *PSNR* dan *SSIM*) dengan dampak aktualnya terhadap performa model klasifikasi pada citra daun tomat yang terdegradasi.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan menganalisis efektivitas tiga metode *image sharpening* (*Basic Sharpening Kernel*, *Unsharp Masking*, dan *High Boost Filtering*) pada citra daun tomat. Penelitian ini akan mengevaluasi apakah peningkatan kualitas visual secara matematis (*PSNR/SSIM*) berkorelasi lurus dengan peningkatan akurasi model *MobileNetV2*, serta memberikan rekomendasi metode prapemrosesan yang paling optimal untuk mengatasi citra berkualitas rendah.

MATERIALS AND METHODS

Penelitian ini menerapkan pendekatan eksperimental kuantitatif untuk mengevaluasi efektivitas teknik *image sharpening* terhadap performa klasifikasi penyakit tanaman. Objek penelitian adalah citra daun tomat dari dataset *PlantVillage* yang bersumber dari platform dataset publik, *kaggle*. Dengan tiga kategori kelas: *Tomato_leaf_blight*, *Tomato_septoria_spot*, dan *Tomato_healthy*.

Persiapan Data

Sebelum pemrosesan, citra diubah ukurannya (*resize*) menjadi 224 x 224 piksel untuk menjaga konsistensi input sesuai standar arsitektur *CNN*, dan dinormalisasi ke ruang warna *RGB* [8], [9]. Untuk mengatasi ketidakseimbangan kelas dan meningkatkan generalisasi model, teknik augmentasi data diterapkan meliputi *horizontal flip* dan *random zoom*, sebagaimana disarankan dalam studi penanganan data pertanian terbatas [10].

Simulasi Degradasi Citra (*Downsampling*)

Untuk mensimulasikan kondisi lapangan nyata di mana kualitas akuisisi citra sering kali rendah, dilakukan proses *downsampling* (Liu et al., 2022). Citra asli $I(x, y)$ diturunkan resolusinya menjadi setengah 112 x 112, kemudian dikembalikan ke ukuran semula (224 x 224) menggunakan interpolasi bilinear. Pendekatan simulasi resolusi rendah ini digunakan untuk menguji ketahanan algoritma pemrosesan citra terhadap degradasi visual. Proses ini direpresentasikan sebagai:

$$I_{deg}(x, y) = D \left(I_{orig}(x, y) \right) \uparrow_2 \downarrow_2 \quad (1)$$

Di mana I_{deg} adalah citra terdegradasi (*low resolution*) dan $\uparrow_2 \downarrow_2$ merepresentasikan operasi penurunan dan peningkatan skala spasial.

Penerapan Metode Image Sharpening

Citra hasil downsampling diproses menggunakan tiga metode sharpening berbeda untuk memulihkan detail tepi dan tekstur, yang krusial untuk identifikasi gejala penyakit (Pradhan et al., 2023).

Basic Sharpening Kernel (BSK)

Metode ini menggunakan operasi konvolusi spasial dengan *kernel Laplacian* yang dimodifikasi. Teknik ini dipilih karena efektivitasnya dalam menonjolkan diskontinuitas intensitas (tepi) pada citra resolusi rendah (Zhou et al., 2021). Operasi penajaman didefinisikan sebagai:

$$g(x, y) = f(x, y) * H_{BSK} \quad (2)$$

$$H_{BSK} = [0 \ -1 \ 0 \ -1 \ 5 \ -1 \ 0 \ -1 \ 0] \quad (3)$$

Unsharp Masking (USM)

Metode *USM* bekerja dengan mengurangi versi buram dari citra asli untuk mendapatkan "masker" detail frekuensi tinggi. Metode ini terbukti efektif mempertahankan struktur asli gambar sambil menekankan pola penyakit yang bersifat lokal (Patil et al., 2020).

$$G_{mask}(x, y) = f(x, y) - f_{blur}(x, y) \quad (4)$$

$$G_{usm}(x, y) = f(x, y) + k \cdot G_{mask}(x, y) \quad (5)$$

Dimana f_{blur} dihasilkan menggunakan *GaussianBlur* dan k ditetapkan sebesar 1.7.

High Boost Filtering (HBF)

Metode *HBF* merupakan varian agresif yang menggunakan faktor amplifikasi tinggi pada piksel pusat. Teknik ini diadopsi untuk kemampuannya memperjelas fitur-fitur kecil atau kabur yang sering terdapat pada gejala awal penyakit. Kernel yang digunakan adalah:

$$H_{HBF} = \begin{bmatrix} -1 & -1 & -1 & -1 & 9 & -1 & -1 & -1 \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \\ & & & & & & & \end{bmatrix} \quad (6)$$

Arsitektur Model dan Pelatihan

Klasifikasi dilakukan menggunakan arsitektur *MobileNetV2* dengan pendekatan *transfer learning*. Arsitektur ini dipilih karena efisiensinya yang tinggi

untuk aplikasi pertanian berbasis *mobile* atau *edge computing*. Pemanfaatan bobot pralatih (*ImageNet*) bertujuan untuk mempercepat konvergensi model pada dataset penyakit tanaman yang terbatas.

Fungsi kerugian (*loss function*) yang digunakan adalah *Categorical Crossentropy*:

$$Loss = - \sum_{c=1}^M y_{o,c} \log(p_{o,c}) \quad (7)$$

Evaluasi Kinerja

Evaluasi dilakukan melalui dua pendekatan untuk memvalidasi dampak teknis dan praktis, yaitu Evaluasi Kualitas Citra (Objektif) dan Evaluasi Performa Model.

Evaluasi Kualitas Citra (Objektif)

Pendekatan ini mengukur dampak filter sharpening pada level citra. Berdasarkan rencana penelitian, evaluasi ini bukan mengukur restorasi ke gambar asli, melainkan mengukur seberapa besar perubahan matematis yang dihasilkan oleh filter sharpening jika dibandingkan dengan citra Baseline (buram). Metrik yang digunakan adalah Peak Signal-to-Noise Ratio (PSNR) dan Structural Similarity Index Measure (SSIM). Nilai PSNR/SSIM yang rendah dalam konteks ini mengindikasikan filter yang agresif (banyak mengubah), sedangkan nilai tinggi mengindikasikan filter yang konservatif (sedikit mengubah).

Peak Signal-to-Noise Ratio (PSNR)

Metrik yang mengukur rasio antara daya maksimum sinyal (citra) dan daya noise (distorsi). Nilai PSNR yang lebih tinggi (umumnya) menunjukkan kualitas restorasi yang lebih baik. Perhitungan Nilai PSNR dirumuskan sebagai berikut:

Langkah awal, mengukur rata-rata kuadrat perbedaan antara citra referensi dan citra uji.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y^{\wedge}_i)^2 \quad (8)$$

Lalu gunakan hasil nilai *MSE* untuk mendapatkan nilai *PSNR*.

$$PSNR = 20 \cdot \log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right) \quad (9)$$

a. *Structural Similarity Index Measure (SSIM)*

Metrik yang lebih sesuai dengan persepsi visual manusia, mengukur kesamaan dalam tiga komponen: luminansi, kontras, dan struktur. Nilai *SSIM* berkisar antara -1 hingga 1, di mana 1 berarti identik secara struktural.

Evaluasi Performa Model

Pendekatan ini mengukur dampak turunan (downstream) dari setiap skenario data terhadap tugas utama, yaitu klasifikasi. Metrik yang digunakan adalah Akurasi dan *Loss* pada data uji.

a. *Accuracy*

Metrik paling umum, untuk mengukur rasio prediksi yang benar terhadap total data uji.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

b. *Loss*

Fungsi kerugian yang mengukur "jarak" antara distribusi probabilitas yang diprediksi model dan distribusi target aktual. Nilai *loss* yang lebih rendah menunjukkan model yang lebih "yakin" dan akurat dalam prediksinya.

$$Loss = - \sum_{i=1}^n y_i \cdot \log(y^{\wedge}_i) \quad (11)$$

Analisis Korelasi

Tahap analisis akhir adalah Analisis Korelasi Konflik. Pada tahap ini, peringkat metode berdasarkan Evaluasi Restorasi Visual (peringkat PSNR/SSIM) dibandingkan secara langsung dengan peringkat metode berdasarkan Evaluasi Performa Model (peringkat Akurasi/Loss) untuk mengidentifikasi adanya korelasi negatif atau "konflik".


RESULTS AND DISCUSSION

Bagian ini menyajikan hasil eksperimen komprehensif yang mencakup dampak visual teknik sharpening dan pengaruhnya terhadap performa model klasifikasi. Evaluasi dibagi menjadi tiga segmen utama: hasil restorasi


visual objektif, hasil performa model, dan analisis korelasi antara kedua metrik tersebut.

3.1. Hasil Persiapan Data

Bagian yang memaparkan hasil dan pembahasan dari tahap persiapan data. Tahap yang meliputi pembacaan data citra daun tomat dan augmentasi sederhana.



Gambar 1. Imbalanced Data



Gambar 2. Balanced Data



Gambar 3. Hasil Pembacaan Data Citra

Gambar 1 dan 2 Menampilkan perubahan kuantitas data citra setelah proses augmentasi sederhana. Kelas *Tomato_Late_blight* mendominasi dengan populasi sampel tertinggi (mendekati 1.900 citra), diikuti oleh *Tomato_Septoria_leaf_spot*, sedangkan kelas *Tomato_healthy* memiliki jumlah sampel terendah (sekitar 1.600 citra). Temuan ketimpangan distribusi ini mengkonfirmasi perlunya penerapan teknik penyeimbangan data dan augmentasi pada tahap persiapan data selanjutnya untuk mencegah bias mayoritas pada model klasifikasi.


Untuk mengatasi masalah tersebut Strategi ini bekerja dengan menargetkan jumlah sampel pada kelas minoritas (*Tomato_healthy*) agar setara dengan kelas mayoritas (*Tomato_Late_blight*).

Teknik augmentasi yang diterapkan meliputi pembalikan *horizontal* (*horizontal flip*) dan *random zoom* (rentang 0.7 hingga 1.2) untuk memperkaya variasi visual tanpa mengubah karakteristik patologi daun.

Pada Gambar 3 menampilkan *sample* citra yang telah melalui proses standarisasi ukuran menjadi 224x224 piksel dan konversi ke ruang warna RGB, menghasilkan dataset yang konsisten dan siap latih, seperti yang ditampilkan pada sampel citra visualisasi data.

3.2. Hasil Simulasi Degradasi Citra

Bagian akan memaparkan hasil dan pembahasan yang didapat, setelah data yang sudah konsisten didegradasikan kualitasnya (*Downsampling*).




Gambar 4. Hasil Simulasi Degradasi Visual

Gambar 4 menampilkan dampak visual dari proses ini pada perbandingan citra sampel. Secara kualitatif, terlihat perbedaan signifikan di mana citra hasil *downsampling* (kanan) kehilangan ketajaman detail frekuensi tinggi (*high-frequency details*) jika dibandingkan dengan citra asli (kiri). Fitur-fitur krusial seperti tekstur urat daun dan batas-batas tegas (*edges*) pada lesi penyakit *Septoria leaf spot* menjadi kabur (*blur*). Kumpulan citra yang telah terdegradasi ini selanjutnya ditetapkan sebagai data *Baseline*, yang menjadi input standar untuk pengujian efektivitas metode *image sharpening*.

3.3. Hasil Penerapan Image Sharpening

Bagian yang akan memaparkan penerapan teknik restorasi citra pada dataset *Baseline* yang telah terdegradasi. Tiga algoritma *sharpening* diterapkan secara terpisah untuk menghasilkan variasi dataset uji. Hasil visual dari penerapan metode ini dapat diamati pada perbandingan citra sampel.



Gambar 5. Hasil Penerapan tiga (3)
Image Sharpening

Gambar 5 menampilkan bahwa secara kualitatif, ketiga metode menunjukkan karakteristik penajaman yang berbeda:

- Basic Sharpening Kernel (BSK)*: Menunjukkan peningkatan ketajaman tepi (*edge enhancement*) yang seimbang, memulihkan detail tekstur pada daun yang terinfeksi *Late blight* tanpa menimbulkan distorsi berlebihan.
- Unsharp Masking (USM)*: Terlihat menonjolkan kontras lokal secara signifikan, membuat pola bercak pada *Septoria leaf spot* menjadi lebih tegas dan mudah dibedakan dari latar belakang.
- High Boost Filtering (HBF)*: Menunjukkan efek penajaman yang paling agresif. Pada sampel *Tomato_healthy*, terlihat bahwa HBF sangat memperjelas struktur tulang daun, namun secara bersamaan juga mengamplifikasi *noise* (derau) pada area permukaan daun yang seharusnya halus.

Output dari tahapan ini menghasilkan tiga variasi dataset baru yang siap untuk dievaluasi kinerjanya, baik secara visual (PSNR/SSIM) maupun fungsional (Akurasi Model).

3.4. Hasil Evaluasi Kualitas Citra (Objektif)

Bagian yang akan memaparkan hasil Pengukuran Restorasi Visual secara kuantitatif yang menggunakan metrik *PSNR* dan *SSIM*. Pengukuran yang bertujuan untuk menilai seberapa besar tingkat perubahan struktur dan sinyal yang dihasilkan oleh setiap metode *sharpening* terhadap citra input (*baseline*).

Tabel 1. Hasil Pengukuran Restorasi Visual Citra

NO	METODE	PSNR	SSIM
1	<i>High Boost Filter Sharpening</i>	35.367718	0.939907
2	<i>Basic Kernel Sharpening</i>	31.431703	0.866840

3	<i>Unsharp Masking Sharpening</i>	22.961309	0.590829
---	-----------------------------------	-----------	----------

Berdasarkan data yang disajikan pada Tabel 1, terlihat disparitas nilai yang signifikan antar metode:

- High Boost Filtering (HBF)* mencatatkan skor tertinggi dengan *PSNR* 35.37 dB dan *SSIM* 0.94. Secara matematis, nilai yang tinggi ini mengindikasikan bahwa citra hasil *HBF* memiliki tingkat kemiripan sinyal yang paling dekat dengan citra baseline, atau dengan kata lain, filter ini melakukan perubahan struktur yang paling minimal.
- Basic Sharpening Kernel (BSK)* menempati posisi kedua dengan *PSNR* 31.43 dB dan *SSIM* 0.87, menunjukkan tingkat modifikasi moderat.
- Unsharp Masking (USM)* mencatat nilai terendah secara drastis, dengan *PSNR* 22.96 dB dan *SSIM* 0.59. Rendahnya nilai ini mengkonfirmasi observasi visual sebelumnya, bahwa *USM* melakukan modifikasi piksel yang paling agresif dan mengubah struktur citra secara substansial dibandingkan bentuk aslinya yang buram.

3.5. Evaluasi Performa Model

Bagian yang akan memaparkan hasil dan pembahasan Pengukuran Kinerja Performa Model dari Masing-masing data citra yang sudah diterapkan metode *Image Sharpening*. Metrik pengukuran yang digunakan, yaitu Akurasi dan *Loss*.

Tabel 2. Hasil Pengukuran Kinerja Performa Model

NO	METODE	Accuracy	Loss
1	<i>Unsharp Masking (Images)</i>	0.989529	0.045507
2	<i>Basic Sharpening Kernel (Images)</i>	0.987784	0.034838
3	<i>No Sharpening (Baseline)</i>	0.980803	0.076421
4	<i>High Boost Filter (Images)</i>	0.977312	0.061034

Pengukuran tahap kedua berfokus pada analisis kinerja model task-based, yaitu mengukur dampak turunan (*downstream*) dari setiap skenario pra-pemrosesan terhadap kemampuan klasifikasi model *MobileNetV2*. Hasil pengujian pada data uji (15% dari total dataset) dirangkum pada Tabel 2.


Hasil ini secara umum mengkonfirmasi hipotesis bahwa penerapan *image sharpening* dapat meningkatkan performa klasifikasi. Namun,

terdapat disparitas kinerja yang sangat mencolok antar metode:

- Performa Unggul: Metode *Unsharp Masking (USM)* mencatatkan akurasi tertinggi (0.989529), diikuti oleh *Basic Sharpening Kernel (BSK)* (0.987784). Kedua metode ini secara signifikan mengungguli model yang hanya menggunakan *Baseline* (tanpa *sharpening*) yang mencatat akurasi 0.980803.
- Stabilitas Model (*Loss*): Meskipun *USM* unggul dalam akurasi mentah, *BSK* menunjukkan stabilitas model tertinggi dengan nilai *Loss* terendah (0.034838). Nilai *Loss* yang sangat rendah ini mengindikasikan model *BSK* memiliki keyakinan (*confidence*) prediksi yang paling tinggi.
- Temuan Kontraproduktif: Sebaliknya, metode *High Boost Filter (HBF)* terbukti kontraproduktif, mencatat akurasi terendah (0.977312). Angka ini bahkan lebih rendah daripada akurasi yang dicapai oleh model *Baseline* (0.980803), membuktikan bahwa *HBF* merugikan kinerja klasifikasi alih-alih memperbaikinya.

3.6. Analisis Korelasi Kontradiktif

Bagian yang akan memaparkan hasil tahap akhir evaluasi yang membandingkan hasil pengukuran restorasi visual dengan kinerja model untuk mengidentifikasi pola korelasi.



Gambar 6. Diagram Perbandingan dua (2) pendekatan evaluasi

Gambar 6. Menampilkan hasil tahap akhir evaluasi yang membandingkan hasil pengukuran restorasi visual dengan kinerja model untuk mengidentifikasi pola korelasi. Berdasarkan visualisasi data komparatif, penelitian ini mengungkap sebuah anomali krusial, yaitu teridentifikasi adanya *korelasi negatif* antara metrik kualitas citra objektif (*PSNR/SSIM*) dan performa klasifikasi (Akurasi). Berikut penjelasan temuan korelasi negatifnya

- Kontradiksi *High Boost Filtering (HBF)*: Secara matematis, *HBF* adalah metode "terbaik" dengan nilai *PSNR* tertinggi (35.4

dB) dan SSIM tertinggi (0.94). Nilai ini mengindikasikan bahwa citra hasil HBF sangat mirip dengan citra *baseline*. Namun, secara fungsional, HBF justru menghasilkan akurasi terendah (97.73%), bahkan dibawah kinerja *baseline tanpa sharpening*. Hal ini mengindikasikan bahwa tingginya fidelitas sinyal tidak menjamin kejelasan semantik bagi model. Kegagalan HBF diduga kuat disebabkan oleh amplifikasi *noise yang inheren* pada filternya, yang oleh model MobileNetV2 disalah artikan sebagai fitur gangguan, sehingga mendegradasi performa klasifikasi.

- b. Keunggulan "Informatif" *Unsharp Masking* (USM): Sebaliknya, USM mencatat nilai restorasi visual terendah (PSNR 23.0 dB; SSIM 0.59), yang menandakan perubahan struktur citra yang masif dan agresif (distorsi tinggi terhadap *baseline*). Namun, metode ini justru menghasilkan akurasi tertinggi (98.95%). Fenomena ini membuktikan bahwa meskipun USM menghasilkan artefak visual (seperti *halo di tepian objek*) yang menurunkan nilai SSIM, artefak tersebut justru bersifat "informatif" bagi model CNN. Penajaman agresif USM berhasil menonjolkan fitur-fitur diskriminatif penyakit (seperti tepi lesi) yang memudahkan model dalam membedakan kelas.

Implikasi Temuan: Hasil komparasi ini secara empiris membuktikan bahwa matrik visual standar (PSNR dan SSIM) tidak dapat diandalkan (*unreliable*) sebagai prediktor tunggal untuk keberhasilan tugas klasifikasi berbasis CNN pada kasus deteksi penyakit tanaman. Model *Deep Learning Terbukti* lebih memprioritaskan citra yang memiliki fitur kontras tinggi (*informative*) dibandingkan citra yang memiliki kemiripan struktural tinggi (*realistic*) dengan data aslinya.

CONCLUSION

Penelitian ini bertujuan untuk menguji secara kritis korelasi antara dampak restorasi visual objektif (diukur melalui PSNR dan SSIM) dengan dampak aktualnya terhadap performa klasifikasi (diukur melalui Akurasi dan *Loss*) ketika berbagai metode *image sharpening diterapkan* pada model MobileNetV2. Berdasarkan analisis evaluasi ganda yang telah dilakukan, tiga kesimpulan utama dapat ditarik:

1. Korelasi Negatif Terbukti: Penelitian ini secara empiris membuktikan adanya korelasi negatif antara metrik restorasi

visual objektif (PSNR/SSIM) dengan performa klasifikasi CNN. Temuan ini menegaskan bahwa peningkatan kualitas citra yang diukur secara matematis (PSNR/SSIM) tidak menjamin, dan bahkan dapat bertolak belakang dengan, peningkatan akurasi model.

2. Anomali Kinerja: Metode *High Boost Filtering* (HBF) mencatatkan skor PSNR dan SSIM tertinggi (dianggap "terbaik" dalam restorasi visual), tetapi menghasilkan akurasi klasifikasi terendah (97.73%), bahkan lebih rendah dari model *baseline* (tanpa *sharpening*). Sebaliknya, metode *Unsharp Masking* (USM) yang mencatat PSNR/SSIM terendah (paling agresif dan terdistorsi secara matematis), justru mencapai akurasi tertinggi (98.95%).

Ketidakandalan Matrik: Temuan ini menyimpulkan bahwa PSNR dan SSIM tidak andal sebagai prediktor tunggal untuk keberhasilan pra-pemrosesan citra dalam tugas *task-based seperti* klasifikasi penyakit tanaman. Model *Deep Learning Lebih* memprioritaskan fitur yang diperkuat (informatif) oleh USM, meskipun fitur tersebut menciptakan distorsi piksel yang signifikan, daripada menjaga kemiripan struktural yang dihargai oleh PSNR/SSIM.

REFERENCE

- [1] L. Zhang, L. Wang, J. Dang, L. Guo, and Q. Yu, "Gender-aware CNN-BLSTM for speech emotion recognition," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2018, pp. 782–790. doi: 10.1007/978-3-030-01418-6_76.
- [2] L. Zhang, L. Wang, J. Dang, L. Guo, and Q. Yu, "Gender-aware CNN-BLSTM for speech emotion recognition," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2018, pp. 782–790. doi: 10.1007/978-3-030-01418-6_76.
- [3] M. Khan and S. Kwon, "A CNN-assisted enhanced audio signal processing for speech emotion recognition," *Sensors*, vol. 20, no. 1, 2020, doi: 10.3390/s20010183.
- [4] R. Maurya, N. Nath Pandey, and M. Kishore Dutta, "VisionCervix: Papanicolaou cervical smears classification using novel CNN-

- Vision ensemble approach," vol. 79, 2023, doi: 10.1016/j.bspc.2022.104156.
- [5] B. H. Pansambal, A. B. Nandgaokar, J. L. Rajput, and A. Wagh, "An Integrated CNN-BiLSTM Approach for Facial Expressions," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 3, pp. 985–990, 2024, doi: 10.14569/IJACSA.2024.0150398.
- [6] N. Wu, D. Jia, C. Zhang, and Z. Li, "Cervical cell classification based on strong feature CNN-LSTM network using Adaboost optimization," vol. 44, no. 3, pp. 4335–4355, 2023, doi: 10.3233/JIFS-221604.
- [7] D. J. Chaudhari and K. Malathi, "Detection and Prediction of Rice Leaf Disease Using a Hybrid CNN-SVM Model," *Optical Memory and Neural Networks (Information Optics)*, vol. 32, no. 1, pp. 39–57, 2023, doi: 10.3103/S1060992X2301006X.
- [8] B. Karatay, D. Beştepe, K. Sailunaz, T. Özyer, and R. Alhajj, "CNN-Transformer based emotion classification from facial expressions and body gestures," *Multimed. Tools Appl.*, vol. 83, no. 8, pp. 23129–23171, 2024, doi: 10.1007/s11042-023-16342-5.
- [9] M. Khan and S. Kwon, "1D-CNN: Speech Emotion Recognition System Using a Stacked Network with Dilated CNN Features," *Computers, Materials and Continua*, vol. 67, no. 3, pp. 4039–4059, 2021, doi: 10.32604/cmc.2021.015070.
- [10] S. M. H. Ali Shuvo and R. Khan, "Bangla Speech-based Emotion Detection using a Hybrid CNN-Transformer Approach," in *Proceedings - 2023 8th International Conference on Communication, Image and Signal Processing, CCISP 2023*, 2023, pp. 163–167. doi: 10.1109/CCISP59915.2023.10355685.