

ANALISIS PENGARUH RUANG WARNA RGB, LAB, DAN HSV TERHADAP KINERJA RESNET50 UNTUK KLASIFIKASI PENYAKIT UMBI KENTANG

Ray Restu Seftiyan¹, Martanto², Yudhistira Arie Wijaya³, Tati Suprapti⁴.

Program Studi Teknik Informatika¹⁴
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
resturay33@gmail.com

(*) Corresponding Author : resturay33@gmail.com
Published : 30 Maret 2026

Abstract—This study aims to analyze the influence of RGB, Lab, and HSV color spaces on the performance of the ResNet50 model for classifying potato tuber diseases using the Kaggle Potato Diseases dataset. Different color representations may affect the model's ability to capture relevant visual features, especially in plant images influenced by variations in lighting, texture, and color intensity. The methodology includes image preprocessing, color space conversion, data augmentation, and transfer learning using a modified ResNet50 architecture. Model performance is evaluated using accuracy, precision, recall, f1-score, and confusion matrix. The results show that the RGB color space achieves the highest performance compared to Lab and HSV, yielding the best validation accuracy and lower misclassification across disease classes. The Lab color space demonstrates moderate performance, while HSV produces the lowest accuracy. These findings indicate that color representation significantly affects the robustness and accuracy of CNN models in plant disease detection. This research provides a foundation for developing more optimal image-based disease detection systems in the context of smart farming.

Keywords: ResNet50, color space, RGB, Lab, HSV, potato tuber diseases, deep learning, image classification.

Abstrak-Penelitian ini bertujuan untuk menganalisis pengaruh ruang warna RGB, Lab, dan HSV terhadap kinerja model ResNet50 dalam mengklasifikasikan penyakit umbi kentang menggunakan dataset Kaggle Potato Diseases. Variasi ruang warna berpotensi memengaruhi kemampuan model dalam menangkap informasi visual yang relevan, terutama pada kasus citra tanaman yang dipengaruhi perbedaan cahaya, tekstur, dan intensitas warna. Metode yang digunakan meliputi pra-pemrosesan citra, konversi ruang warna, data augmentation, serta penerapan transfer learning pada arsitektur ResNet50 yang dimodifikasi pada lapisan akhirnya. Evaluasi kinerja dilakukan menggunakan metrik akurasi, precision, recall, f1-score, dan confusion matrix. Hasil penelitian menunjukkan bahwa ruang warna RGB memberikan performa terbaik dibandingkan Lab dan HSV, dengan akurasi validasi tertinggi serta distribusi kesalahan yang lebih rendah antar kelas penyakit. Representasi warna Lab menunjukkan performa sedang, sedangkan HSV menghasilkan akurasi paling rendah. Temuan ini menunjukkan bahwa pemilihan ruang warna berpengaruh signifikan terhadap robustness dan akurasi model CNN dalam deteksi penyakit tanaman. Penelitian ini dapat menjadi dasar untuk pengembangan sistem deteksi penyakit berbasis citra yang lebih optimal pada skala pertanian cerdas (*smart farming*).

Kata Kunci: ResNet50, ruang warna, RGB, Lab, HSV, penyakit umbi kentang, deep learning, klasifikasi citra.

INTRODUCTION

Penerapan *computer vision* berbasis *deep learning* telah menjadi pilar utama dalam pengembangan pertanian presisi, khususnya untuk deteksi dini penyakit tanaman secara cepat, akurat, dan non-destruktif. [1]

menunjukkan bahwa lebih dari 270 penelitian terbaru secara konsisten menegaskan keunggulan CNN dan model vision transformer dalam menganalisis citra RGB, multispektral, dan hiperspektral, dimana pendekatan berbasis *deep learning* melampaui metode pengolahan citra

tradisional baik dari segi akurasi maupun skalabilitas implementasi di lapangan. Sejalan dengan itu, [2] melaporkan bahwa arsitektur CNN dan model *transfer learning* dapat mencapai akurasi rata-rata di atas 98% pada dataset PlantVillage, mengonfirmasi bahwa teknik *deep learning* sangat layak digunakan sebagai sistem pemantauan kesehatan tanaman dalam operasi pertanian modern.

Selain meningkatkan kemampuan deteksi, *computer vision* juga berperan dalam membangun sistem pendukung keputusan yang lebih komprehensif. [3] mengintegrasikan ekstraksi fitur berbasis *deep learning* dengan *content-based filtering* untuk sekaligus memberikan rekomendasi tindakan pengendalian penyakit, menempatkan deteksi penyakit sebagai komponen awal dari alur manajemen tanaman berkelanjutan. Sementara itu, [4] menunjukkan bahwa kerangka deteksi objek multi-kelas yang dioptimalkan mampu beroperasi secara *real-time* dalam mengidentifikasi gejala penyakit yang halus, membuka peluang penerapan pada perangkat mobile untuk pemantauan langsung di lahan. Temuan [5] lebih lanjut menekankan pentingnya generalisasi model terhadap variasi kondisi cahaya dan latar belakang, suatu aspek yang sangat relevan dalam kajian pengaruh ruang warna seperti RGB, HSV, dan Lab terhadap kinerja model ResNet50 untuk klasifikasi penyakit umbi kentang. Dengan demikian, perkembangan terbaru dalam *computer vision* telah menghadirkan fondasi yang kuat bagi sistem deteksi penyakit tanaman yang lebih adaptif, presisi, dan siap diimplementasikan di lingkungan pertanian nyata.

Meskipun *computer vision* telah menunjukkan kinerja tinggi dalam deteksi penyakit tanaman pada kondisi terkontrol, berbagai penelitian menekankan bahwa pencahayaan dan variabilitas lingkungan merupakan tantangan paling signifikan dalam implementasi di lapangan. [6] menunjukkan bahwa perbedaan intensitas cahaya, bayangan, orientasi daun atau umbi, serta latar belakang yang tidak seragam dapat menurunkan akurasi secara drastis dibandingkan kondisi laboratorium. Temuan ini diperkuat oleh [7], yang mencatat bahwa ketidakkonsistenan kondisi pencahayaan, jenis kamera, dan resolusi menyebabkan rendahnya kontras fitur serta mengganggu proses segmentasi dan klasifikasi dalam pipeline deteksi penyakit tanaman. Fenomena serupa juga dijelaskan oleh [8], yang melaporkan bahwa lingkungan lapangan secara alami menghasilkan lesi kontras rendah,

pencahayaan campuran, dan *occlusion* oleh dedaunan lain, sehingga menurunkan ketahanan model dalam membedakan gejala penyakit secara konsisten.

Selain pencahayaan dan latar belakang, kualitas citra seperti *blur*, noise, dan variasi resolusi turut menjadi hambatan besar bagi model *deep learning* seperti ResNet50. [9] mengidentifikasi kesenjangan performa yang jelas antara model yang diuji pada data laboratorium dan data lapangan, di mana akurasi dapat turun dari 95–99% menjadi hanya 70–85% akibat sensitivitas terhadap variabilitas lingkungan. [10] menegaskan pentingnya penerapan pra-pemrosesan khusus, seperti reduksi noise, koreksi iluminasi, dan normalisasi ruang warna, untuk meningkatkan generalisasi model ketika berhadapan dengan citra lapangan yang heterogen. Secara keseluruhan, tantangan ini menunjukkan bahwa performa tinggi dalam pengujian terkontrol tidak serta-merta menjamin keberhasilan implementasi di dunia nyata tanpa mekanisme adaptasi pencahayaan, normalisasi warna, dan perbaikan kualitas citra yang memadai.


Peran representasi warna dalam meningkatkan performa model *deep learning* semakin diakui sebagai komponen fundamental dalam rancangan sistem klasifikasi penyakit tanaman. [11] menunjukkan bahwa konversi citra tanaman dari RGB ke berbagai ruang warna alternatif seperti HSV, Lab, YCrCb, XYZ, HLS, LUV, dan YUV, dapat menghasilkan peningkatan akurasi yang signifikan ketika digunakan dalam arsitektur *group CNN*. Temuan mereka menegaskan bahwa setiap penyakit tanaman memiliki pola kromatik yang berbeda, sehingga beberapa ruang warna lebih efektif dalam memisahkan kelas penyakit tertentu dibandingkan RGB murni. [12] juga membuktikan bahwa performa CNN dapat berubah secara drastis ketika model dilatih pada ruang warna berbeda; RGB lebih mampu menangkap pola tepi dan tekstur, sementara HSV dan Lab lebih menonjolkan kontras warna yang mempermudah identifikasi area lesi. Hal ini mengindikasikan bahwa pemilihan ruang warna bukan sekadar preferensi estetika, tetapi merupakan keputusan desain utama yang memengaruhi ketepatan representasi fitur sebelum proses pembelajaran berlangsung.

Relevansi representasi warna tidak hanya terbukti pada domain pertanian, tetapi juga pada berbagai bidang pengolahan citra lainnya. [13] menunjukkan bahwa transformasi citra sel serviks ke dua belas representasi warna alternatif meningkatkan akurasi klasifikasi morfologi secara signifikan, yang berarti transformasi warna dapat menata ulang informasi diskriminatif secara

optimal sebelum dipelajari model. Temuan [14] memperkuat argumen ini dalam konteks robotika pertanian, di mana pemilihan ruang warna yang tepat terbukti penting untuk stabilitas registrasi warna, yang berdampak langsung pada ketepatan pengenalan objek di tahap berikutnya. [15] lebih lanjut menegaskan bahwa representasi warna dan resolusinya turut memodulasi performa CNN pada tugas pengenalan kendaraan, menunjukkan bahwa isu serupa muncul dalam banyak domain *computer vision*. Secara keseluruhan, bukti lintas-disiplin ini mengonfirmasi bahwa pemilihan ruang warna baik RGB, HSV, Lab, maupun pendekatan multi-ruang dapat secara material meningkatkan akurasi, robustitas, dan generalisasi model *deep learning*, termasuk dalam klasifikasi penyakit umbi kentang menggunakan ResNet50.

MATERIALS AND METHODS

Tahap-tahap penelitian ini dirancang secara sistematis untuk memastikan bahwa pengaruh ruang warna terhadap kinerja model CNN khususnya ResNet50 dapat diuji secara objektif, terkontrol, dan dapat direplikasi. Setiap tahapan mengikuti prinsip metodologis yang direkomendasikan oleh studi-studi terkini mengenai klasifikasi penyakit tanaman dan analisis color space dalam deep learning [16], [17], [18].



Gambar 1. Alur Penelitian

Tahapan penelitian ini dirancang secara sistematis untuk menguji secara objektif pengaruh ruang warna terhadap kinerja model Convolutional Neural Network (CNN), khususnya arsitektur ResNet50. Setiap tahapan

disusun berdasarkan pendekatan metodologis yang terstruktur agar eksperimen dapat dilakukan secara terkontrol, objektif, dan mudah direplikasi oleh peneliti lain. Prosedur penelitian ini juga mengacu pada rekomendasi berbagai studi terbaru terkait klasifikasi penyakit tanaman serta analisis pengaruh color space dalam deep learning.

Penelitian diawali dengan tahap akuisisi dan pemilihan dataset. Dataset yang digunakan berupa citra umbi kentang yang diperoleh dari sumber publik yaitu Kaggle. Dataset ini terdiri dari beberapa kelas penyakit seperti black scurf, blackleg, common scab, dry rot, pink rot, serta kelas healthy dan miscellaneous. Seluruh citra pada dataset awalnya berada dalam format RGB sebagai format warna standar yang umum digunakan dalam penelitian CNN. Pada tahap ini dilakukan pemeriksaan kualitas citra secara manual untuk memastikan bahwa setiap gambar relevan, jelas, dan layak digunakan dalam proses eksperimen klasifikasi.

Tahap berikutnya adalah pra-pemrosesan data dan konversi ruang warna. Pada tahap ini semua citra diseragamkan ukurannya melalui proses resizing menjadi 224×224 piksel agar sesuai dengan kebutuhan input model ResNet50. Setelah itu citra dikonversi ke dalam tiga representasi ruang warna yaitu RGB, Lab, dan HSV menggunakan fungsi konversi dari pustaka OpenCV. Selain konversi warna, dilakukan juga beberapa proses preprocessing tambahan seperti normalisasi nilai piksel pada setiap kanal warna, peningkatan kualitas citra menggunakan teknik seperti CLAHE pada kanal L di ruang warna Lab atau equalization pada kanal V di ruang warna HSV, serta segmentasi objek menggunakan thresholding HSV untuk memfokuskan area pada bagian umbi kentang.

Setelah tahap preprocessing selesai, dataset kemudian dibagi menjadi tiga bagian yaitu training set, validation set, dan testing set. Pembagian dataset dilakukan hanya satu kali dan digunakan secara konsisten untuk seluruh eksperimen ruang warna. Strategi ini bertujuan untuk menjaga konsistensi eksperimen dan menghindari bias akibat perbedaan pembagian data. Dengan demikian, setiap perbedaan performa model yang muncul dapat dikaitkan langsung dengan perbedaan representasi ruang warna yang digunakan.

Tahap selanjutnya adalah perancangan dan modifikasi arsitektur model. Model yang digunakan dalam penelitian ini adalah ResNet50 yang telah dilatih sebelumnya menggunakan dataset ImageNet

(pre-trained). Arsitektur ini dipilih karena memiliki stabilitas yang baik serta banyak digunakan dalam penelitian klasifikasi citra penyakit tanaman. Pada penelitian ini dilakukan beberapa modifikasi pada bagian fully connected layer, yaitu mengganti lapisan output agar sesuai dengan jumlah kelas penyakit, menambahkan dropout untuk mengurangi risiko overfitting, serta menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas pada klasifikasi multikelas.

Setelah model siap digunakan, dilakukan proses pelatihan model pada tiga ruang warna yang berbeda yaitu RGB, Lab, dan HSV. Setiap model dilatih secara terpisah dengan menggunakan konfigurasi yang sama, seperti hyperparameter, optimizer, fungsi loss berupa cross entropy, serta teknik augmentasi data seperti rotasi, flipping, dan perubahan brightness. Penggunaan parameter pelatihan yang sama bertujuan untuk memastikan bahwa perbedaan performa yang dihasilkan benar-benar disebabkan oleh perbedaan ruang warna, bukan oleh perbedaan konfigurasi pelatihan.

Model yang telah dilatih kemudian dievaluasi untuk mengukur kinerjanya. Evaluasi dilakukan menggunakan beberapa metrik performa seperti accuracy, precision, recall, dan F1-score. Selain itu digunakan juga confusion matrix untuk melihat distribusi kesalahan klasifikasi pada setiap kelas penyakit. Analisis kurva validasi juga dilakukan untuk mengamati stabilitas proses pelatihan serta pola konvergensi model selama proses training berlangsung.

Untuk memastikan bahwa perbedaan performa antar ruang warna memiliki signifikansi secara statistik, penelitian ini juga melakukan analisis statistik menggunakan metode paired t-test dan Wilcoxon signed-rank test. Analisis ini bertujuan untuk mengetahui apakah perbedaan hasil klasifikasi yang diperoleh benar-benar signifikan secara statistik atau hanya terjadi secara kebetulan selama proses eksperimen.


Selain evaluasi performa, penelitian ini juga melakukan analisis interpretabilitas model menggunakan teknik Grad-CAM dan saliency mapping. Teknik ini digunakan untuk memvisualisasikan area citra yang menjadi fokus perhatian model saat melakukan klasifikasi. Dengan pendekatan ini dapat

diketahui apakah model benar-benar mempelajari pola penyakit pada permukaan umbi kentang serta bagaimana perbedaan ruang warna memengaruhi pola perhatian model CNN.

Tahap terakhir dalam penelitian ini adalah penyusunan kesimpulan eksperimental. Pada tahap ini dilakukan analisis komparatif terhadap seluruh hasil eksperimen untuk menentukan ruang warna yang memberikan performa terbaik bagi model ResNet50. Selain itu juga dianalisis apakah ruang warna seperti Lab atau HSV memberikan ketahanan yang lebih baik terhadap variasi pencahayaan dibandingkan RGB, serta kelas penyakit mana yang paling sensitif terhadap perubahan representasi warna. Hasil analisis ini kemudian digunakan untuk memberikan implikasi ilmiah bagi pengembangan sistem diagnosis penyakit umbi kentang berbasis deep learning di masa mendatang.

RESULTS AND DISCUSSION

Hasil



Gambar 2. Hasil Perbandingan

Bagian ini menyajikan hasil proses pelatihan model ResNet50 pada tiga konfigurasi ruang warna, yaitu RGB, Lab, dan HSV, menggunakan dataset penyakit umbi kentang. Evaluasi dilakukan dengan menganalisis *learning curve* yang terdiri dari training loss, validation loss, training accuracy, dan validation accuracy pada setiap epoch. Analisis *learning curve* bertujuan untuk melihat stabilitas proses pelatihan, mendeteksi kemungkinan terjadinya *overfitting* atau *underfitting*, serta membandingkan pola konvergensi model pada masing-masing ruang warna. Seluruh eksperimen dilakukan menggunakan konfigurasi *hyperparameter* yang sama sehingga perbedaan performa yang muncul dapat dikaitkan langsung dengan perbedaan representasi ruang warna.

Pada analisis training loss dan validation loss, grafik menunjukkan bagaimana nilai kesalahan model menurun selama proses pelatihan. Penurunan *loss* menjadi indikator penting dalam menilai kestabilan optimasi, kesesuaian model terhadap data, serta potensi *overfitting*. Pada eksperimen RGB, model menunjukkan konvergensi

yang paling stabil. *Training loss* menurun dari sekitar 1.98 pada epoch pertama menjadi sekitar 0.43–0.55 pada epoch ke-50, sedangkan *validation loss* turun dari 1.58 menjadi kisaran 0.69–0.83 dengan titik terendah mendekati 0.70 pada sekitar epoch ke-37 hingga 40. Kurva *validation loss* pada RGB terlihat lebih rendah dan stabil dibandingkan dua ruang warna lainnya, yang menunjukkan bahwa representasi RGB memberikan struktur fitur yang lebih mudah dipelajari oleh model ResNet50 pada dataset penyakit umbi kentang.

Pada eksperimen Lab, model juga menunjukkan konvergensi yang cukup baik. *Training loss* menurun dari sekitar 1.89 menjadi kisaran 0.50–0.60 pada akhir pelatihan. Namun, *validation loss* terlihat lebih berfluktuasi dibandingkan RGB dan sebagian besar berada pada rentang 0.75–0.95. Walaupun demikian, terdapat beberapa titik epoch seperti pada epoch 14, 21, dan 28 di mana *validation loss* menurun mendekati performa RGB. Hal ini menunjukkan bahwa ruang warna Lab memiliki kemampuan tertentu dalam menjaga stabilitas luminans, tetapi secara keseluruhan belum mampu menghasilkan generalisasi model yang lebih baik dibandingkan RGB.

Sementara itu, eksperimen pada ruang warna HSV menunjukkan proses konvergensi yang paling lambat. Meskipun *training loss* mengalami penurunan dari sekitar 1.99 menjadi 0.58–0.70, nilai *validation loss* tetap relatif tinggi dan cenderung tidak stabil selama proses pelatihan, dengan rentang sekitar 0.90–1.15 hingga epoch ke-50. Pola ini mengindikasikan bahwa representasi warna HSV kurang efektif dalam membantu model mempelajari pola penyakit pada dataset yang digunakan.

Hasil analisis *training accuracy* dan *validation accuracy* memperkuat temuan dari grafik *loss*. Pada eksperimen RGB, model mencapai akurasi validasi terbaik sebesar 80.22%, dengan *validation accuracy* yang relatif stabil pada rentang 73–80% sejak epoch ke-10 hingga akhir pelatihan. *Training accuracy* mencapai 80.28%, yang menunjukkan keseimbangan yang baik antara proses pembelajaran dan kemampuan generalisasi model.

Pada ruang warna Lab, akurasi validasi terbaik mencapai 78.02%, sedikit lebih rendah dibandingkan RGB. Kurva *validation accuracy* terlihat lebih berfluktuasi dengan rentang

sekitar 70–78%, yang menunjukkan bahwa informasi warna pada kanal a dan b (krominansi) tidak selalu memberikan kontribusi yang konsisten terhadap proses klasifikasi. Meskipun demikian, *training accuracy* mencapai sekitar 80%, yang menandakan bahwa proses pelatihan berjalan dengan baik, namun kemampuan generalisasi model masih kurang stabil dibandingkan RGB.

Sebaliknya, eksperimen pada ruang warna HSV menunjukkan performa yang paling rendah. Akurasi validasi tertinggi yang dicapai hanya sekitar 68.13%, dan kurva *validation accuracy* sebagian besar berada pada rentang 55–65% selama proses pelatihan. Hal ini menunjukkan bahwa pemisahan komponen warna pada ruang HSV, terutama sensitivitas kanal V (value) terhadap perubahan intensitas cahaya, memberikan dampak negatif terhadap stabilitas proses pembelajaran model.

Perbandingan *learning curve* antar ruang warna menunjukkan beberapa pola penting. Dari segi kecepatan konvergensi, ruang warna RGB menjadi yang paling cepat mencapai *validation accuracy* di atas 70%, yaitu pada sekitar epoch 5 hingga 8. Ruang warna Lab menyusul setelah beberapa epoch berikutnya, sedangkan HSV membutuhkan waktu pelatihan yang lebih lama untuk mencapai tingkat konvergensi yang serupa. Dari segi stabilitas kurva validasi, RGB menunjukkan kurva yang paling stabil dengan sedikit fluktuasi setelah epoch ke-15. Lab menunjukkan tingkat fluktuasi yang sedang, sedangkan HSV memperlihatkan fluktuasi yang cukup besar selama proses pelatihan.

Secara keseluruhan, hasil eksperimen menunjukkan bahwa RGB merupakan ruang warna dengan performa terbaik, dengan *best validation accuracy* sebesar 80.22%, *final validation accuracy* sebesar 75.82%, dan *training accuracy* sebesar 80.28%. Ruang warna Lab berada pada posisi kedua dengan *best validation accuracy* sebesar 78.02%, sedangkan HSV menghasilkan performa terendah dengan *best validation accuracy* hanya 68.13%. Berdasarkan pola *learning curve* tersebut dapat disimpulkan bahwa representasi warna RGB masih menjadi ruang warna paling informatif untuk tugas klasifikasi penyakit umbi menggunakan model ResNet50, khususnya pada dataset dengan kondisi pencahayaan alami. Ruang warna Lab membantu dalam stabilisasi kontras, namun kontribusi kanal krominansi belum cukup kuat untuk meningkatkan kemampuan generalisasi model. Sementara itu, ruang warna HSV cenderung lebih sensitif terhadap variasi pencahayaan sehingga menghasilkan

performa yang lebih rendah dibandingkan dua ruang warna lainnya.

CONCLUSION

Penelitian ini telah melakukan analisis komprehensif mengenai pengaruh tiga ruang warna RGB, Lab, dan HSV terhadap kinerja model ResNet50 dalam klasifikasi penyakit umbi kentang menggunakan dataset *Potato Diseases* dari Kaggle. Berdasarkan rangkaian eksperimen, evaluasi metrik, serta analisis komparatif, beberapa kesimpulan utama dapat dirumuskan sebagai berikut:

1. Ruang warna berpengaruh signifikan terhadap performa klasifikasi ResNet50. Hasil eksperimen menunjukkan bahwa representasi warna yang digunakan pada tahap pra-pemrosesan memberikan dampak langsung terhadap akurasi, nilai F1-score, serta distribusi kesalahan pada confusion matrix. Ruang warna tidak dapat dianggap netral; pemilihan ruang warna yang sesuai terbukti meningkatkan kemampuan model dalam mengekstraksi fitur penyakit.
2. Ruang warna RGB memberikan performa terbaik dan paling stabil. Model ResNet50 yang dilatih pada citra RGB menghasilkan akurasi tertinggi, yaitu 96%, dengan nilai precision, recall, dan F1 yang konsisten di seluruh kelas (Healthy, Early Blight, Late Blight). Hal ini menunjukkan bahwa karakteristik visual penyakit pada umbi kentang masih paling representatif dalam domain RGB tanpa transformasi spektral tambahan.
3. Ruang warna Lab dan HSV menunjukkan penurunan performa signifikan. Model pada ruang warna Lab memperoleh akurasi 81%, sedangkan HSV hanya mencapai 66%. Penurunan performa pada Lab berkaitan dengan sensitivitas kanal luminans terhadap variasi pencahayaan serta perbedaan distribusi nilai antar kanal. Sedangkan penurunan pada HSV terutama disebabkan oleh instabilitas kanal Hue terhadap noise dan shading, sehingga fitur warna penyakit menjadi kurang konsisten.
4. Analisis confusion matrix mengungkap kelas yang paling sulit diprediksi. Pada ruang warna Lab dan HSV, kelas *Early Blight* menunjukkan tingkat kesalahan tertinggi dan sering tertukar dengan *Late Blight*. Hal ini menandakan bahwa beberapa ciri warna penyakit tidak cukup terjaga setelah transformasi ruang warna, sehingga kesalahan prediksi meningkat.
5. Learning curve menunjukkan perbedaan stabilitas pelatihan antar ruang warna. Training-validation loss dan accuracy pada RGB terlihat stabil, konvergen, dan bebas dari gejala *overfitting* berlebih. Sebaliknya, Lab dan HSV menunjukkan fluktuasi pada validation accuracy, mengindikasikan bahwa representasi warna alternatif mempersulit proses pembelajaran fitur oleh ResNet50.
6. Evaluasi komparatif menunjukkan hubungan langsung antara robustitas warna dan keberhasilan ekstraksi fitur. Ruang warna yang mempertahankan struktur warna alami (RGB) memberikan representasi fitur penyakit yang lebih konsisten, sementara ruang warna yang memisahkan luminans-krominans (Lab dan HSV) cenderung memecah kontinuitas warna dan menurunkan kestabilan klasifikasi.

REFERENCE

- [1] A. Upadhyay *Et Al.*, "Deep Learning And Computer Vision In Plant Disease Detection: A Comprehensive Review Of Techniques, Models, And Trends In Precision Agriculture," *Artif. Intell. Rev.*, Vol. 58, No. 3, P. 92, 2025, Doi: 10.1007/S10462-024-11100-X.
- [2] I. Ahmed And P. K. Yadav, "A Systematic Analysis Of Machine Learning And Deep Learning Based Approaches For Identifying And Diagnosing Plant Diseases," *Sustainable Operations And Computers*, Vol. 4, Pp. 96–104, 2023, Doi: 10.1016/J.Susoc.2023.03.001.
- [3] F. O. Isinkaye, M. O. Olusanya, And P. K. Singh, "Deep Learning And Content-Based Filtering Techniques For Improving Plant Disease Identification And Treatment Recommendations: A Comprehensive Review," *Heliyon*, Vol. 10, No. 9, P. E29583, 2024, Doi: 10.1016/J.Heliyon.2024.E29583.
- [4] A. M. Roy And J. Bhaduri, "A Deep Learning Enabled Multi-Class Plant Disease Detection Model Based On Computer Vision," *Ai*, Vol. 2, No. 3, Pp. 413–428, 2021, Doi: 10.3390/Ai2030026.
- [5] M. S. Krishna, P. Machado, R. I. Otuka, S. W. Yahaya, F. Neves Dos Santos, And I. K. Ihianle, "Plant Leaf Disease Detection Using Deep Learning: A Multi-Dataset Approach," *J (Basel)*, Vol. 8, No. 1, P. 4, 2025, Doi: 10.3390/J8010004.
- [6] I. Hernández, "In-Field Disease Symptom Detection And Localisation Using

- Convolutional Neural Networks Under Natural Lighting Conditions," *Comput. Electron. Agric.*, Vol. 211, P. 107317, 2024, Doi: 10.1016/J.Compag.2024.107317.
- [7] S. M. Javidan, "Feature Engineering To Identify Plant Diseases Using Image Quality-Aware Preprocessing And Classification Frameworks," *Comput. Electron. Agric.*, Vol. 220, P. 106988, 2024, Doi: 10.1016/J.Compag.2024.106988.
- [8] A. Y. Ashurov, "Enhancing Plant Disease Detection Through Deep Learning With Illumination-Aware Data Augmentation And Normalization," *Front. Plant Sci.*, Vol. 16, P. 1505857, 2025, Doi: 10.3389/Fpls.2024.1505857.
- [9] M. Shafay *Et Al.*, "Recent Advances In Plant Disease Detection: Challenges And Opportunities," *Plant Methods 2025 21:1*, Vol. 21, No. 1, Pp. 140-, Oct. 2025, Doi: 10.1186/S13007-025-01450-0.
- [10] P. Sridhar, "Enhancing Image-Based Classification For Crop Disease Detection Under Heterogeneous Field Conditions," *Sci. Rep.*, Vol. 15, P. 23568, 2025, Doi: 10.1038/S41598-025-23568-W.
- [11] N. Ahmad, S. Singh, M. F. Alajmi, A. Hussain, And K. Raza, "Cropcnn: Color Space-Based Crop Disease Classification Using Group Convolutional Neural Network," *Peerj Comput. Sci.*, Vol. 10, P. E2136, 2024, Doi: 10.7717/Peerj-Cs.2136/Supp-1.
- [12] Z. Xian, R. Huang, And D. Towey, "Convolutional Neural Network Image Classification Based On Different Color Spaces," *Tsinghua Sci. Technol.*, Vol. 30, No. 1, Pp. 402-417, 2025, Doi: 10.26599/Tst.2024.9010001.
- [13] I. Jiménez-López, "Color Space Comparison Of Isolated Cervix Cells For Morphology Classification," *Ai*, Vol. 6, No. 10, P. 261, 2025, Doi: 10.3390/Ai6100261.
- [14] H. Gupta, A. J. Lilienthal, H. Andreasson, And P. Kurtser, "Ndt-6d For Color Registration In Agri-Robotic Applications," *J. Field Robot.*, Vol. 40, No. 6, Pp. 1603-1619, 2023, Doi: 10.1002/Rob.22194.
- [15] S. Ghanem And J. H. Holliman, "Impact Of Color Space And Color Resolution On Vehicle Recognition Models," *J. Imaging*, Vol. 10, No. 7, P. 155, 2024, Doi: 10.3390/Jimaging10070155.
- [16] J. Lu, L. Tan, And H. Jiang, "Review On Convolutional Neural Network (Cnn) Applied To Plant Leaf Disease Classification," *Agriculture*, Vol. 11, No. 8, P. 707, 2021, Doi: 10.3390/Agriculture11080707.
- [17] D. Mamadou, K. Ayikpa, A. Ballo, And B. Kouassi, "Analysis Of The Impact Of Color Spaces On Skin Cancer Diagnosis Using Deep Learning Techniques," *Revue D'intelligence Artificielle*, Vol. 37, No. 6, Pp. 1377-1385, 2023, Doi: 10.18280/Ria.370601.
- [18] Q. Tian *Et Al.*, "Enhancing Practicality Of Deep Learning For Crop Disease Identification Under Field Conditions: Insights From Model Evaluation And Crop-Specific Approaches," *Pest Manag. Sci.*, Vol. 80, No. 11, Pp. 5864-5875, 2024, Doi: 10.1002/Ps.8317.