

UAV Image Classification of Oil Palm Plants Using CNN Ensemble Model

Merinda Lestandy^{1*}, Adhi Nugraha^{2**}

* Teknik Elektro, Universitas Muhammadiyah Malang

** Teknik Industri, Universitas Muhammadiyah Malang
merindalestandy@umm.ac.id¹, adhinugraha@umm.ac.id²

Article Info

Article history:

Received 2025-04-18

Revised 2025-06-23

Accepted 2025-07-03

Keyword:

*Oil Palm,
UAV,
Basal Stem Rot,
CNN,
Ensemble Learning.*

ABSTRACT

Basal Stem Rot (BSR), caused by *Ganoderma boninense*, is one of the most destructive diseases affecting oil palm plantations in Southeast Asia. Early detection of this disease is crucial to prevent its widespread transmission and to maintain plantation productivity. This study proposes an image classification approach using ensemble learning with three Convolutional Neural Network (CNN) architectures: DenseNet161, ResNet152, and VGG19, to detect BSR-infected oil palm trees through aerial imagery captured by Unmanned Aerial Vehicles (UAVs). The dataset used consists of 7,348 annotated images classified into two categories: healthy and unhealthy. Experimental results show that the DenseNet161 model outperformed the others, achieving a validation accuracy of 91.75% and a validation loss of 0.0307. The ensemble CNN approach demonstrated improved classification accuracy and holds significant potential for implementation in automated and precise plant health monitoring systems. This research provides a valuable contribution to AI-based agricultural technology, particularly in disease management for oil palm plantations.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Kelapa sawit merupakan salah satu jenis tanaman yang cocok tumbuh di iklim tropis Asia Tenggara khususnya untuk wilayah Indonesia[1]. Faktanya, produksi minyak sawit merupakan industri global yang sangat besar bernilai 65,73 miliar USD pada tahun 2015 dan diperkirakan akan mencapai 92,84% pada tahun 2025, dengan negara pengekspor minyak sawit utama seperti Malaysia dan Indonesia menghasilkan 85% permintaan dunia[2], [3]. Namun, pohon kelapa sawit rentan terhadap penyakit seperti *Ganoderma boninense* (*G. boninense*) [4], dan tidak ada metode yang efisien untuk menangani infeksi tersebut tanpa penggunaan bahan kimia yang berlebihan, kerusakan pada produk sehingga mengakibatkan penurunan produksi kelapa sawit per unit area[5]. Penyebab yang mendasari penyakit ini dapat bervariasi dan dapat berhubungan dengan kondisi tanah (yaitu suhu dan bayangan seperti yang dijelaskan dalam[6], perubahan cuaca yang tidak wajar atau bahkan perubahan iklim[7].

Sektor kelapa sawit juga berkontribusi terhadap pencapaian Sustainable Development Goals (SDGs). SDGs merupakan pendekatan pembangunan yang lebih inklusif yang menghasilkan manfaat ekonomi sekaligus memberikan manfaat sosial dan lingkungan secara berkelanjutan atau lintas generasi. Dalam hal keberlanjutan, pertumbuhan perkebunan kelapa sawit mencakup tiga pilar utama keberlanjutan, yaitu dimensi ekonomi, sosial, dan ekologi.

Salah satu penyakit utama yang mempengaruhi penyakit utama yang mempengaruhi kesehatan tanaman kelapa sawit adalah penyakit BSB, yaitu penyakit jamur dan deteksi dini infeksi *G. boninense*. Dari survei yang dilakukan, penyakit BSB telah menimbulkan kerugian ekonomi di Indonesia sekitar 50-350 juta USD per tahun, sedangkan di Malaysia kerugian ekonomi diperkirakan mencapai USD 365 juta per tahun[2]. Permasalahan menjadi lebih serius ketika penyakit BSB merupakan penyakit yang sangat menular dan mudah menyebar dari tanaman ke tanaman melalui kontak langsung[2]. Saat ini belum ada pengobatan efektif yang dapat dilakukan untuk menyembuhkan pohon kelapa sawit[2].

Pengumpulan data yang sangat akurat mengenai distribusi dan status kesehatan pohon kelapa sawit di suatu kawasan perkebunan sangat penting untuk pengelolaan pengendalian penyakit dan pemodelan hasil pertanian yang efisien. Pemeriksaan penyakit BSB pada pohon kelapa sawit oleh manusia sangatlah sulit, terutama pada tahap awal infeksi. Selain itu, areal perkebunan kelapa sawit biasanya luas dan penyebaran pohon kelapa sawitnya luas. Oleh karena itu, proses pemantauan status kesehatan dan distribusi pohon kelapa sawit dengan menerapkan inspeksi berbasis lapangan bisa sangat menantang dan memerlukan investasi waktu dan tenaga yang besar.

Citra satelit dan citra dari wahana udara tanpa awak (UAV) telah banyak digunakan dalam penelitian terdahulu untuk pemantauan perkebunan skala besar [8], [9], [10]. Namun, penggunaan citra UAV cenderung lebih unggul dibandingkan citra satelit dalam hal resolusi gambar dan fleksibilitas. Hal ini karena UAV dapat terbang pada ketinggian yang lebih rendah dan lebih dekat dengan objek sasaran saat proses akuisisi data berlangsung. Dengan begitu, gambar suatu wilayah dalam kondisi terkini dapat diambil dengan resolusi yang lebih tinggi. Meskipun demikian, citra satelit mampu mencakup wilayah yang lebih luas dengan biaya per unit area yang lebih rendah. Namun, data yang diperoleh memiliki resolusi lebih rendah dibandingkan dengan citra UAV karena jarak antara kamera dan objek sasaran yang lebih jauh. Selain itu, kualitas gambar juga dipengaruhi oleh kondisi atmosfer. Oleh karena itu, citra UAV lebih cocok digunakan karena data yang diperoleh memiliki resolusi spasial dan fleksibilitas yang lebih tinggi.

Selama beberapa tahun terakhir, berbagai teknologi remote sensing seperti pencitraan satelit dan UAV telah banyak diterapkan di sektor pertanian. Hal ini digunakan karena, yang pertama, kemampuannya bisa mencakup area yang luas, yang kedua, memberikan resolusi spasial gambar yang lebih tinggi dengan biaya yang wajar. Selain itu, Namun, pemantauan dan deteksi gejala awal penyakit BSB pada pohon kelapa sawit dari citra UAV masih merupakan tantangan yang kompleks dan berat. Pertama, karakteristik visual pohon kelapa sawit yang terserang penyakit BSB tahap awal sangat mirip dengan pohon kelapa sawit yang sehat, sehingga menghasilkan kinerja klasifikasi yang buruk. Kedua, wilayah perkebunan kelapa sawit tertentu sangat padat dan batas-batas perkebunan kelapa sawit tumpang tindih. Oleh karena itu, mendeteksi tahap awal infeksi penyakit BSB pada masing-masing pohon kelapa sawit merupakan suatu tantangan yang besar untuk menghasilkan kualitas yang baik.

Studi terakhir tentang identifikasi dini penyakit sawit memanfaatkan teknologi kecerdasan buatan [5], [11]. Dengan pendekatan berbasis AI ini, mampu meningkatkan akurasi deteksi penyakit tanaman sawit. Meski demikian, tidak ada satu algoritma dengan performansi baik untuk semua dataset. Sebuah algoritma klasifikasi/deteksi mungkin dapat mencapai tingkat akurasi tinggi pada citra tanaman sawit, namun belum tentu berperforma baik pada dataset citra tanaman sawit yang lainnya. Untuk mengatasi masalah


“ketidakstabilan” ini, penelitian ini mengusulkan teknik ensemble learning dengan menggabungkan base learner atau base classifier untuk meningkatkan performa model dan akurasi hasil. Salah satu teknik penggabungan dalam ensemble learning adalah weighted voting [12]. Ketika menggunakan voting berbobot, bobot dari berbagai klasifikasi harus disesuaikan untuk menemukan kombinasi bobot optimal. Algoritma penyesuaian bobot ini dapat dianggap sebagai masalah optimisasi, yang dapat diatasi menggunakan algoritma metaheuristik seperti algoritma genetika.

Pengembangan dan implementasi ensemble machine learning telah dilakukan oleh peneliti misalnya untuk kasus prediksi [13], [14], dalam literature yang lain misalnya untuk klasifikasi spesies mangrove [15], dan identifikasi gejala yang berhubungan dengan citra kentang *Verticillium* layu multispektral berbasis UAV [16]. Penelitian [17] menyajikan teknik ensemble learning untuk mengidentifikasi dan mengklasifikasikan penyakit pada daun tanaman kacang tanah, mencapai tingkat akurasi yang mengesankan sebesar 98,46%. Metodologi ini melibatkan pelatihan tiga pembelajar dasar (base learners) yaitu DenseNet-169, InceptionV3, dan Xception dan menggunakan confidence scores dalam persamaan non-linier untuk membuat prediksi akhir. Pendekatan ini mengungguli metode ensemble tradisional seperti strategi berbasis peringkat fuzzy, weighted average dan soft voting. Performa ensemble learning ini juga divalidasi pada kumpulan data kentang dan daun anggur, yang menunjukkan tingkat akurasi tinggi masing-masing sebesar 96,05% dan 99,32%.

Kemajuan teknologi saat ini membuat Teknik deteksi objek dapat digunakan untuk meningkatkan kinerja peningkatan kualitas. Penelitian ini bertujuan untuk mengembangkan model yang dapat mendeteksi citra sawit untuk mendeteksi penyakit BSB. Untuk mengatasi masalah permasalahan tersebut, penelitian ini mengusulkan teknik ensemble learning dengan menggabungkan base learner atau base classifier untuk meningkatkan performa model dan akurasi hasil

II. METODE

Penelitian ini menggunakan metode ensemble learning CNN untuk mengklasifikasikan penyakit BSB pada tanaman sawit. Terdapat banyak model jaringan saraf konvolusional (CNN) yang berbeda untuk klasifikasi gambar (VGG, ResNet, DenseNet, MobileNet, dll.). Semuanya memberikan akurasi yang berbeda-beda. Dalam penelitian ini, kami melatih tiga model klasifikasi gambar (DenseNet161, ResNet152 dan VGG19) pada dataset citra tanaman sawit. Kemudian kita akan menyatukan mereka dalam sebuah ensemble. Adapun tahapan penelitian yang dilakukan ditunjukkan pada Gambar 1.



Gambar 1. Metode Penelitian

A. Data Preparation




Tahapan pertama dalam proses penelitian ini adalah preparasi data. Data yang digunakan berupa citra tanaman kelapa sawit yang diperoleh melalui proses akuisisi menggunakan UAV (Unmanned Aerial Vehicle). UAV digunakan karena kemampuannya untuk menangkap citra tanaman dari ketinggian secara efisien, serta menjangkau area perkebunan yang luas dan sulit diakses secara manual.

Sumber data di dapatkan di website <https://kaggle.com>. Dataset diperoleh dengan mengambil gambar pohon kelapa sawit dari puncak lokasi penelitian menggunakan UAV. Gambar diambil dengan UAV pada ketinggian 500m dan kecepatan 15-20 m/s dengan resolusi 1024 x 1024 piksel. Kumpulan data sampel dengan gambar berlabel ditunjukkan pada Tabel 1[5].

Data preprocessing dimulai dengan proses pelabelan untuk mengklasifikasikan citra kelapa sawit ke dalam kategori sehat dan tidak sehat. Pada tahap pelabelan ini juga dilakukan pembagian awal dataset menjadi Train, Validation, dan Test. Setelah itu, data yang sudah dilabeli dipersiapkan untuk dimasukkan ke dalam model CNN melalui tahapan pre-processing atau serialisasi model. Proses ini mencakup pemotongan gambar (crop) berdasarkan klasifikasi sehat dan tidak sehat yang telah ditentukan sebelumnya. Selanjutnya, gambar hasil pemotongan dikelompokkan ke dalam direktori masing-masing sesuai kategorinya, sekaligus dilakukan pencatatan dimensi dan label kategori dalam format yang akan digunakan saat proses training atau validasi. Tahapan berikutnya adalah serialisasi dataset dengan menerapkan fungsi `Resize()` untuk memastikan ukuran gambar tidak melebihi 224 x 224 piksel, kemudian `RandomHorizontalFlip()` digunakan untuk mengubah orientasi gambar agar menyesuaikan sudut pandang penglihatan. Setelah itu, dilakukan beberapa transformasi tambahan seperti `ToTensor()`, `Normalize()`, dan `RandomErasing()`, yang semuanya diterapkan pada dataset untuk training. Sementara itu, untuk dataset validasi hanya dilakukan `Resize()`, `ToTensor()`, dan `Normalize()`.

TABEL 1
CONTOH DATASET[5]

Contoh Dataset	Klasifikasi	Keterangan
	Sehat	Kanopi bukan sehat memperlihatkan

		n warna hijau subur dan dedaunan lebat.
	BSB disease-infected	Warna hijau halus dengan sedikit warna kuning terlihat pada daun.
	BSB disease-infected	Intensitas bintik kuning yang lebih tinggi terlihat
	BSB disease-infected	Kanopi layu dan dimensi kanopi mengecil.

Selanjutnya setiap gambar akan diberikan labelisasi dan bonding box berupa label “Healthy” dan “Unhealthy”. Bounding box merupakan proses penandaan wilayah spesifik dalam citra yang menjadi fokus utama pengenalan oleh model, misalnya area daun atau batang yang menunjukkan tanda-tanda penyakit. Bounding box ini berfungsi sebagai ROI (Region of Interest) dalam proses pelatihan, yang akan meningkatkan akurasi model dengan mengarahkan perhatian jaringan pada bagian paling relevan dalam citra.

B. Training Process

Setelah data siap, tahap berikutnya adalah proses pelatihan model (training process). Penelitian ini menggunakan pendekatan ensemble learning untuk meningkatkan performa klasifikasi. Ensemble learning adalah teknik yang menggabungkan beberapa model pembelajaran untuk menghasilkan prediksi yang lebih akurat dan stabil dibandingkan model tunggal. Dalam penelitian ini menggunakan tiga arsitektur CNN (Convolutional Neural Network) untuk basis ensemble, yaitu DenseNet161, ResNet152 dan VGG19.

DenseNet161 mampu menghubungkan layer secara padat sehingga fitur dari layer sebelumnya dapat langsung digunakan oleh layer berikutnya, memperkuat aliran gradien dan efisiensi pembelajaran. Sedangkan ResNet152 memiliki struktur residual yang membantu mengatasi permasalahan vanishing gradient, memungkinkan pelatihan jaringan yang sangat dalam. Terakhir, arsitektur VGG19 merupakan salah satu arsitektur klasik CNN yang menggunakan banyak lapisan konvolusional berurutan, efektif dalam menangkap fitur spasial pada citra.

Masing-masing model dilatih menggunakan dataset yang telah dilabeli, dan hasil pelatihan berupa weight data (bobot model) yang mencerminkan kemampuan masing-masing model dalam mengenali pola-pola penyakit. Bobot-bobot ini digunakan untuk mengimplementasikan model secara nyata dalam tahap klasifikasi.

C. Implementation Process

Tahap terakhir dari metode penelitian ini adalah implementasi model pada data uji. Dataset uji digunakan untuk mengukur performa model hasil pelatihan dalam mengklasifikasikan jenis penyakit yang terdapat pada tanaman kelapa sawit. Model yang telah dilatih dan disimpan dalam bentuk weight data diimplementasikan untuk memproses data baru secara otomatis. Training parameter yang digunakan untuk setiap arsitektur terlihat pada Tabel 2.

TABEL II
TRAINING PARAMETER

Optimizer	Adam
Max Epoch	16
Mini Batch Size	8
Learning Rate	0.0003

Hasil dari proses klasifikasi ini dievaluasi berdasarkan dua aspek utama yaitu Disease Classification untuk mengidentifikasi dan membedakan sawit sehat dan tidak sehat dan Accuracy model dalam menghasilkan prediksi yang sesuai. Evaluasi performa ini memberikan gambaran sejauh mana pendekatan ensemble learning dengan kombinasi model CNN mampu meningkatkan akurasi deteksi dan klasifikasi penyakit pada tanaman kelapa sawit, yang pada akhirnya dapat digunakan sebagai sistem pendukung keputusan dalam pengelolaan perkebunan secara digital dan presisi.

III. HASIL DAN PEMBAHASAN

A. Pembagian Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari dua kelas klasifikasi, yaitu kelas 0 (tidak sehat) dan kelas 1 (sehat). Data diklasifikasikan dan dibagi ke dalam tiga bagian: data pelatihan (training), validasi (validation), dan pengujian (testing), dengan total keseluruhan sebanyak 7.348 citra. Pembagian dataset tertera seperti pada Tabel 3.

TABEL III
PEMBAGIAN DATASET


Classification	Train	Valid	Test	Total
0	3126	1263	780	5169
1	1563	421	195	2179

B. DenseNet161

Gambar 2 di atas menunjukkan performa pelatihan model DenseNet161 dengan batch size sebesar 8 yang ditampilkan dalam dua grafik utama. Grafik sebelah kiri memperlihatkan perkembangan nilai loss pada data pelatihan (train loss) dan data validasi (validation loss) terhadap jumlah epoch. Sementara grafik sebelah kanan menampilkan nilai akurasi pelatihan (train accuracy) dan validasi (validation accuracy) sepanjang proses pelatihan berlangsung.

Terlihat bahwa nilai train loss mengalami penurunan yang cukup tajam pada awal pelatihan dan terus menurun secara bertahap hingga mencapai kestabilan setelah epoch ke-10. Nilai validation loss juga menunjukkan tren penurunan yang

signifikan, dengan nilai terendah sebesar 0.0307 yang tercapai pada epoch ke-10. Pola penurunan yang konsisten ini menunjukkan bahwa model mampu mempelajari data dengan baik dan melakukan generalisasi terhadap data validasi tanpa mengalami overfitting.




Gambar 2. Training Proses DenseNet161

Nilai train accuracy mengalami peningkatan stabil dari awal pelatihan hingga mencapai lebih dari 88% pada akhir pelatihan. Sementara itu, validation accuracy terlihat sudah cukup tinggi sejak awal, yaitu berada di atas 87%, dan mencapai nilai maksimum sebesar 91,75% saat validation loss berada di titik terendahnya. Hal ini mengindikasikan bahwa model berhasil membangun representasi fitur yang baik dari data input, serta memiliki kemampuan klasifikasi yang kuat dan konsisten terhadap data yang belum pernah dilihat sebelumnya.

Secara keseluruhan, hasil pelatihan model DenseNet161 menunjukkan performa yang sangat baik, dengan loss yang rendah dan accuracy yang tinggi baik pada data pelatihan maupun validasi. Karakteristik ini mencerminkan stabilitas dan efektivitas model dalam menyelesaikan tugas klasifikasi citra tanaman kelapa sawit yang digunakan dalam penelitian.

C. ResNet152

Gambar 3. menunjukkan visualisasi performa pelatihan model ResNet152 dalam dua grafik utama: grafik kiri menampilkan nilai loss terhadap jumlah epoch, dan grafik kanan menampilkan nilai accuracy terhadap jumlah epoch.



Gambar 3. Training Proses ResNet152

Pada gambar tersebut train loss (garis biru) maupun validation loss (garis oranye) mengalami penurunan selama proses pelatihan. Train loss turun cukup tajam dari awal hingga sekitar epoch ke-4, lalu mengalami penurunan yang lebih landai hingga akhir pelatihan. Validation loss juga

menunjukkan tren menurun, meskipun terdapat beberapa fluktuasi kecil di pertengahan epoch. Nilai validation loss terendah yaitu 0.0741 dicapai pada epoch ke-12, yang mengindikasikan saat terbaik model dalam meminimalkan kesalahan prediksi terhadap data validasi.

Terlihat bahwa train accuracy mengalami peningkatan bertahap dari sekitar 62% hingga mencapai sekitar 67% pada akhir pelatihan. Sementara itu, validation accuracy (garis oranye) cenderung lebih tinggi dibandingkan train accuracy, dengan kisaran antara 72% hingga 75%. Validation accuracy tertinggi tercatat sebesar 75,36% pada saat validation loss mencapai titik terendahnya, yaitu di epoch ke-12.

Secara umum, model ResNet152 tetap menunjukkan kemampuan belajar yang baik, namun hasilnya masih belum optimal untuk diterapkan secara langsung dalam klasifikasi penyakit tanaman kelapa sawit tanpa dilakukan penyesuaian lebih lanjut terhadap arsitektur atau hyperparameter-nya.

D. VGG19



Gambar 4. Training Process VGG19

Gambar 4. menunjukkan grafik hasil pelatihan model VGG19 pada proses klasifikasi citra tanaman kelapa sawit. Train loss menunjukkan tren penurunan yang konsisten, meskipun melambat setelah epoch ke-8. Sementara itu, validation loss mengalami fluktuasi kecil namun tetap berada pada tren menurun. Nilai validation loss terendah sebesar 0.0506 dicapai pada epoch ke-14, yang menunjukkan bahwa model mampu meminimalkan kesalahan prediksi pada data validasi pada titik tersebut.

Train accuracy (garis biru) menunjukkan peningkatan stabil dari sekitar 66% hingga mencapai lebih dari 73% pada akhir pelatihan. Validation accuracy relatif tinggi sejak awal, berada pada kisaran 85% hingga 89%, dan menunjukkan kestabilan selama proses pelatihan. Akurasi validasi tertinggi sebesar 87,35% tercatat saat validation loss berada pada titik terendahnya, yaitu di epoch ke-14.

Hasil ini menunjukkan bahwa model VGG19 mampu belajar secara efektif tanpa overfitting yang signifikan. Hal ini dibuktikan dengan tren penurunan loss yang stabil dan perbedaan yang tidak terlalu jauh antara akurasi pelatihan dan validasi. Dengan demikian, VGG19 menunjukkan performa yang baik dalam proses klasifikasi penyakit tanaman kelapa sawit, terutama ketika digunakan dengan batch size sebesar 8 dan jumlah epoch hingga 16.

E. Perbandingan antara ketiga model.

Hasil pengujian terhadap tiga model deep learning, yaitu DenseNet161, ResNet152, dan VGG19, menunjukkan variasi performa yang cukup signifikan dalam proses validasi klasifikasi penyakit pada tanaman kelapa sawit seperti pada Tabel 4. Berdasarkan hasil evaluasi menggunakan metrik validation loss dan validation accuracy, model DenseNet161 menunjukkan kinerja terbaik di antara ketiganya. Model ini menghasilkan nilai validation loss sebesar 0,0307 dan validation accuracy sebesar 91,75%, yang menunjukkan bahwa DenseNet161 mampu meminimalkan kesalahan prediksi dan memiliki tingkat ketepatan yang tinggi dalam mengklasifikasikan data validasi. Keunggulan ini tidak lepas dari arsitektur DenseNet yang menghubungkan setiap layer ke semua layer sebelumnya, sehingga memungkinkan pembelajaran fitur yang lebih efisien dan aliran gradien yang lebih baik.

TABEL IV
ACUAN UKURAN TEKS

Classification	Train	Valid
0	3126	1263
1	1563	421

Model VGG19 menempati posisi kedua dalam hal kinerja, dengan nilai validation loss sebesar 0,0506 dan validation accuracy sebesar 87,35%. Meskipun tidak sebaik DenseNet161, VGG19 masih mampu memberikan hasil klasifikasi yang cukup akurat. Sementara itu, model ResNet152 menunjukkan performa yang paling rendah, dengan validation loss sebesar 0,0741 dan validation accuracy sebesar 75,36%. Hal ini mengindikasikan bahwa model ini memiliki tingkat kesalahan yang lebih tinggi dalam memproses data validasi. Meskipun ResNet dikenal efektif dalam pelatihan jaringan yang dalam berkat penggunaan shortcut connection, dalam konteks penelitian ini model tersebut belum menunjukkan performa optimal, kemungkinan karena sensitivitas terhadap parameter pelatihan atau karakteristik dataset yang digunakan.

Secara keseluruhan, hasil ini menunjukkan bahwa DenseNet161 merupakan model paling ideal untuk digunakan dalam klasifikasi penyakit kelapa sawit berbasis citra UAV, karena mampu memberikan hasil klasifikasi yang lebih akurat dan stabil dibandingkan dengan model lainnya. Dengan demikian, model ini layak untuk diimplementasikan lebih lanjut dalam sistem pendeteksian dini penyakit tanaman secara otomatis dan presisi.

F. Penerapan EnsembleCNN

Pada penerapan EnsembleCNN, nilai validation accuracy tercatat sebesar 0,8818 saat validation loss mencapai nilai minimumnya. Berdasarkan grafik, Train Loss menunjukkan penurunan yang cukup tajam mulai dari epoch ke-2 hingga epoch ke-4, kemudian perlahan melambat mendekati epoch ke-6 dan seterusnya. Pola serupa juga terlihat pada Validation Loss, yang turun secara signifikan di epoch ke-2, kemudian melandai hingga epoch ke-6, sebelum kembali mengalami

penurunan tajam dan akhirnya naik serta stabil hingga epoch ke-14. Pada epoch ke-15, terjadi lonjakan signifikan pada Validation Loss, yang kemudian menurun kembali di epoch ke-16. Nilai minimum Validation Loss tercapai sebesar 0,0535 pada iterasi ke-7. Dari sisi akurasi, Training Accuracy menunjukkan peningkatan yang stabil sepanjang proses pelatihan. Sementara itu, Validation Accuracy meningkat cukup signifikan menjelang epoch ke-2, kemudian mengalami penurunan pada epoch ke-6, naik lagi dan stabil hingga epoch ke-14, serta mengalami kenaikan tambahan pada epoch ke-15.



Gambar 5. Penerapan EnsembleCNN

Proses pelatihan EnsembleCNN memperlihatkan tren train loss dan validation loss yang stabil, serta peningkatan train accuracy dan validation accuracy yang konsisten hingga akhir pelatihan. Hal ini mengindikasikan bahwa model EnsembleCNN efektif dalam mempelajari pola data dan dapat mengklasifikasikan data baru dengan tingkat akurasi yang tinggi. Dengan demikian, EnsembleCNN menjadi solusi yang menjanjikan untuk diimplementasikan dalam sistem pendeteksian dini penyakit tanaman kelapa sawit secara otomatis dan presisi.

V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, klasifikasi penyakit tanaman kelapa sawit berbasis citra UAV menggunakan metode deep learning menunjukkan performa yang bervariasi pada setiap model yang digunakan. Dataset penelitian terdiri dari dua kelas, yaitu sehat dan tidak sehat, dengan total 7.348 citra yang dibagi ke dalam data pelatihan, validasi, dan pengujian.

Model DenseNet161 menunjukkan performa terbaik dengan validation loss terendah sebesar 0,0307 dan validation accuracy tertinggi sebesar 91,75%. Hal ini menunjukkan kemampuan DenseNet161 dalam mempelajari fitur secara efisien dan melakukan klasifikasi dengan tingkat akurasi yang tinggi. Model VGG19 berada pada posisi kedua dengan validation loss sebesar 0,0506 dan validation accuracy sebesar 87,35%, sedangkan model ResNet152 menunjukkan performa terendah dengan validation loss sebesar 0,0741 dan validation accuracy sebesar 75,36%.

Hasil ini menunjukkan bahwa arsitektur model memiliki pengaruh signifikan terhadap performa klasifikasi. DenseNet161 unggul berkat desain arsitekturnya yang menghubungkan setiap layer ke semua layer sebelumnya,

memungkinkan aliran gradien yang lebih baik dan pembelajaran fitur yang lebih mendalam.

Lebih lanjut, penerapan metode EnsembleCNN yang menggabungkan keunggulan dari beberapa model (DenseNet161, VGG19, dan ResNet152) memberikan hasil yang menjanjikan dengan validation accuracy sebesar 88,18% dan validation loss minimum sebesar 0,0535. Tren train loss dan validation loss yang stabil, serta peningkatan train accuracy dan validation accuracy yang konsisten hingga akhir pelatihan, menunjukkan bahwa EnsembleCNN mampu meningkatkan generalisasi dan keandalan model dalam memproses data baru.

Secara keseluruhan, penelitian ini membuktikan bahwa penggunaan DenseNet161 sebagai model tunggal maupun penerapan EnsembleCNN dapat diandalkan untuk mendeteksi penyakit tanaman kelapa sawit secara otomatis dengan akurasi yang tinggi. Temuan ini membuka peluang untuk pengembangan sistem pendeteksian dini berbasis citra UAV yang lebih presisi, efisien, dan praktis dalam mendukung pengelolaan perkebunan kelapa sawit secara berkelanjutan.

UCAPAN TERIMA KASIH

Terimakasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Muhammadiyah Malang (LPPM UMM) atas dukungan terselenggaranya Program Penelitian Batch 3 Pendanaan Internal melalui Skim Penelitian Dasar Tahun 2024.

DAFTAR PUSTAKA

- [1] R. H. V Corley and P. B. Tinker, "The Oil Palm, Fourth Edition," 2003.
- [2] Y. Siddiqui, A. Surendran, R. R. M. Paterson, A. Ali, and K. Ahmad, "Current strategies and perspectives in detection and control of basal stem rot of oil palm," May 01, 2021, Elsevier B.V. doi: 10.1016/j.sjbs.2021.02.016.
- [3] Y. Xu et al., "Author Correction: Recent expansion of oil palm plantations into carbon-rich forests (Nature Sustainability, (2022), 10.1038/s41893-022-00872-1)," May 01, 2022, Nature Research. doi: 10.1038/s41893-022-00897-6.
- [4] N. A. Jazuli et al., "A Review of Factors Affecting Ganoderma Basal Stem Rot Disease Progress in Oil Palm," Oct. 01, 2022, MDPI. doi: 10.3390/plants11192462.
- [5] O. Win Kent, T. Weng Chun, T. Lee Choo, and L. Weng Kin, "Early symptom detection of basal stem rot disease in oil palm trees using a deep learning approach on UAV images," Comput Electron Agric, vol. 213, Oct. 2023, doi:10.1016/j.compag.2023.108192.
- [6] M. L. Lo et al., "Comparison of Ganoderma boninense Isolate's Aggressiveness Using Infected Oil Palm Seedlings," Journal of Microbiology, vol. 61, no. 4, pp. 449–459, Apr. 2023, doi:10.1007/s12275-023-00040-w.
- [7] N. H. Darlan, H. Hasan Siregar, E. Listia, and E. S. Sutarta, "Recent Evaluation of Rising Temperature and Oil Palm Extension to Higher Elevation in North Sumatra Evaluasi Terkini Kenaikan Suhu dan Perluasan Tanaman Kelapa Sawit ke Dataran Tinggi di Sumatera Utara," 2009.
- [8] J. Zheng, W. Li, M. Xia, R. Dong, H. Fu, and S. Yuan, Large-Scale Oil Palm Tree Detection From High-Resolution Remote Sensing Images Using Faster-RCNN. 2019 IEEE International Geoscience & Remote Sensing Symposium : proceedings : July 28-August 2, 2019, Yokohama, Japan, 2019.

- [9] I. Bonet, F. Caraffini, A. Pena, A. Puerta, and M. Gongora, Oil Palm Detection via Deep Transfer Learning. 2020 IEEE Congress on Evolutionary Computation (CEC), 2020.
- [10] J. Zheng et al., "Cross-regional oil palm tree counting and detection via multi-level attention domain adaptation network," 2020.
- [11] R. Malinee, D. Stratoulas, and N. Nuthammachot, "Detection of oil palm disease in plantations in krabi province, thailand with high spatial resolution satellite imagery," *Agriculture (Switzerland)*, vol. 11, no. 3, Mar. 2021, doi: 10.3390/agriculture11030251.
- [12] L. I. Kuncheva and J. J. Rodríguez, "A weighted voting framework for classifiers ensembles," *Knowl Inf Syst*, vol. 38, no. 2, pp. 259–275, Feb. 2014, doi: 10.1007/s10115-012-0586-6.
- [13] M. Lestandy, A. Abdurrahim, A. Faruq, M. Irfan, and N. Setyawan, "Ensembled Machine Learning Methods and Feature Extraction Approaches for Suicide-Related Social Media," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 13, no. 2, pp. 192–203, Jul. 2024, doi: 10.23887/janapati.v13i2.70016.
- [14] A. Faruq, S. S. Abdullah, A. Marto, C. M. Che Razali, and S. F. Mohd Hussein, "Flood Forecasting using Committee Machine with Intelligent Systems: A Framework for Advanced Machine Learning Approach," in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics Publishing, Jul. 2020. doi: 10.1088/1755-1315/479/1/012039.
- [15] B. Fu et al., "Comparison of RFE-DL and stacking ensemble learning algorithms for classifying mangrove species on UAV multispectral images," *International Journal of Applied Earth Observation and Geoinformation*, vol. 112, Aug. 2022, doi: 10.1016/j.jag.2022.102890.
- [16] I. Lizarazo, J. L. Rodriguez, O. Cristancho, F. Olaya, M. Duarte, and F. Prieto, "Identification of symptoms related to potato Verticillium wilt from UAV-based multispectral imagery using an ensemble of gradient boosting machines," *Smart Agricultural Technology*, vol. 3, Feb. 2023, doi: 10.1016/j.atech.2022.100138.
- [17] A. M. P. and P. Reddy, "Ensemble of CNN models for classification of groundnut plant leaf disease detection," *Smart Agricultural Technology*, vol. 6, Dec. 2023, doi: 10.1016/j.atech.2023.100362