



Klasifikasi Tanaman Umbi Berbasis Citra Digital Menggunakan Convolutional Neural Network dengan Transfer Learning EfficientNet

Reiyan Nugra Abdila¹, Elmayati^{2,*}, Novi Lestari³

¹ Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia

² Fakultas Ilmu Teknik, Program Studi Sistem Infromasi, Universitas Bina Insan, Lubuklinggau, Indonesia

³ Fakultas Ilmu Teknik, Program Studi Rekayasa Sistem Komputer, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ¹zeezayn02@gmail.com, ^{2,*}elmayati@univbinainsan.ac.id, ³novilestari@univbinainsan.ac.id

Email Penulis Korespondensi: elmayati@univbinainsan.ac.id

Abstrak—Klasifikasi tanaman umbi secara manual masih menghadapi kendala karena kemiripan karakteristik visual antar jenis umbi, seperti warna, tekstur, dan bentuk, sehingga berpotensi menimbulkan kesalahan identifikasi. Pemanfaatan citra digital dan *deep learning* menjadi alternatif yang lebih objektif untuk mendukung proses identifikasi secara otomatis. Penelitian ini bertujuan mengembangkan model klasifikasi tanaman umbi berbasis citra digital menggunakan *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* pada arsitektur EfficientNet. Tahapan penelitian meliputi penyusunan dataset citra tanaman umbi, *preprocessing* citra (penyesuaian ukuran dan normalisasi), perancangan model EfficientNet berbasis bobot *pretrained* sebagai *feature extractor*, pelatihan model menggunakan data latih, serta evaluasi menggunakan data uji. Kinerja model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*, serta dianalisis lebih lanjut menggunakan *confusion matrix* untuk melihat distribusi prediksi pada masing-masing kelas. Hasil pengujian menunjukkan bahwa model CNN EfficientNet mampu melakukan klasifikasi tanaman umbi dengan performa yang baik, ditandai oleh akurasi yang tinggi dan nilai metrik evaluasi yang stabil pada seluruh kelas. Kesalahan klasifikasi relatif kecil dan umumnya terjadi pada kelas dengan kemiripan karakteristik visual. Hasil ini menunjukkan bahwa penerapan *transfer learning* EfficientNet efektif untuk meningkatkan akurasi dan efisiensi pelatihan pada klasifikasi citra tanaman umbi, serta berpotensi dikembangkan sebagai sistem pendukung identifikasi tanaman pada konteks pertanian cerdas.

Kata Kunci: Tanaman Umbi; Klasifikasi Citra; CNN; Transfer Learning; Efficientnet; Confusion Matrix

Abstract—Manual classification of tuber crops often suffers from misidentification due to the visual similarity among tuber types in terms of color, texture, and shape. Digital image analysis combined with deep learning provides a more objective approach for automated identification. This study aims to develop a tuber crop image classification model using a Convolutional Neural Network (CNN) with transfer learning based on the EfficientNet architecture. The research stages include building a tuber image dataset, performing image preprocessing (resizing and normalization), designing an EfficientNet model with pretrained weights as a feature extractor, training the model on the training set, and evaluating it on a separate testing set. Model performance is assessed using accuracy, precision, recall, and F1-score, while a confusion matrix is used to analyze the distribution of predictions across classes. The experimental results indicate that the EfficientNet-based CNN achieves strong classification performance, reflected by high accuracy and stable evaluation metrics across all classes. Misclassifications are relatively limited and mostly occur among classes with highly similar visual characteristics. These findings confirm that EfficientNet transfer learning is effective in improving both accuracy and training efficiency for tuber crop image classification and has potential to be further developed as a decision-support tool in smart agriculture applications.

Keywords: Tuber Crops; Image Classification; CNN; Transfer Learning; Efficientnet; Confusion Matrix

1. PENDAHULUAN

Perkembangan teknologi digital dan kecerdasan buatan telah mendorong pemanfaatan *computer vision* dalam berbagai sektor, termasuk bidang pertanian. Salah satu penerapan yang banyak dikembangkan adalah klasifikasi citra tanaman untuk mendukung proses identifikasi dan pengambilan keputusan secara otomatis. Pemanfaatan citra digital memungkinkan pengolahan informasi visual secara objektif berdasarkan karakteristik warna, tekstur, dan bentuk objek yang dianalisis, sehingga mampu mengurangi ketergantungan pada pengamatan manusia yang bersifat subjektif [1], [2].

Tanaman umbi merupakan salah satu komoditas pertanian yang memiliki nilai ekonomi penting dan tersebar luas di berbagai wilayah. Identifikasi jenis tanaman umbi secara manual masih menghadapi kendala, terutama ketika karakteristik visual antar jenis umbi memiliki kemiripan yang tinggi. Kondisi ini berpotensi menimbulkan kesalahan klasifikasi yang berdampak pada proses distribusi, pengolahan, maupun pemanfaatan hasil pertanian. Oleh karena itu, diperlukan pendekatan berbasis citra digital yang mampu melakukan klasifikasi tanaman umbi secara akurat dan konsisten [3]. Metode *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah terbukti efektif dalam tugas klasifikasi citra karena kemampuannya mengekstraksi fitur visual secara otomatis tanpa memerlukan perancangan fitur manual. CNN mampu mempelajari representasi fitur secara hierarkis, mulai dari fitur tingkat rendah hingga fitur tingkat tinggi, sehingga banyak digunakan dalam berbagai penelitian klasifikasi citra pada bidang pertanian [4][5]. Namun, penerapan CNN dari awal (*training from scratch*) membutuhkan dataset yang besar dan waktu pelatihan yang relatif lama.

Untuk mengatasi keterbatasan tersebut, pendekatan *transfer learning* dengan memanfaatkan model CNN *pretrained* menjadi solusi yang banyak digunakan. Model *pretrained* seperti EfficientNet telah dilatih menggunakan dataset berskala besar sehingga mampu menghasilkan representasi fitur yang kuat dan efisien. Penggunaan transfer learning terbukti dapat meningkatkan performa klasifikasi citra, terutama pada kondisi dataset terbatas, serta mempercepat proses pelatihan model [6][7]. Penelitian terkait yang pernah dilakukan oleh Nadila Handayani Putri dkk, tentang Klasifikasi Citra Stroke Menggunakan Augmentasi dan Convolutional Neural Network EfficientNet-B0 dimana penelitian ini bertujuan untuk melakukan perbandingan tingkat akurasi menggunakan augmentasi dan tanpa augmentasi



serta hyperparameter menggunakan Convolutional Neural Network dalam arsitektur EfficientNet-B0 untuk melakukan klasifikasi citra stroke iskemik, hemoragik, dan otak normal. Augmentasi data yang digunakan adalah dengan melakukan rotation, horizontal flip, dan pengaturan contrast pada data asli. Data uji disediakan sebanyak 20% dari porsi data asli dan augmentasi, dan 80% lainnya digunakan untuk proses training pencarian model optimal. Pencarian model berdasarkan komposisi data latih dan validasi dengan perbandingan 70:30, 80:20, dan 90:10. Hasil eksperimen menunjukkan performa yang terbaik diperoleh pada gabungan citra asli dan augmentasi, dengan akurasi dan F1-score berturut-turut sebesar 97%, 93%, dan 94% untuk data uji citra asli, citra augmentasi, dan citra gabungan. Penggabungan citra asli dan augmentasi untuk data training telah menunjukkan bahwa model cukup robust untuk dapat menghasilkan akurasi yang tinggi. Penelitian ini sistem dirancang agar mampu mengklasifikasikan penyakit leukemia tipe Acute Lymphoblastic Leukemia (ALL) ke dalam 4 kelas, yaitu: Benign, Early, (Pre) Precursor, dan Pro (Progenitor) dengan memanfaatkan salah satu arsitektur dari Convolutional Neural Network (CNN) yaitu EfficientNet-B0. Skenario pengujian dilakukan terhadap hyperparameter pada arsitektur EfficientNet-B0 melalui epoch (20, 30 dan 50) dengan learning rate (0.0001, 0.0003, 0.001, 0.003) dan optimizer jenis Adam dan RMSProp. Hasilnya adalah nilai performa akurasi pada data train mencapai 97,84% dan pada data test sebesar 98,48%.

Hama serangga merupakan salah satu kendala utama yang kerap dihadapi petani dalam menjaga produktivitas pertanian. Ukurannya yang mikro serta keberagaman spesies yang tinggi sering kali menyulitkan petani dalam mengidentifikasi jenis hama secara tepat. Hal ini menjadi krusial karena pengendalian hama membutuhkan pendekatan spesifik; jenis pestisida atau penanganan medis yang digunakan harus disesuaikan dengan karakteristik spesies serangga penyerang. Banyaknya variasi obat pembasmi di pasaran kerap menimbulkan keraguan bagi petani dalam menentukan solusi yang paling efektif.

Sebagai upaya mengatasi permasalahan tersebut, penelitian ini mengeksplorasi implementasi teknologi deep learning menggunakan arsitektur EfficientNetV2-B0. Pengujian dilakukan pada dataset IP102 yang memiliki tantangan berupa imbalanced dataset (ketidakseimbangan jumlah sampel antarkelas) serta kemiripan visual yang sangat tinggi (highly-identical species) antarbeberapa jenis serangga. Penelitian ini secara khusus bertujuan untuk menguji potensi model berukuran ringan (compact model) agar dapat diintegrasikan pada perangkat smartphone atau Internet of Things (IoT). Keunggulan dari pendekatan ini adalah portabilitasnya yang tinggi, memungkinkan petani melakukan identifikasi langsung di ladang secara offline tanpa ketergantungan pada koneksi internet. Hasil eksperimen menunjukkan bahwa model terbaik yang dikembangkan berhasil memperoleh akurasi sebesar 51% dengan F1-Score 50,14%. Selain itu, eksplorasi juga diperluas menggunakan Corn or Maize Leaf Disease Dataset dari platform Kaggle untuk memperkuat analisis performa klasifikasi pada penyakit tanaman berbasis citra.

Dataset ini memiliki 4 klasifikasi: Hawar, Karat biasa, Bercak daun abu-abu, dan Sehat. Penelitian ini menggunakan metode Convolutional Neural Network dengan 2 model yang berbeda, yaitu model EfficientNet-B0 dan ResNet-50. Arsitektur yang digunakan adalah dense layer, dropout layer, dan GlobalAveragePooling layer dengan perbandingan pembagian dataset sebesar 70% merupakan data training dan 30% merupakan data validasi. Setelah dilakukan pengujian terhadap kedua skenario yang diusulkan, hasil akurasi yang didapatkan pada skenario model uji 1 yaitu EfficientNet-B0 adalah 94% dan untuk skenario model uji kedua yaitu ResNet-50 didapatkan hasil akurasi sebesar 93% [4].

Meskipun beberapa penelitian telah menerapkan CNN dan transfer learning dalam klasifikasi citra pertanian, sebagian besar masih berfokus pada objek atau komoditas tertentu. Kajian mengenai klasifikasi tanaman umbi berbasis citra digital dengan memanfaatkan arsitektur CNN EfficientNet masih relatif terbatas. Oleh karena itu, penelitian ini mengusulkan penerapan CNN dengan metode transfer learning menggunakan arsitektur EfficientNet untuk melakukan klasifikasi tanaman umbi berbasis citra digital. Pendekatan ini diharapkan mampu menghasilkan sistem klasifikasi yang akurat, efisien, serta mendukung pemanfaatan teknologi cerdas dalam sektor pertanian. Penelitian yang pernah dilakukan oleh Alfitra Salam, Dkk, 2023 tentang Perbandingan Klasifikasi Citra CT-Scan Kanker Paru-Paru Menggunakan Contrast Stretching Pada CNN dengan EfficientNet-B0 dengan hasil dengan arsitektur EfficientNet-B0 untuk mengklasifikasikan kanker paru-paru. Proses preprocessing yaitu contrast stretching, dan berbagai Teknik optimasi hyperparameter seperti Adam, Adagrad, dan SGD digunakan untuk meningkatkan kinerja CNN dan menggunakan Average pooling dengan out dense 64, 32, 16, 1. Analisis kinerja dilakukan dengan menggunakan matriks klasifikasi (confusion matrix). Hasil klasifikasi tertinggi dicapai menggunakan optimizer ADAM [19].

2. METODOLOGI PENELITIAN

2.1 Dataset dan Akuisisi Data

Berisi Dataset yang digunakan dalam penelitian ini berupa citra tanaman umbi yang dikumpulkan dari berbagai sumber dan telah melalui proses seleksi. Setiap citra merepresentasikan jenis tanaman umbi yang berbeda dan digunakan sebagai data masukan dalam proses pelatihan dan pengujian model. Dataset kemudian dibagi menjadi dua bagian, yaitu data latih (training data) dan data uji (testing data), dengan tujuan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Penggunaan citra digital sebagai sumber data memungkinkan sistem untuk memanfaatkan informasi visual berupa warna, tekstur, dan bentuk objek tanaman umbi secara langsung. Pendekatan ini dinilai lebih objektif dibandingkan identifikasi manual karena mengurangi ketergantungan pada persepsi subjektif pengamat [1][3].



2.2 Preprocessing Citra

Tahap preprocessing bertujuan untuk menyiapkan citra agar sesuai dengan kebutuhan model CNN. Seluruh citra pada dataset dilakukan penyesuaian ukuran (resizing) agar seragam dengan dimensi input model EfficientNet. Selain itu, dilakukan normalisasi nilai piksel untuk memastikan distribusi data berada pada rentang yang sesuai sehingga proses pembelajaran jaringan saraf dapat berlangsung lebih stabil. Tahapan preprocessing ini sangat penting karena kualitas data masukan berpengaruh langsung terhadap performa model klasifikasi. Citra yang telah dinormalisasi dan distandarisasi memungkinkan CNN mengekstraksi fitur visual secara lebih efektif [4][5].

2.3 Arsitektur Convolutional Neural Network

Model klasifikasi yang digunakan dalam penelitian ini adalah Convolutional Neural Network dengan arsitektur EfficientNet. CNN dipilih karena memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis melalui lapisan konvolusi dan pooling. Setiap lapisan konvolusi berperan dalam mengenali pola visual tertentu, mulai dari fitur sederhana seperti tepi hingga fitur kompleks yang merepresentasikan karakteristik objek tanaman umbi. EfficientNet merupakan arsitektur CNN yang dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi. Arsitektur ini mampu meningkatkan performa model dengan jumlah parameter yang relatif lebih sedikit dibandingkan model CNN konvensional, sehingga cocok digunakan pada dataset dengan ukuran terbatas [6][7].

2.4 Penerapan Transfer Learning

Penelitian ini mengimplementasikan pendekatan transfer learning untuk mengoptimalkan proses klasifikasi citra tanaman umbi. Model EfficientNet yang telah melalui proses pra-pelatihan (pre-trained) menggunakan dataset berskala besar, seperti ImageNet, dimanfaatkan kembali sebagai feature extractor utama. Melalui skema ini, bobot (*weights*) awal dari arsitektur tidak diinisialisasi secara acak dari nol, melainkan difungsikan sebagai representasi fitur mendasar untuk mengekstraksi karakteristik visual citra tanaman umbi secara otomatis dan komprehensif. Penerapan transfer learning ini memberikan efisiensi signifikan, di mana model mampu memanfaatkan transfer pengetahuan (*knowledge transfer*) berupa pola-pola fitur visual yang telah dipelajari sebelumnya. Hal tersebut tidak hanya mempercepat proses konvergensi saat iterasi pelatihan (*training time*), tetapi juga meningkatkan generalisasi dan akurasi model klasifikasi. Strategi ini terbukti sangat efektif dan efisien, khususnya dalam mengatasi kendala keterbatasan jumlah data latih (small dataset) yang kerap menjadi hambatan utama dalam pelatihan model deep learning dari awal (*from scratch*). [6][7].

2.5 Proses Pelatihan Model

Proses pelatihan model dilakukan menggunakan himpunan data latih (*training set*) berdasarkan konfigurasi hiperparameter yang telah dioptimalkan. Selama fase pelatihan, model deep learning secara bertahap mempelajari pemetaan (*mapping*) karakteristik dan fitur visual citra tanaman umbi ke dalam kategori kelas sasaran yang sesuai. Proses optimasi ini berlangsung secara iteratif melalui mekanisme propagasi balik (*backpropagation*) untuk meminimalkan nilai kesalahan prediksi yang diukur menggunakan fungsi kerugian (*loss function*). Selama iterasi (*epoch*) berlangsung, evaluasi performa model dipantau secara real-time dengan mengamati pergerakan kurva akurasi dan nilai loss baik pada data latih maupun data validasi. Penyesuaian hiperparameter seperti learning rate, ukuran batch (*batch size*), dan penggunaan teknik regularisasi dilakukan secara cermat untuk memastikan model mencapai performa konvergensi yang optimal serta memiliki kemampuan generalisasi yang baik tanpa mengalami kondisi penuangan berlebih (*overfitting*). [4][5].

2.6 Evaluasi Performa Model


Evaluasi performa model dilakukan menggunakan data uji untuk mengukur kemampuan model dalam mengklasifikasikan citra tanaman umbi secara akurat. Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, *confusion matrix* digunakan untuk menganalisis distribusi prediksi model terhadap masing-masing kelas. Penggunaan berbagai metrik evaluasi ini bertujuan untuk memberikan gambaran menyeluruh mengenai kinerja model klasifikasi, tidak hanya dari sisi akurasi, tetapi juga kemampuan model dalam mengenali setiap kelas tanaman umbi secara seimbang [3][5].

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian model klasifikasi tanaman umbi berbasis citra digital menggunakan Convolutional Neural Network dengan metode transfer learning pada arsitektur EfficientNet. Hasil pengujian diperoleh dari proses evaluasi model terhadap data uji yang tidak digunakan selama pelatihan, sehingga dapat menggambarkan kemampuan generalisasi model dalam mengklasifikasikan citra tanaman umbi.

3.1 Distribusi Dataset Penelitian

Tahap awal analisis hasil dimulai dengan penyajian distribusi dataset yang digunakan dalam penelitian ini. Dataset terdiri dari beberapa kelas tanaman umbi, di mana setiap kelas memiliki jumlah citra yang berbeda. Informasi mengenai distribusi jumlah citra pada masing-masing kelas disajikan pada Gambar 1.




Gambar 1. Distribusi Dataset Tanaman Umbi

Berdasarkan Gambar 1, terlihat bahwa jumlah citra pada setiap kelas relatif seimbang, meskipun terdapat perbedaan jumlah data pada beberapa kelas. Kondisi ini penting untuk diperhatikan karena distribusi data yang tidak seimbang berpotensi memengaruhi kinerja model klasifikasi. Dataset yang digunakan pada penelitian ini masih berada dalam batas wajar untuk dilakukan pelatihan model CNN, terutama dengan penerapan *transfer learning* yang mampu mengatasi keterbatasan jumlah data latih. Distribusi dataset ini menjadi dasar dalam mengevaluasi hasil klasifikasi, karena performa model pada setiap kelas sangat dipengaruhi oleh ketersediaan data latih yang representatif.

3.2 Hasil Pelatihan Model CNN EfficientNet

Proses pelatihan model CNN dengan arsitektur EfficientNet menghasilkan perubahan nilai akurasi dan loss yang diamati selama beberapa epoch pelatihan. Visualisasi hasil pelatihan model disajikan dalam bentuk grafik akurasi dan loss pada Gambar 2.




Gambar 2. Grafik Akurasi dan Loss Selama Proses Pelatihan Model

Berdasarkan Gambar 2, terlihat bahwa nilai akurasi model mengalami peningkatan secara bertahap seiring dengan bertambahnya jumlah epoch, sementara nilai *loss* menunjukkan tren penurunan. Pola ini mengindikasikan bahwa model berhasil mempelajari karakteristik visual citra tanaman umbi dengan baik. Stabilitas kurva akurasi dan *loss* pada akhir proses pelatihan menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan. Penerapan *transfer learning* pada arsitektur EfficientNet memberikan kontribusi positif terhadap stabilitas proses pelatihan. Model tidak perlu mempelajari fitur visual dari awal, melainkan memanfaatkan bobot awal hasil pelatihan sebelumnya, sehingga proses konvergensi dapat dicapai lebih cepat dan efisien.

3.3 Hasil Pelatihan Model

Evaluasi performa model klasifikasi dilakukan lebih lanjut menggunakan *confusion matrix* untuk mengetahui distribusi prediksi benar dan salah pada setiap kelas tanaman umbi. Hasil *confusion matrix* ditampilkan pada Gambar 3.



Gambar 3. Confusion Matrix Hasil Klasifikasi Tanaman Umbi

Berdasarkan Gambar 3, sebagian besar data uji berhasil diklasifikasikan dengan benar ke dalam kelas yang sesuai. Nilai diagonal utama pada *confusion matrix* menunjukkan jumlah prediksi benar yang dominan, sementara kesalahan klasifikasi relatif kecil dan umumnya terjadi pada kelas tanaman umbi yang memiliki karakteristik visual yang mirip. Kesalahan klasifikasi yang terjadi menunjukkan bahwa faktor kemiripan warna, tekstur, dan bentuk antar jenis tanaman umbi masih menjadi tantangan dalam proses klasifikasi berbasis citra digital. Namun demikian, jumlah kesalahan yang terbatas menunjukkan bahwa model CNN EfficientNet memiliki kemampuan yang baik dalam membedakan karakteristik visual antar kelas.

3.4 Evaluasi Precision, Recall dan F1-Score

Selain *confusion matrix*, evaluasi performa model juga dilakukan menggunakan metrik *precision*, *recall*, dan *F1-score* untuk memberikan gambaran yang lebih detail mengenai kinerja model pada masing-masing kelas tanaman umbi. Hasil evaluasi metrik tersebut disajikan dalam Gambar 4.

Classification Report:

	precision	recall	f1-score	support
jahe	0.9500	1.0000	0.9744	19
kencur	1.0000	1.0000	1.0000	16
kunci	1.0000	1.0000	1.0000	15
kunyit	1.0000	0.9545	0.9767	22
laos	1.0000	1.0000	1.0000	18
accuracy			0.9889	90
macro avg	0.9900	0.9909	0.9902	90
weighted avg	0.9894	0.9889	0.9889	90

Gambar 4. Hasil Evaluasi Kinerja Model

Berdasarkan Gambar 4, model menunjukkan nilai *precision* dan *recall* yang relatif tinggi pada seluruh kelas tanaman umbi. Nilai *precision* yang tinggi menunjukkan bahwa prediksi yang dihasilkan model pada suatu kelas memiliki tingkat kesalahan yang rendah, sedangkan nilai *recall* yang baik menunjukkan kemampuan model dalam mendeteksi sebagian besar data yang benar pada kelas tersebut. Nilai *F1-score* yang stabil pada setiap kelas mengindikasikan keseimbangan antara *precision* dan *recall*. Hal ini menunjukkan bahwa model tidak hanya unggul pada satu metrik tertentu, tetapi mampu memberikan performa klasifikasi yang konsisten pada seluruh kelas tanaman umbi.

3.5 Pembahasan

Hasil pengujian yang diperoleh menunjukkan bahwa penerapan CNN dengan arsitektur EfficientNet dan metode transfer learning mampu menghasilkan performa klasifikasi yang baik pada data citra tanaman umbi. Keberhasilan model dalam mencapai tingkat akurasi dan stabilitas metrik evaluasi tidak terlepas dari kemampuan EfficientNet dalam mengekstraksi fitur visual yang representatif dengan jumlah parameter yang efisien.

Dibandingkan dengan pendekatan klasifikasi konvensional yang mengandalkan fitur manual, penggunaan CNN memungkinkan sistem untuk mempelajari fitur visual secara otomatis dan adaptif. Hal ini menjadikan model lebih



fleksibel dalam menghadapi variasi kondisi citra, seperti perbedaan pencahayaan, sudut pengambilan gambar, dan latar belakang.

Implikasi dari hasil penelitian ini menunjukkan bahwa sistem klasifikasi tanaman umbi berbasis citra digital berpotensi untuk diterapkan dalam lingkungan nyata, baik sebagai sistem pendukung keputusan maupun sebagai bagian dari aplikasi pertanian cerdas. Dengan performa yang diperoleh, pendekatan ini dapat membantu meningkatkan efisiensi dan akurasi dalam proses identifikasi tanaman umbi.

4. KESIMPULAN

Penelitian ini telah berhasil menerapkan metode Convolutional Neural Network (CNN) dengan pendekatan transfer learning menggunakan arsitektur EfficientNet untuk melakukan klasifikasi tanaman umbi berbasis citra digital. Pendekatan yang digunakan mampu memanfaatkan karakteristik visual berupa warna, tekstur, dan bentuk objek tanaman umbi secara efektif, sehingga sistem dapat melakukan proses klasifikasi secara otomatis dan objektif. Hasil pengujian menunjukkan bahwa model CNN EfficientNet mampu menghasilkan performa klasifikasi yang baik, ditunjukkan oleh nilai akurasi, precision, recall, dan F1-score yang relatif tinggi dan stabil pada seluruh kelas tanaman umbi. Analisis confusion matrix juga memperlihatkan bahwa sebagian besar citra uji berhasil diklasifikasikan dengan benar, dengan tingkat kesalahan yang relatif kecil dan umumnya terjadi pada kelas tanaman umbi yang memiliki kemiripan karakteristik visual. Hal ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Penerapan transfer learning memberikan kontribusi signifikan terhadap peningkatan performa model, terutama pada kondisi dataset yang terbatas. Dengan memanfaatkan bobot awal dari model pretrained, proses pelatihan dapat berlangsung lebih efisien tanpa mengorbankan akurasi klasifikasi. Selain itu, arsitektur EfficientNet yang dirancang untuk menyeimbangkan akurasi dan efisiensi komputasi terbukti sesuai untuk diterapkan pada permasalahan klasifikasi citra tanaman umbi. Secara keseluruhan, penelitian ini menunjukkan bahwa pendekatan CNN dengan transfer learning EfficientNet berpotensi untuk dikembangkan lebih lanjut sebagai sistem pendukung identifikasi tanaman umbi berbasis citra digital. Untuk penelitian selanjutnya, disarankan untuk memperluas jumlah dan variasi dataset, menguji arsitektur CNN lain sebagai pembandingan, serta mengimplementasikan sistem pada lingkungan aplikasi nyata guna mendukung penerapan teknologi smart agriculture secara lebih optimal.

REFERENCES

- [1] K. Citra, P. Daun, dan T. Padi, "Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19," *Jurnal Sains dan Informatika*, vol. 9, no. 1, pp. 37–45, 2023, doi: 10.22216/jsi.v9i1.2175.
- [2] A. Agustina, F. Yanto, E. Budianita, I. Iskandar, dan F. Syafria, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode CNN Arsitektur DenseNet-121 dan Augmentasi Data," *Journal of Information Systems and Informatics Engineering*, vol. 8, no. 1, pp. 124–134, 2024. [Online]. Available: <https://doi.org/10.35145/joisie.v8i1.4256>
- [3] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, dan Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classify Corn Disease," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, 2023, doi: 10.29207/resti.v7i2.4736.
- [4] S. Ahmad, P. Singh, dan A. K. Sagar, "A Survey on Big Data Analytics," dalam *Proceedings of the 2018 IEEE International Conference on Advanced Computing, Communication Control and Networking (ICACCCN)*, 2018, pp. 256–260, doi: 10.1109/ICACCCN.2018.8748774.
- [5] A. Herlangga, "Penerapan Transfer Learning EfficientNet-B3 untuk Pengenalan Senjata Tradisional Sumatera Barat Menggunakan Convolutional Neural Network," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 2, pp. 1416–1423, 2024, doi: 10.23960/jitet.v12i2.4256.
- [6] Y. Fang, J. Zhao, L. Hu, X. Ying, Y. Pan, dan X. Wang, "Image Classification Toward Breast Cancer Using Deeply Learned Quality Features," *Journal of Visual Communication and Image Representation*, vol. 64, p. 102609, 2019, doi: 10.1016/j.jvcir.2019.102609.
- [7] A. Yunus, S. Samanhudi, dan A. Sakya, "Pengembangan Usaha Tanaman Umbi-Umbian di Desa Sambirejo," 2014.
- [8] O. Rostiana, N. Bermawie, dan M. Rahardjo, *Budidaya Jahe, Kencur, Kunyit, dan Temulawak*, Cetakan ke-2. Jakarta: —, 2010, pp. 1–43.
- [9] M. G. Azhari, M. A. Husain, dan M. Lutfi, "Transfer Learning Convolutional Neural Network dengan Arsitektur EfficientNet untuk Identifikasi Penyakit Daun Cabai," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 5, pp. 3662–3666, 2024, doi: 10.36040/jati.v7i5.7791.
- [10] S. S. Rhomadhon dan D. R. Ningtias, "Developing a Classification System for Brain Tumors Using the ResNet152V2 CNN Model Architecture," *Journal of Soft Computing Exploration*, vol. 5, no. 2, pp. 173–182, 2024, doi: 10.52465/josce.v5i2.372.
- [11] I. Suhardin, A. Patombongi, dan A. M. Islah, "Mengidentifikasi Jenis Tanaman Berdasarkan Citra Daun Menggunakan Algoritma Convolutional Neural Network," *Simtek: Jurnal Sistem Informasi dan Teknik Komputer*, vol. 6, no. 2, pp. 100–108, 2021, doi: 10.51876/simtek.v6i2.101.
- [12] F. Marpaung, F. Aulia, dan R. C. Nabila, *Computer Vision dan Pengolahan Citra Digital*. Yogyakarta: Pustaka Aksara, 2022.
- [13] I. Deep et al., *Implementasi Deep Learning Menggunakan Citra Digital*, Digital Repository Universitas Jember, 2022.
- [14] A. A. Hania, "Mengenal Artificial Intelligence, Machine Learning, dan Deep Learning," *Jurnal Teknologi Indonesia*, vol. 1, no. 1, pp. 1–6, 2017. [Online]. Available: <https://amt-it.com/mengenal-perbedaan-artificial-intelligence-machine-learning-deep-learning/>



- [15] V. Salim, A. Abdullah, dan P. Y. Utami, “Klasifikasi Citra Penyakit Tanaman pada Daun Paprika dengan Metode Transfer Learning Menggunakan DenseNet-201,” *Indonesian Journal of Computer Science*, vol. 13, no. 2, pp. 3001–3014, 2024, doi: 10.33022/ijcs.v13i2.3746.
- [16] N. H. Putri, J. Jasril, M. Irsyad, S. Agustian, dan F. Yanto, “Klasifikasi Citra Stroke Menggunakan Augmentasi dan Convolutional Neural Network EfficientNet-B0,” *Jurnal Media Informatika Budidarma*, vol. 7, no. 2, p. 650, 2023, doi: 10.30865/mib.v7i2.5981.
- [17] Y. Amrozi, D. Yuliati, A. Susilo, N. Novianto, dan R. Ramadhan, “Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM,” *Jurnal Sisfokom*, vol. 11, no. 3, pp. 394–399, 2022, doi: 10.32736/sisfokom.v11i3.1502.
- [18] J. A. Bunge dan D. H. Judson, “Implementasi Data Mining Menggunakan CRISP-DM pada Sistem Informasi Eksekutif Dinas Kelautan dan Perikanan Provinsi Jawa Tengah,” *Encyclopedia of Social Measurement*, vol. 1, pp. V1-617–V1-624, 2004, doi: 10.1016/B0-12-369398-5/00159-6.
- [19] A. Salam, F. Yanto, S. Agustian, dan S. Ramadhani, “Perbandingan Klasifikasi Citra CT-Scan Kanker Paru-Paru Menggunakan Contrast Stretching pada CNN dengan EfficientNet-B0,” *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 3, pp. 1341–1351, 2023, doi: 10.30865/klik.v4i3.1448.
- [20] A. N. Fajrina, Z. H. Pradana, S. I. Purnama, dan S. Romadhona, “Penerapan Arsitektur EfficientNet-B0 pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia,” *Jurnal Riset Rekayasa Elektro*, vol. 6, no. 1, p. 59, 2024, doi: 10.30595/jrre.v6i1.22090.
- [21] A. H. Nurfauzi, Y. Azhar, dan D. R. Chandranegara, “Penerapan Model EfficientNetV2-B0 pada Benchmark IP102 Dataset untuk Menyelesaikan Masalah Klasifikasi Hama Serangga,” *Repositor*, vol. 5, no. 3, pp. 805–814, 2023.