



Artikel Penelitian

Article history:

Received 28 Nov, 2023
Revised 14 Dec, 2023
Accepted 20 Dec, 2023

Kata Kunci:

CNN; Transfer Learning; Gandum; MobileNet, VGGNet16

Keywords:

CNN; Transfer Learning; Wheat; MobileNet, VGGNet16

INDEXED IN

SINTA - Science and Technology Index
Crossref
Google Scholar
Garba Rujukan Digital: Garuda

CORRESPONDING AUTHOR

Rian Ardianto
Department of Computer Science, Universitas Harapan Bangsa

EMAIL

rianardianto@uhb.ac.id

OPEN ACCESS

E ISSN 2623-2022

Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum

Analysis of Convolutional Neural Network Deep Learning Method in Durum Wheat Variety Classification

Rian Ardianto^{1*}, Sony Kartika Wibisono²

^{1,2} Department of Computer Science, Universitas Harapan Bangsa
rianardianto@uhb.ac.id^{1*}, sonykartika@uhb.ac.id²

Abstrak: Selama ini, Indonesia memenuhi kebutuhan gandum dengan mengimpor dari beberapa negara, seperti Australia, Ukraina, Kanada, Argentina, Amerika Serikat, Bulgaria, Moldova, Rusia, India, dan lain-lain. Tanaman ini umumnya tumbuh subur di wilayah subtropis dengan suhu berkisar 10–25°C dan curah hujan antara 350–1.250 mm. Penelitian ini bertujuan untuk menjelaskan metode transfer learning pada arsitektur Convolutional Neural Network (CNN) guna mendukung identifikasi otomatis. Keunggulan CNN terletak pada kemampuannya yang tidak memerlukan ekstraksi fitur karena fitur ekstraksi sudah terintegrasi secara otomatis dalam CNN. Studi ini melakukan perbandingan antara dua arsitektur CNN pada tiga jenis gandum yang berbeda. Hasil analisis menggunakan 150 citra data latih dan 45 citra data uji menunjukkan bahwa arsitektur MobileNet mampu memodelkan dataset dengan tingkat akurasi mencapai 98%, sementara tingkat kesalahan mencapai 0,02%.

Abstract: So far, Indonesia has met its wheat needs by importing from several countries, such as Australia, Ukraine, Canada, Argentina, the United States, Bulgaria, Moldova, Russia, India, and others. This plant generally grows well in subtropical areas with temperatures ranging from 10–25°C and rainfall between 350–1,250 mm. This research aims to explain the transfer learning method on the Convolutional Neural Network (CNN) architecture to support automatic identification. The advantage of CNN lies in its ability to not require feature extraction because the extraction features are automatically integrated in the CNN. This study performs a comparison between two CNN architectures on three different types of wheat. The analysis results using 150 training data images and 45 test data images show that the MobileNet architecture is able to model the dataset with an accuracy level of up to 98%, while the error rate reaches 0.02%.

Jurnal Kolaboratif Sains (JKS)

Doi: 10.56338/jks.v6i12.4938

Pages: 2081-2092

LATAR BELAKANG

Klasifikasi objek pada gambar merupakan tantangan utama dalam visi komputer, yang mencoba mensimulasikan kognisi visual manusia. Jaringan Syaraf Tiruan (JST) yang telah berkembang menjadi Deep Learning memungkinkan komputer untuk mengenali pola yang rumit dalam data visual (Azmi et al., 2023). Dengan menggunakan lapisan-lapisan yang dalam, JST dapat mengekstrak ciri-ciri hierarkis dari gambar, mencapai tingkat akurasi klasifikasi objek yang sangat baik. Pendekatan ini memiliki implikasi praktis dalam bidang pengenalan wajah, deteksi objek, dan teknologi mobil otonom (Hayati, 2023). Kemajuan dalam desain JST, terutama Convolutional Neural Networks (CNN), telah menghasilkan peningkatan signifikan dalam kategorisasi gambar, memberikan manfaat besar untuk berbagai industri yang bergantung pada analisis gambar sebagai dasar pengambilan keputusan (Wibowo et al., 2023).

Deep Learning, sebuah sub-bidang dari Machine Learning, memberikan pelatihan pada komputer untuk melaksanakan tugas-tugas seperti yang dilakukan manusia dengan menggunakan model matematika yang terinspirasi oleh jaringan saraf otak manusia. Ini memungkinkan komputer untuk memahami dan menganalisis data dengan lebih mendalam, menghasilkan hasil analisis yang lebih akurat (Astriningsih & Hatta Fudholi, 2023). Jaringan Syaraf Tiruan (JST), sebagai model komputasi dengan lapisan-lapisan dalam untuk mengekstrak fitur dari data, menjadi komponen utama dalam paradigma deep learning. Konsep ini memiliki penerapan yang signifikan dalam berbagai bidang, termasuk analisis gambar, pemrosesan bahasa alami, dan prediksi pola pada data berskala besar (Dandi Mochamad Reza et al., 2023). Convolutional Neural Networks (CNN) merupakan kemajuan penting dalam konteks deep learning, terutama dalam pemrosesan gambar. Meskipun demikian, perkembangan ini juga menimbulkan sejumlah hambatan, seperti kebutuhan akan dataset pelatihan yang besar dan sumber daya komputasi yang mahal. Penelitian terus dilakukan untuk meningkatkan efisiensi dan skalabilitas model deep learning, menjadikan kontribusi deep learning sebagai suatu tonggak penting dalam literatur ilmiah (Fernando Pratama et al., 2023).

Convolutional Neural Network (CNN) adalah model Deep Learning yang digunakan untuk analisis gambar, dengan mengandalkan pembagian bobot untuk mengurangi parameter pelatihan dan mencegah overfitting. CNN menonjol dalam identifikasi objek dan deteksi pola visual yang kompleks, mengekstrak elemen-elemen penting dari gambar sambil meningkatkan efisiensi komputasi (Alhamdani, 2022). Kemampuan CNN dalam membagi bobot membuatnya sangat sesuai untuk tugas-tugas pemrosesan gambar real-time, seperti dalam aplikasi mobil otonom dan pengenalan wajah. Meskipun demikian, implementasi yang efektif memerlukan pertimbangan yang hati-hati terhadap desain arsitektur, pemilihan parameter, dan manajemen data pelatihan. Dengan penelitian lebih lanjut, CNN telah menjadi alat yang tak tergantikan dalam literatur ilmiah terkait pemrosesan gambar dan pemahaman visual (Jack Billie Chandra & Dewi Nasien, 2023).

CNN telah menjadi fokus penelitian yang signifikan, terutama dalam konteks klasifikasi citra. Dalam penelitian klasifikasi citra Caltech 101, CNN menunjukkan kinerja yang cukup andal dengan tingkat akurasi berkisar antara 20% hingga 50% (I Wayan Suartika E. P et al., 2016). Kelebihan CNN terlihat dalam kemampuannya untuk menentukan kebenaran klasifikasi objek, dengan memanfaatkan konsep pembagian bobot untuk mengurangi jumlah parameter dan mencegah overfitting. Selanjutnya, CNN digunakan dalam klasifikasi tanaman pada Citra Resolusi Tinggi dengan mengimplementasikan algoritma CNN yang dapat membedakan 5 jenis tanaman, seperti padi, bawang merah, kelapa, pisang, dan cabai (Erlyna Nour Arrofiqoh & Harintaka, 2018). Penelitian ini mencapai akurasi yang sangat tinggi, mencapai 100% pada data training, 93% untuk data validasi, dan 82% pada data tes. Hal ini menunjukkan bahwa CNN tidak hanya andal dalam klasifikasi objek, tetapi juga mampu mengatasi kompleksitas klasifikasi pada tingkat lebih tinggi, seperti jenis tanaman. Tidak hanya terbatas pada klasifikasi objek atau tanaman, CNN juga diterapkan dalam klasifikasi ras, seperti dalam penelitian tentang Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network (CNN) (Afif et al., 2020). Dalam penelitian ini, CNN dilatih dan diuji menggunakan dataset kucing, dengan hasil akurasi yang bervariasi berdasarkan model CNN yang digunakan, seperti VGG16, InceptionV3,

Resnet50, dan Xception. Pada tahun 2018, penelitian tentang Race recognition using deep convolutional neural networks menyajikan perbandingan antara dua model CNN, yaitu RR-CNN dan RR-VGG, dalam klasifikasi ras Jepang, Cina, dan Brasil (Salimah et al., 2021). Hasilnya menunjukkan bahwa model RR-VGG memiliki akurasi 90%, menjadikannya sebagai model terbaik dalam skenario tersebut. Penelitian ini mencerminkan aplikasi CNN dalam klasifikasi yang lebih abstrak, seperti ras manusia, dengan hasil yang menjanjikan.

Dengan demikian, penelitian-penelitian ini menegaskan bahwa CNN bukan hanya alat andal dalam klasifikasi citra objek, tetapi juga efektif dalam mengatasi tantangan klasifikasi yang semakin kompleks, seperti identifikasi jenis tanaman dan ras manusia. Implikasi dari penelitian ini tidak hanya mencakup domain akademis, tetapi juga memiliki dampak potensial dalam berbagai aplikasi praktis seperti pertanian, kedokteran, dan teknologi pengenalan wajah. Perkembangan lebih lanjut dalam penelitian ini akan terus membuka peluang baru untuk penerapan CNN dalam pemahaman dan analisis citra yang lebih canggih (Putra et al., 2023).

Populasi penduduk Indonesia mencapai lebih dari 269.603 jiwa, dengan sebaran terbesar di Pulau Jawa (56,10%), disusul oleh Pulau Sumatera (21,68%), Sulawesi (7,36%), Kalimantan (6,15%), Bali, NTB, NTT, dan Maluku (5,54%), serta Papua (3,17%). Meskipun jumlah penduduknya besar, pola konsumsi masyarakat Indonesia masih dianggap tidak seimbang dalam pemenuhan gizi, terutama karena 97% penduduk masih mengonsumsi karbohidrat dari beras. Oleh karena itu, diversifikasi sumber karbohidrat menjadi semakin krusial untuk menjaga ketahanan pangan di masa depan (Saptono et al., 2023). Dalam konteks diversifikasi pangan, gandum muncul sebagai opsi yang menjanjikan. Sebagai tanaman penghasil karbohidrat yang umum di Indonesia, gandum dapat menjadi alternatif selain beras. Pemanfaatan sumber karbohidrat non-beras, seperti gandum, berpotensi meningkatkan variasi konsumsi pangan. Gandum juga terkenal sebagai sumber vitamin dan protein, menjadikannya komoditas yang potensial untuk memenuhi kebutuhan gizi masyarakat. Penting untuk memahami bahwa pergeseran fokus dari ketergantungan pada beras menuju pemanfaatan sumber karbohidrat non-beras, termasuk gandum, menjadi suatu kebutuhan mendesak. Diversifikasi pangan tidak hanya dapat meningkatkan ketahanan pangan, tetapi juga memberikan kontribusi yang signifikan terhadap pemenuhan nutrisi masyarakat Indonesia. Mengingat potensi gandum sebagai sumber utama karbohidrat, protein, dan vitamin, pengembangan strategi untuk mengintegrasikan gandum dalam pola konsumsi pangan menjadi krusial untuk meningkatkan kesejahteraan masyarakat Indonesia di masa depan (Wicaksono et al., 2020).

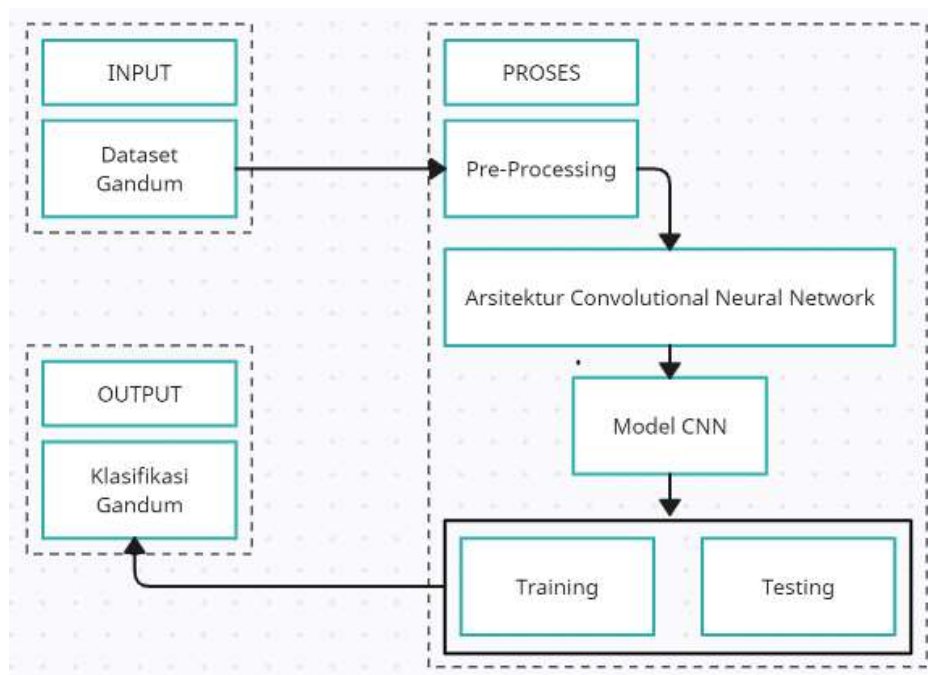
Penelitian ini mengarah pada tujuan klasifikasi untuk menilai performa dua model Convolutional Neural Network (CNN), yaitu VGG16 dan MobileNet v1, dalam mengklasifikasikan varietas gandum. Klasifikasi menjadi fokus utama karena memahami kemampuan dan keunggulan masing-masing model dapat memberikan wawasan yang berharga terkait penerapan praktis dalam konteks analisis citra pertanian (Niki Nadialita et al., 2023). Pertama, pemilihan model CNN menjadi langkah kunci dalam desain penelitian ini. VGG16 dikenal dengan kedalaman lapisan yang signifikan dan kapabilitas ekstraksi fitur yang kompleks, sementara MobileNet v1 menonjol dengan struktur yang ringan dan efisien, khususnya untuk aplikasi pada perangkat berdaya terbatas. Kedua model ini dianggap sebagai representasi yang baik dari arsitektur CNN yang berbeda, memungkinkan perbandingan yang bermakna terkait keunggulan dan keterbatasan masing-masing (Rifa et al., 2023). Selanjutnya, proses klasifikasi varietas gandum menjadi tantangan yang menarik, karena citra pertanian sering kali memiliki tingkat kompleksitas yang tinggi. Dengan menggunakan dataset yang relevan, penelitian ini bertujuan untuk mengukur akurasi dan kehandalan VGG16 dan MobileNet v1 dalam mengenali dan membedakan varietas gandum. Evaluasi ini mencakup beberapa metrik, seperti akurasi, presisi, recall, dan F1 score,

yang diperlukan untuk mendapatkan pemahaman yang komprehensif tentang kinerja model (Dwi Putro & Tantyoko, 2023).

Hasil dari penelitian ini diharapkan dapat memberikan rekomendasi yang berharga terkait pemilihan model CNN terbaik untuk tugas klasifikasi varietas gandum. Dengan pemahaman mendalam tentang kelebihan dan kekurangan masing-masing model, pemilihan model yang tepat dapat meningkatkan efisiensi dan akurasi dalam aplikasi nyata di bidang pertanian. Implikasi dari penelitian ini dapat membuka jalan bagi peningkatan teknologi pertanian yang didukung oleh analisis citra dan kecerdasan buatan.

METODE

Riset Model



Gambar 1. Riset Model Klasifikasi Gandum Metode CNN

Dalam Gambar 1 terdapat model penelitian yang telah dirancang. Pada gambar tersebut terdapat tiga tahap utama, yang terdiri dari input, proses, dan output.

Input: Pada bagian input terdapat dataset gambar gandum sebanyak 3 kelas yang akan diidentifikasi. (Kaya & Saritas, 2019) Dataset ini bersumber dari <https://www.muratkoklu.com/datasets/vtdhnd11.php>.

Proses: Pada data gambar yang telah diambil dilakukan pra-pemrosesan sebelum memasuki CNN. Tujuan dari pra-pemrosesan ini adalah untuk menghilangkan noise, mempertegas fitur data gambar, mengurangi ukuran gambar, dan mengubah gambar gandum sehingga dapat diproses oleh CNN. Selanjutnya, data gambar diproses menggunakan Arsitektur Transfer Learning CNN. Untuk mendapatkan sistem pengenalan gandum yang cerdas dan akurat, perlu dilakukan pelatihan dan pengujian data melalui model CNN yang terbentuk dan terakhir menghasilkan model CNN yang diinginkan.


Output: Pada bagian output terdapat hasil klasifikasi berupa prediksi gambar gandum, sehingga pengguna lebih mudah mengetahui jenis gandum yang diidentifikasi.

Metode Klasifikasi Gandum

Gandum memiliki banyak fitur, seperti bentuk, tekstur, dan pola. Makalah ini berfokus pada pengenalan gandum melalui warna, tekstur, ukuran, deteksi tepi, dan bentuknya menggunakan metode CNN. Pengujian menggunakan 3 jenis tanaman gandum yang berbeda. Sebelum dimasukkan ke dalam CNN, gambar mengalami pra-pemrosesan atau normalisasi data gambar terlebih dahulu.

Resize Gambar: Tujuan dari resize gambar adalah untuk mengurangi proses komputasi pada Unit Pemrosesan Grafis (GPU). Gambar 2 (a) menunjukkan input asli, sebelum dilakukan resize, yang akan digunakan dalam eksperimen, dengan ukuran 1600×1200 piksel. Gambar 2 (b) adalah hasil dari proses resize gambar, dengan ukuran 224×224 piksel.

Pembelajaran Menggunakan Model Transfer Learning dari Arsitektur CNN: Pada tahap ini, gambar gandum yang telah mengalami pra-pemrosesan dilatih untuk menghasilkan sistem pengenalan gandum yang baik dan benar. Ekstraksi Fitur yang terdapat dalam CNN melakukan encoding dari gambar yang telah diambil menjadi fitur dalam bentuk angka yang merepresentasikan gambar.



Gambar 2. Resize Gambar

Fitur Ekstraksi

Pembelajaran Mendalam atau deep learning merupakan sub-bidang khusus dalam pembelajaran mesin, yang menciptakan perspektif baru dalam representasi pembelajaran data dengan menekankan proses pembelajaran lapisan secara berturut-turut dari representasi yang semakin informatif (François Chollet, 2017). Jumlah lapisan yang turut berperan dalam pembentukan model data disebut sebagai kedalaman model. Convolutional Neural Network (CNN) merupakan evolusi dari multilayer perceptron (MLP) yang dirancang khusus untuk memproses data dua dimensi (Kasyanto & Rismiana Sari, 2023). CNN termasuk dalam jenis jaringan saraf mendalam karena memiliki tingkat kedalaman yang tinggi dan umumnya diterapkan pada data gambar. Pendekatan umum dan sangat efektif dalam pembelajaran mendalam pada sejumlah dataset gambar adalah melalui penggunaan jaringan yang telah mendapatkan pelatihan sebelumnya (Pretrained Network) (François Chollet, 2017). Dalam CNN, proses ekstraksi fitur melibatkan penggunaan basis konvulsional dari jaringan yang sudah mendapatkan pelatihan sebelumnya, dengan menjalankan data baru melalui basis tersebut dan melatih klasifikasi yang baru dihasilkan dari keluarannya.

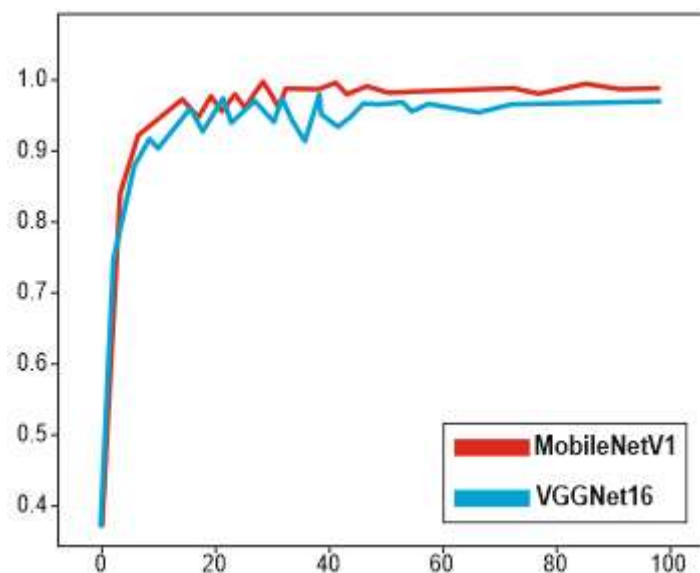
HASIL DAN DISKUSI

Dataset Training

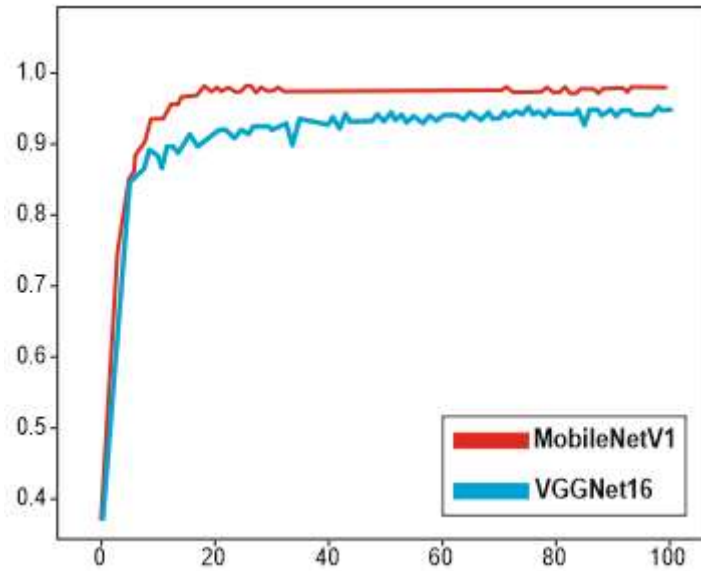
Dataset yang digunakan dalam penelitian identifikasi gandum terbagi dalam dua folder, yakni Train dan Test. Keseluruhan dataset menggunakan gambar RGB (tiga saluran warna) dan diubah ukurannya menjadi 224x224 piksel sesuai dengan penerapan arsitektur Transfer Learning CNN. Dalam konteks pengambilan dataset, gambar-gambar dalam format .jpg diambil sebagai dataset pelatihan sebanyak 80% secara acak dari folder Train pada setiap sampel gandum. Sementara itu, 20% sisanya diambil sebagai dataset validasi dari folder yang sama. Dataset validasi digunakan untuk menguji dan membandingkan hasil pelatihan dengan dataset pelatihan pada setiap tahap (epoch) penelitian. Dataset validasi untuk masing-masing jenis gandum juga dipisahkan dan disimpan dalam folder terpisah sesuai dengan nama jenisnya. Di sisi lain, dataset pengujian ditempatkan dalam folder terpisah yang berbeda dari dataset pelatihan dan validasi. Dataset pengujian ini menjadi dasar untuk menguji hasil pelatihan pada jaringan CNN yang diterapkan dalam penelitian ini. Jumlah data yang diambil dari tiga jenis gandum yang diteliti adalah sebanyak 195 data. Data tersebut dibagi menjadi dua kelompok utama, yaitu data pelatihan sebanyak 150 dan data pengujian sebanyak 45. Data ini akan melalui proses pengolahan menggunakan model CNN guna memperoleh hasil identifikasi yang optimal. Penting untuk mencatat bahwa penggunaan dataset yang memadai dan terstruktur secara baik menjadi kunci kesuksesan dalam melatih model dan menguji performanya. Hasil dari penelitian ini diharapkan memberikan kontribusi pada pemahaman dan pengembangan teknik identifikasi gandum melalui pendekatan Deep Learning, khususnya dengan penerapan arsitektur Transfer Learning CNN.

Hasil Training dan Testing

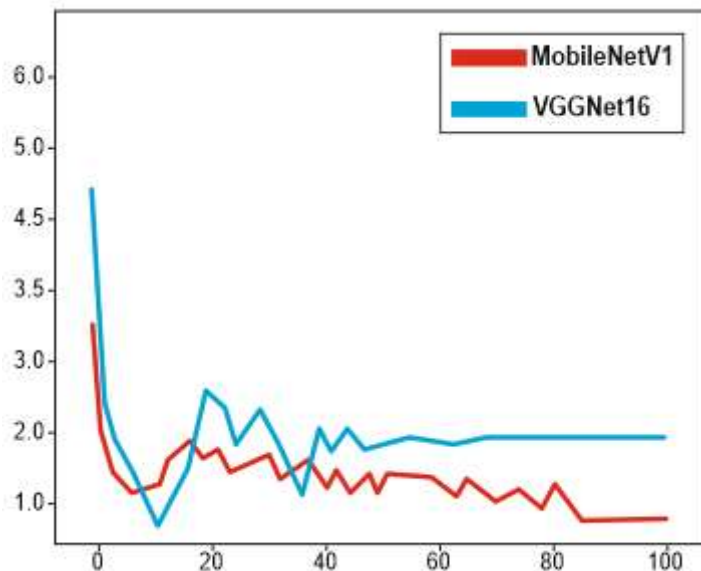
Pada Gambar 3, terlihat kurva akurasi dari dataset pelatihan, sementara pada Gambar 4, terlihat validasi akurasi dari model MobileNetV1. Terlihat bahwa kurva hasil pelatihan dan validasi meningkat mendekati nilai 1.0 seiring dengan peningkatan jumlah epoch. Pada Epoch terakhir, nilai akurasi pelatihan mencapai 1.0 dan nilai akurasi validasi mencapai 0.9842. Kurva akurasi pelatihan hampir sama dengan peningkatan kurva akurasi validasi, menunjukkan hasil pelatihan dengan kondisi yang baik.



Gambar 3. Kurva Akurasi



Gambar 4. Kurva Validasi



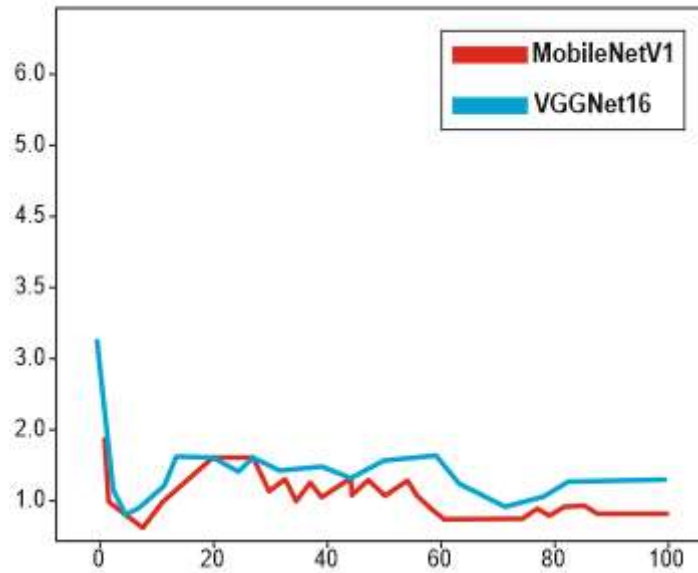
Gambar 5. Kurva Kesalahan Akurasi

Kurva kesalahan (error) akurasi pada Gambar 5 dan hasil MobileNetV1 selama pelatihan ditampilkan pada Gambar 6. Dari kurva tersebut, pada Epoch terakhir, nilai kesalahan pelatihan mencapai 0.0025 dan nilai kesalahan validasi mencapai 0.2993. Semakin mendekati 0 dan kurva kesalahan pelatihan hampir sama dengan penurunan kurva kesalahan validasi, menunjukkan hasil pelatihan sangat baik.


Pada Gambar 3, terlihat kurva akurasi dari dataset pelatihan, sementara pada Gambar 4, terlihat validasi akurasi dari model VGGNet16. Terlihat bahwa kurva hasil pelatihan dan validasi meningkat mendekati nilai 1.0 seiring dengan peningkatan jumlah epoch. Pada Epoch terakhir, nilai akurasi

pelatihan mencapai 1.0 dan nilai akurasi validasi mencapai 0.9682. Kurva akurasi pelatihan hampir sama dengan peningkatan kurva akurasi validasi, menunjukkan hasil pelatihan dengan kondisi yang baik.

Kurva kesalahan (error) akurasi pada Gambar 5 dan hasil VGGNet16 selama pelatihan ditampilkan pada Gambar 6. Dari kurva tersebut, pada Epoch terakhir, nilai kesalahan pelatihan mencapai 0.0361 dan nilai kesalahan validasi mencapai 0.3221. Semakin mendekati 0 dan kurva kesalahan pelatihan hampir sama dengan penurunan kurva kesalahan validasi, menunjukkan hasil pelatihan sangat baik.



Gambar 6. Kurva Kesalahan Validasi

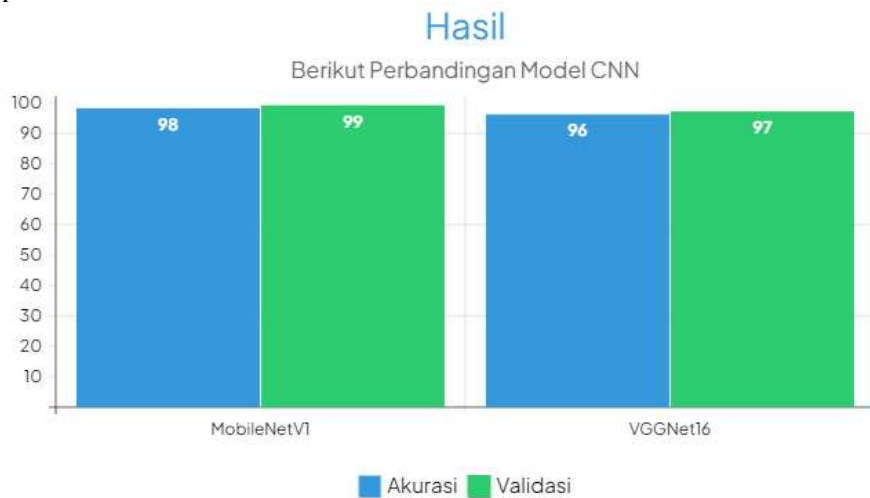


Gambar 7. Prediksi Klasifikasi Model CNN

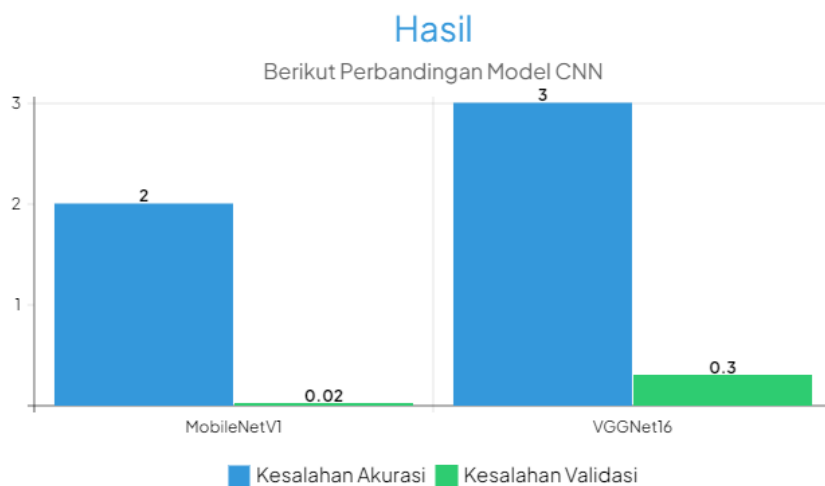
Gambar 7 menunjukkan hasil pengujian prediksi gandum menggunakan model CNN. Hasil pengujian ini memberikan gambaran tentang sejauh mana model dapat mengklasifikasikan varietas gandum dengan akurasi yang baik berdasarkan hasil pelatihan dan validasi sebelumnya.

Komparasi Hasil Penelitian

Gambar 8 dan Gambar 9 memberikan pandangan lebih rinci terkait kurva perbandingan akurasi dan tingkat kesalahan hasil pelatihan. Dari diagram tersebut, dapat dilihat bahwa seluruh tingkat akurasi pelatihan mencapai nilai maksimum mendekati 1. Hal ini menunjukkan bahwa model yang dikembangkan mampu mempelajari pola dengan sangat baik dari dataset pelatihan. Sementara itu, tingkat akurasi validasi juga menunjukkan performa yang baik, dihasilkan dengan stabil oleh arsitektur MobileNetV1 dengan mencapai akurasi 0.9842 pada dataset berkualitas baik. Konsistensi dan kualitas akurasi ini memperkuat validitas model.



Gambar 8. Demografi Grafik Hasil Akurasi dan Validasi



Gambar 9. Demografi Grafik Hasil Kesalahan Akurasi dan Validasi

Tabel 1. Hasil Komparasi Penelitian Terdahulu

| Penelitian | Judul | Metode | Hasil (Akurasi(%)) |
|---|---|------------------------------|--------------------|
| (I Wayan Suartika E. P et al., 2016) | Klasifikasi Citra Menggunakan Convolutional Neural Network pada Caltech 101 | Convolutional Neural Network | 20-50 |
| (Erlyna Nour Arrofiqoh & Harintaka, 2018) | Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi | | 93 |
| (Afif et al., 2020) | Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network(CNN) | | 93 |
| (Salimah et al., 2021) | Eksplorasi dan Penentuan Ras Penyebab Penyakit Blas Padi di Kabupaten Maros | | 90 |
| Penelitian Ini | Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum | | 98 |

Selanjutnya, analisis dari diagram menunjukkan bahwa seluruh tingkat kesalahan pelatihan mendekati nilai minimum, mendekati 0. Hal ini mencerminkan kemampuan model dalam menghindari kesalahan ketika menghadapi data yang sudah pernah dilihat. Kesalahan validasi juga tetap rendah, dengan nilai kesalahan sekitar 0.0025 pada arsitektur MobileNetV1. Keberhasilan ini menunjukkan bahwa model dapat menggeneralisasi dengan baik pada data baru dan belum pernah dilihat sebelumnya.

Tabel 1, yang membandingkan dengan penelitian-penelitian sebelumnya, menyoroti pergeseran metode dari Machine Learning ke Deep Learning. Penelitian ini tergolong sebagai salah satu upaya untuk meningkatkan pendekatan identifikasi varietas gandum dengan menerapkan Deep Learning. Pergeseran ini menandai peningkatan signifikan dalam kemampuan model untuk memahami dan memproses informasi yang lebih kompleks, terutama pada konteks identifikasi varietas gandum.

Hasil pengamatan dan perbandingan ini menunjukkan bahwa pendekatan Deep Learning, khususnya menggunakan arsitektur MobileNetV1, memberikan kinerja yang sangat baik dalam identifikasi varietas gandum. Keberhasilan ini dapat memberikan kontribusi positif dalam pengembangan teknik identifikasi varietas gandum melalui penerapan metode Deep Learning, membuka potensi untuk penggunaan lebih lanjut dalam penelitian dan aplikasi di lapangan.

KESIMPULAN

Pengidentifikasian menggunakan model arsitektur CNN (transfer learning) berhasil mengenali tiga kelas Dataset Vitreous, Starcy, dan Foreign Matters, pada gambar gandum dengan data pelatihan dan data uji. Data pelatihan berjumlah 150 data gambar, sedangkan data uji berjumlah 45 citra. CNN (Transfer Learning) berhasil memodelkan dengan sukses dan menghasilkan nilai akurasi yang stabil dan sangat baik dengan MobileNetV1 mencapai 98%. Penyelidikan ini penting untuk aplikasi di bidang pertanian dan pengolahan gandum, di mana kemampuan mengidentifikasi kandungan gandum seperti

Vitreous, Starcy, dan Foreign Matters dapat membantu dalam menghasilkan produk gandum berkualitas. Metode transfer learning dengan menggunakan MobileNetV1 membuktikan kehandalannya dalam mengenali variasi kelas pada dataset yang dihadapi, terutama dalam kasus identifikasi tiga kelas gandum tersebut. Penerapan teknologi deep learning, seperti CNN dengan arsitektur transfer learning, memungkinkan pengenalan objek pada gambar dengan tingkat akurasi yang tinggi. Keberhasilan dalam mengenali tiga kelas pada gambar gandum membuktikan bahwa pendekatan ini dapat diandalkan. Implikasi praktisnya dapat mencakup peningkatan kualitas dan efisiensi dalam pengolahan gandum, serta memberikan dasar bagi pengembangan teknologi identifikasi bahan pada produk pertanian lainnya. Selain itu, penelitian ini memberikan kontribusi pada literatur ilmiah terkait aplikasi deep learning dalam bidang pertanian dan analisis citra.

DAFTAR PUSTAKA

- Afif, M., Fawwaz, A., Ramadhani, K. N., & Sthevanie, F. (2020). Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network(CNN). *E-Proceeding of Engineering*, 8(1).
- Alhamdani, A. A. (2022). Application of Deep Learning using Convolutional Neural Network (CNN) Algorithm for Gesture Recognition. *Journal of Software Engineering, Information and Communication Technology (SEICT)*, 4(1), 61–68. <https://doi.org/10.17509/seict.v2i1.34673>
- Astriningsih, W., & Hatta Fudholi, D. (2023). Identifikasi Multi Aspek Dan Sentimen Analisis Pada Review Hotel Menggunakan Deep Learning. *Jurnal Teknik Informatika Dan Sistem Informasi*, 10(3), 433. <http://jurnal.mdp.ac.id>
- Azmi, K., Defit, S., & Putra Indonesia YPTK Padang Jl Raya Lubuk Begalung-Padang-Sumatera Barat, U. (2023). Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat. *Jurnal Unitek*, 16(1), 2023.
- Dandi Mochamad Reza, Satria Mandala, Salim M. Zaki, & Eileen Su Lee Ming. (2023). Deep Learning Autoencoder Study on ECG Signals. *Jurnal Nasional Teknik Elektro*, 12(3). <https://doi.org/10.25077/jnte.v12n3.1117.2023>
- Dwi Putro, A., & Tantyoko, H. (2023). Hybrid Algoritma Vgg16-Net Dengan Support Vector Machine Untuk Klasifikasi Jenis Buah dan sayuran. *JTIM : Jurnal Teknologi Informasi Dan Multimedia*, 5(2), 56–65. <https://doi.org/10.35746/jtim.v5i2.335>
- Erlyna Nour Arrofiqoh, & Harintaka. (2018). IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI. *Geomatika*, 24(2).
- Fernando Pratama, A., Basuki Kurniawan, T., Arrova Dewi, D., Jenderal Ahmad Yani No, J., Palembang, K., Selatan, S., Studi Teknik Komputer, P., Vokasi, F., & Bina Darma, U. (2023). Implementasi Analisis Sentimen dan Model Deep Learning Untuk Prediksi Harga Bitcoin. *Jurnal Jupiter*, 15(1).
- François Chollet. (2017). *Deep Learning with Python*.
- Hayati, N. (2023). KLASIFIKASI JENIS BUNGA MAWAR MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOUR. In *Jurnal Informatika dan Riset (IRIS)* (Vol. 1, Issue 1).
- I Wayan Suartika E. P, Arya Yudhi Wijaya, & Rully Soelaiman. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101. *JURNAL TEKNIK ITS*, 5(1).
- Jack Billie Chandra, & Dewi Nasien. (2023). Application Of Machine Learning K-Nearest Neighbour Algorithm To Predict Diabetes. *International Journal of Electrical, Energy and Power System Engineering (IJEPPSE)*, 6(2). <http://www.ijeppse.ejournal.unri.ac.id>

Kasyanto, H., & Rismiana Sari, R. (2023). PENERAPAN ALGORITMA MULTILAYER

- PERCEPTRON (MLP) UNTUK MEMPREDIKSI DEBIT DI SUNGAI CITARUM BAGIAN HULU (POS PENGUKURAN MAJALAYA), KAB.BANDUNG, JAWA BARAT. *Jurnal Potensi*, 25(1). <http://103.110.9.91/>.
- Kaya, E., & Saritas, I. (2019). Towards a real-time sorting system: Identification of vitreous durum wheat kernels using ANN based on their morphological, colour, wavelet and gaborlet features. *Computers and Electronics in Agriculture*, 166, 105016. <https://doi.org/10.1016/J.COMPAG.2019.105016>
- Niki Nadialita, Ashabul Anhar, & Ali Muhammad Muslih. (2023). Analisis Perubahan Tutupan Lahan Kesatuan Hidrologi GambutKrueng Wonki- Krueng Gubon Di Kabupaten Aceh Barat. *JURNAL ILMIAH MAHASISWA PERTANIAN*, 8(4).
- Putra, N. S., Hutabarat, B. F., & Khaira, U. (2023). Implementasi Algoritma Convolutional Neural Network Untuk Identifikasi Jenis Kelamin Dan Ras. *Decode: Jurnal Pendidikan Teknologi Informasi*, 3(1), 82–93. <https://doi.org/10.51454/decode.v3i1.123>
- Rifa, A., Sujiwanto, I., Ronggo Bintang Pratomo Prawirodirjo, R., & Palupingsih, P. (2023). Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat menggunakan Arsitektur VGG, MobileNet, dan Inception V3 Analysis Tomato Leaf Health Classification Model Performance Comparison Using VGG, MobileNet, and Inception V3. *Jurnal Ilmu Komputer Agri-Informatika*, 10(1). <https://jurnal.ipb.ac.id/index.php/jika>
- Salimah, N. A., Tutik Kuswinanti, & Andi Nasruddin. (2021). Eksplorasi dan Penentuan Ras Penyebab Penyakit Blas Padi di Kabupaten Maros. *Jurnal Fitopatologi Indonesia*, 17(2), 41–48. <https://doi.org/10.14692/jfi.17.2.41-48>
- Saptono, M., Rahayuningsih, S. E. A., Christiana, I., Kusumadati, W., & Nafisah, Z. (2023). Pengenalan dan Pemanfaatan Tanaman Penghasil Karbohidrat Non Beras dan Gandum sebagai Bahan Dasar Usaha Kuliner untuk Siswa Sekolah Menengah Kejuruan. *PengabdianMu: Jurnal Ilmiah Pengabdian Kepada Masyarakat*, 8(5), 656–664. <https://doi.org/10.33084/pengabdianmu.v8i5.5010>
- Wibowo, A., Lusiana, L., & Dewi, T. K. (2023). Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) Untuk Deteksi Buah Segar Dan Busuk. *Paspalum: Jurnal Ilmiah Pertanian*, 11(1), 123. <https://doi.org/10.35138/paspalum.v11i1.489>
- Wicaksono, F. Y., Ratnasari, A., Shabira, R. H., Sutrisna, R. E., & Ruminta, R. (2020). Respons varietas-varietas gandum terhadap pemupukan silika organik di dataran medium. *Kultivasi*, 19(2). <https://doi.org/10.24198/kultivasi.v19i2.26746>