

ANALISIS PERFORMA METODE CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR CONVNEXT DALAM KLASIFIKASI VARIETAS BERAS

Achmad Faouzi¹; Nana suarna²; Agus Bahtiar³; Cep lukman rohma⁴; Gifthera dwilestari⁵;

Program Studi Teknik Informatika¹²
Program Studi Sistem Informasi³⁵
Program Studi Rekayasa perangkat Lunak⁴

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

(*) Corresponding Author : achamdfaouzi@gmail.com
Received: date; Accepted: date; Published: date

Abstract—Rice variety classification is essential for ensuring product quality and supporting agricultural and trade activities, particularly in Indonesia, where rice consumption is high and imports continue to rise. Manual identification performed by agricultural experts is often inconsistent, time-consuming, and prone to errors, especially when distinguishing varieties with very subtle morphological differences such as Arborio, Basmati, and Ipsala. Advances in deep learning especially modern architectures like ConvNeXt provide new opportunities to improve accuracy and efficiency in image-based classification. This research employs a quantitative experimental approach by implementing the ConvNeXt architecture for the classification of three rice varieties. The dataset used is the Rice Image Dataset from Kaggle, consisting of 1,050 images evenly distributed across the three classes. Preprocessing included resizing images to 224×224 pixels and applying augmentations such as rotation, flipping, and zooming. A pretrained ConvNeXt model (ImageNet weights) was fine-tuned by adjusting the classifier to produce three output classes. Model performance was evaluated using accuracy, precision, recall, F1-score, and confusion matrix analysis. The ConvNeXt model achieved excellent performance, reaching a test accuracy of 98%, precision of 0.98, recall of 0.98, and an F1-score of 0.98. The confusion matrix shows a very low rate of misclassification: 61 out of 62 Arborio images, 68 out of 69 Basmati images, and 76 out of 79 Ipsala images were correctly classified. The convergence of training and validation curves indicates that the model is in a good-fit condition without signs of overfitting. Data augmentation significantly contributed to improving the model's ability to recognize fine-grained textures and visual patterns. ConvNeXt demonstrates high effectiveness in rice variety classification, showing strong feature extraction capabilities and excellent accuracy in distinguishing visually similar grains. The model outperforms traditional CNN approaches reported in previous studies and shows strong potential for implementation in automated rice quality inspection systems, supporting efficiency in agriculture and food processing industries.

Keywords: ConvNeXt, Rice Classification, Deep Learning, Image Processing, CNN.

Abstrak—Klasifikasi varietas beras merupakan proses penting dalam memastikan kualitas dan pemilihan komoditas beras yang sesuai, terutama di tengah meningkatnya impor dan keragaman varietas di Indonesia. Proses identifikasi manual yang dilakukan oleh ahli pertanian sering kali tidak konsisten, memakan waktu, serta rentan terhadap kesalahan, khususnya pada varietas beras dengan kemiripan morfologi yang tinggi seperti Arborio, Basmati, dan Ipsala. Perkembangan teknologi deep learning, khususnya arsitektur modern ConvNeXt, membuka peluang baru dalam meningkatkan akurasi dan efisiensi klasifikasi berbasis citra. Penelitian ini menggunakan pendekatan eksperimen kuantitatif dengan mengimplementasikan model ConvNeXt untuk klasifikasi tiga varietas beras. Dataset yang digunakan merupakan Rice Image Dataset dari Kaggle berjumlah 1.050 citra, yang dibagi menjadi set pelatihan (80%) dan validasi/pengujian (20%). Preprocessing meliputi normalisasi ukuran citra menjadi 224×224 piksel dan penerapan augmentasi seperti rotasi, flip, dan zoom. Model ConvNeXt pretrained ImageNet

dimodifikasi pada bagian classifier untuk menghasilkan tiga kelas output. Evaluasi performa dilakukan menggunakan metrik akurasi, precision, recall, F1-score, serta analisis confusion matrix. Model ConvNeXt menunjukkan performa yang sangat baik dengan akurasi pengujian sebesar 98%, precision 0,98, recall 0,98, dan F1-score 0,98. Confusion matrix memperlihatkan tingkat kesalahan prediksi yang sangat rendah: 61/62 citra Arborio diklasifikasikan benar, 68/69 citra Basmati benar, dan 76/79 citra Ipsala benar. Performa yang stabil antara data pelatihan dan validasi menunjukkan bahwa model berada pada kondisi good fit tanpa indikasi overfitting. Augmentasi data terbukti membantu model dalam mengenali variasi tekstur dan bentuk butir beras yang halus. ConvNeXt terbukti efektif sebagai model klasifikasi varietas beras dengan tingkat akurasi yang tinggi dan kemampuan yang kuat dalam mengekstraksi fitur visual beras. Arsitektur ini mampu membedakan varietas dengan kemiripan morfologi yang tipis dan memberikan performa lebih baik dibanding pendekatan CNN tradisional yang dilaporkan pada penelitian terdahulu. Dengan demikian, ConvNeXt berpotensi digunakan dalam sistem otomatis klasifikasi beras untuk mendukung efisiensi industri pertanian dan pengolahan pangan.

Kata kunci: ConvNeXt, Klasifikasi Beras, Deep Learning, Pengolahan Citra, CNN.

INTRODUCTION

Beras (*Oryza sativa* L.) merupakan salah satu komoditas pangan dengan tingkat konsumsi yang sangat tinggi di berbagai negara, menjadikannya sumber energi utama bagi sebagian besar penduduk dunia. Kandungan karbohidrat dalam beras didominasi oleh pati yang mencapai sekitar 85–90% dari bobot keringnya, sehingga beras berperan penting sebagai penyedia kalori dalam pola makan sehari-hari. Selain pati, beras juga mengandung komponen karbohidrat lain seperti pentosa dengan proporsi sekitar 2,0–2,5%, serta serat struktural berupa selulosa dan hemiselulosa yang mendukung nilai fungsionalnya sebagai bahan pangan. Pada beras pecah kulit, kandungan gula berkisar antara 0,6–1,4%, yang turut memengaruhi cita rasa dan karakteristik sensori produk olahannya. Variasi komposisi ini berkontribusi terhadap perbedaan mutu, tekstur, dan kualitas gizi beras antarvarietas, sehingga pemahaman terhadap struktur kimianya menjadi penting dalam kajian pangan dan teknologi hasil pertanian. Dengan demikian, beras tidak hanya bernilai strategis secara ekonomi, tetapi juga memiliki signifikansi nutrisi dan fungsional yang luas dalam sistem pangan global. (Syahbanu et al., 2023). Kandungan gizi yang terdapat dalam beras menjadikan komoditas ini memiliki peran yang sangat strategis dalam pemenuhan kebutuhan pangan masyarakat. Sebagai sumber makanan pokok, beras sulit digantikan oleh bahan pangan lain karena kemampuannya menyediakan karbohidrat yang mudah dicerna dan cepat diubah menjadi energi bagi tubuh. Keterikatan ini tidak hanya berkaitan dengan aspek nutrisi, tetapi juga dengan kebiasaan konsumsi yang telah terbentuk dalam jangka waktu

lama. Oleh sebab itu, keberadaan beras sering dipandang sebagai prioritas utama dalam memenuhi kebutuhan energi harian, khususnya bagi masyarakat yang mengandalkannya sebagai sumber kalori utama. Di banyak daerah, beras bahkan dianggap sebagai penentu rasa kenyang, sehingga perannya dalam pola konsumsi tidak dapat dengan mudah dialihkan kepada komoditas lain. Kondisi ini menunjukkan bahwa beras memiliki nilai fungsional dan budaya yang saling melengkapi dalam sistem pangan nasional. Dengan demikian, ketersediaannya menjadi faktor penting bagi stabilitas konsumsi dan ketahanan pangan masyarakat. (Simamora et al., 2023).

Keberagaman pada komoditas beras tidak semata-mata ditentukan oleh kandungan nutrisinya, tetapi juga oleh variasi varietas yang memiliki peran penting dalam sistem pertanian dan pangan. Setiap varietas beras menunjukkan karakteristik unik yang berpengaruh terhadap produktivitas, mutu hasil panen, serta kemampuan adaptasi tanaman terhadap kondisi lingkungan di berbagai daerah. Dalam praktik budidaya, perbedaan ini menghasilkan variasi pada rasa, tekstur, komposisi gizi, dan ketahanan tanaman terhadap berbagai tekanan biologis maupun ekologis. Keragaman tersebut memberikan fleksibilitas bagi konsumen dan pelaku industri pangan untuk memilih jenis beras yang paling sesuai dengan kebutuhan, preferensi, maupun tujuan pengolahan. Mengingat kompleksitas pasar beras yang terus berkembang, identifikasi varietas yang akurat menjadi aspek yang sangat penting untuk memastikan terpenuhinya permintaan konsumen sekaligus menjaga keberlanjutan pasokan secara stabil. Oleh karena itu, pemahaman yang tepat mengenai karakteristik setiap varietas

merupakan langkah strategis dalam mendukung efisiensi rantai pasok dan ketahanan pangan (Noorizki & Kusumawati, 2023).

Populasi masyarakat Indonesia terus berkembang pesat seiring bertambahnya jumlah penduduk setiap tahunnya. Meningkatnya jumlah penduduk di Indonesia mengakibatkan kebutuhan pokok pangan juga meningkat, terutama beras. Indonesia, berada di urutan ke-empat dunia setelah Tiongkok dalam tingkat konsumsi beras dikarenakan mayoritas masyarakat Indonesia mengonsumsi beras sebagai makanan pokok. Indonesia terus bergantung pada impor beras, dikarenakan produksi beras di Indonesia tidak dapat memenuhi kebutuhan konsumsi masyarakat Indonesia. Tujuannya adalah untuk memastikan bahwa stok beras Indonesia tetap tersedia untuk menjaga ketahanan pangan masyarakatnya (Yunitasari, 2025).

Masuknya berbagai varietas beras dari berbagai negara menyebabkan para importir di Indonesia menghadapi tantangan dalam melakukan proses sortir dan pengelompokan produk secara akurat. Berdasarkan laporan Badan Pusat Statistik (BPS) tahun 2022, tercatat bahwa India, Pakistan, Vietnam, Thailand, Myanmar, dan Jepang merupakan negara dengan volume ekspor beras tertinggi ke Indonesia, dengan total sekitar 429.207 ton beras yang diimpor. Arus masuk komoditas yang begitu besar ini menuntut ketelitian dalam identifikasi varietas agar distribusi dan pengolahannya dapat dilakukan secara tepat. Dalam penelitian ini, fokus kajian diarahkan pada tiga varietas beras impor yang banyak beredar, yaitu Arborio, Basmati, dan Ipsala, karena ketiganya memiliki karakteristik fisik dan kualitas kuliner yang berbeda serta penting untuk dikenali secara cermat dalam proses klasifikasi. Pendalaman terhadap ketiga varietas ini diharapkan dapat memberikan kontribusi pada peningkatan akurasi identifikasi beras dalam rantai pasok. (Noorizki & Kusumawati, 2023).

Dalam konteks pemeriksaan kualitas beras, penggunaan teknologi pengolahan citra digital dapat menjadi alternatif yang efektif untuk mengatasi kelemahan pemeriksaan manual yang dilakukan oleh ahli pertanian. Pemeriksaan manual sering kali menghadapi masalah seperti waktu yang lama dan inkonsistensi hasil akibat keterbatasan visual serta potensi kelelahan pengamat (Supriadi et al., 2021).

Kemajuan teknologi pengolahan citra dan pembelajaran mendalam (*deep learning*) memungkinkan proses klasifikasi varietas beras dilakukan secara otomatis dan lebih akurat. Salah satu arsitektur modern yang sangat berpengaruh dalam pengenalan citra adalah ConvNeXt, yang

merupakan CNN generasi terbaru yang dirancang dengan struktur modern, efisien, dan kuat dalam mengekstraksi fitur visual yang detail. ConvNeXt terbukti memiliki kemampuan representasi fitur yang baik untuk tugas klasifikasi citra, termasuk pada objek dengan perbedaan yang sangat halus seperti varietas beras (Arct et al., 2025; Neuwieser et al., 2025).

Berdasarkan tantangan dan peluang yang ada, penelitian ini bertujuan untuk mengevaluasi performa CNN dengan arsitektur ConvNeXt dalam klasifikasi varietas beras. Dengan menggunakan ConvNeXt, diharapkan dapat meningkatkan akurasi identifikasi varietas, mempercepat proses klasifikasi, serta menyediakan solusi yang lebih andal dibandingkan metode tradisional atau algoritma machine learning klasik. Hal ini sejalan dengan studi yang menunjukkan bahwa ConvNeXt memiliki kemampuan representasi fitur yang baik dan efisiensi dalam mengolah data citra, yang sangat penting dalam pengenalan objek dengan perbedaan halus seperti varietas beras (H. Li et al., 2023; Zhang et al., 2025).

MATERIALS AND METHODS

Prosedur penelitian ini disusun melalui serangkaian tahapan yang dilaksanakan secara sistematis, dimulai dari proses pemahaman karakteristik data hingga diperolehnya hasil akhir evaluasi performa model. Setiap tahapan dirancang agar saling berkaitan dan mendukung keberhasilan proses analisis, sehingga alur kerja penelitian dapat berjalan terstruktur dan terukur. Tahap awal melibatkan identifikasi komposisi dan kualitas dataset untuk memastikan bahwa data memenuhi kebutuhan klasifikasi. Selanjutnya, dilakukan proses preprocessing dan augmentasi guna meningkatkan konsistensi dan keberagaman citra. Setelah itu, model dikonfigurasi dan dilatih menggunakan parameter yang telah ditetapkan, sehingga model mampu mempelajari pola visual dari setiap kelas varietas beras. Proses pelatihan kemudian diikuti oleh tahap evaluasi yang bertujuan mengukur kinerja model berdasarkan metrik akurasi dan metrik lainnya. Pada akhirnya, seluruh rangkaian prosedur ini memberikan landasan ilmiah yang kuat untuk memperoleh hasil pengujian model yang valid dan dapat dipertanggungjawabkan. Adapun tahapan yang dilakukan dijabarkan secara rinci pada bagian berikutnya.

Eksplorasi dan Analisis Dataset

Tahap ini bertujuan untuk memahami isi dan karakteristik dataset sebelum diproses lebih lanjut. Langkah-langkahnya adalah:

1. Menghitung jumlah data
Menghitung total citra yang ada (1.050 gambar) dan jumlah citra untuk setiap kelas varietas beras, yaitu *Arborio*, *Basmati*, dan *Ipsala* (masing-masing sekitar 350 gambar).
2. Mengecek keseimbangan kelas
Mengevaluasi apakah jumlah data tiap kelas seimbang atau tidak, sehingga dapat diketahui apakah perlu dilakukan penanganan khusus.
3. Membuat visualisasi data
Menyajikan hasil perhitungan dalam bentuk tabel dan grafik batang sebagai gambaran komposisi dataset.

Preprocessing dan Augmentasi Citra

Tahap ini dilakukan untuk menyiapkan data agar dapat diproses oleh model dan mencegah kesalahan saat pelatihan.

Langkah-langkahnya:

1. Membagi dataset

Dataset dibagi menjadi Dua bagian:

- A. **Training Set (80%)**
- B. **Validation Set (20%)**

2. Menyeragamkan ukuran citra

Tahap persiapan atau data preprocessing merupakan proses penting untuk mengubah data mentah menjadi format yang layak digunakan dalam pemodelan klasifikasi. Pada penelitian ini, prosedur preprocessing dilakukan dengan menyesuaikan ukuran seluruh citra menjadi 224×224 piksel agar memiliki dimensi seragam dan tetap mempertahankan format warna RGB sebagai standar representasi visual. Penyeragaman ini memastikan bahwa citra dapat diproses secara konsisten oleh model berbasis deep learning. Setelah penyesuaian ukuran, dataset dibagi menjadi dua subset utama, yaitu 80% sebagai training data yang berfungsi untuk melatih model dalam mengenali pola-pola visual, serta 20% sebagai validation data yang digunakan untuk mengevaluasi performa model selama proses pelatihan. Pembagian ini bertujuan mengurangi risiko overfitting, yaitu kondisi ketika model terlalu menyesuaikan diri dengan data pelatihan sehingga kehilangan kemampuan generalisasi terhadap data baru. Melalui tahapan ini, kualitas dan konsistensi masukan ke dalam model dapat terjamin, sehingga mendukung pelatihan yang lebih stabil dan akurat.

3. Melakukan augmentasi data

Menambahkan variasi pada citra merupakan langkah penting dalam proses augmentasi untuk meningkatkan kemampuan model dalam mengenali pola secara lebih komprehensif. Melalui teknik ini, citra mengalami transformasi tertentu tanpa mengubah label aslinya, sehingga model memperoleh paparan terhadap berbagai kemungkinan kondisi visual yang mungkin

muncul pada data nyata. Proses tersebut membantu jaringan saraf dalam mengembangkan representasi fitur yang lebih kuat dan tidak bergantung pada pola tunggal. Selain itu, penambahan variasi visual terbukti efektif dalam mengurangi risiko overfitting, karena model tidak hanya belajar dari citra dengan karakteristik yang seragam. Dengan demikian, teknik augmentasi memungkinkan model membangun pemahaman yang lebih mendalam terhadap struktur citra, sekaligus meningkatkan akurasi dalam tugas klasifikasi. Upaya ini pada akhirnya berkontribusi pada performa model yang lebih stabil dan adaptif pada berbagai kondisi input..

3.5.3 Implementasi Model ConvNeXt

Tahapan ini merupakan proses membangun dan menyesuaikan model agar mampu mengenali tiga kelas varietas beras.

Langkah-langkahnya:

1. **Menggunakan model ConvNeXt standar (pretrained)**

Model memanfaatkan bobot prelatih dari *ImageNet* untuk menginisialisasi parameter awal, sehingga proses pelatihan dapat berlangsung lebih efisien dan stabil. Penggunaan bobot prelatih ini memungkinkan model memulai pembelajaran dengan representasi fitur dasar yang sudah terbentuk, sehingga waktu pelatihan lebih singkat dan performa yang dihasilkan cenderung lebih optimal dibandingkan pelatihan dari awal (*training from scratch*). Pendekatan ini juga membantu model beradaptasi lebih baik terhadap pola visual pada dataset penelitian, terutama ketika jumlah data tidak terlalu besar.

2. **Menyesuaikan output model**

Bagian akhir model atau *classifier layer* dimodifikasi sehingga mampu menghasilkan tiga keluaran kelas yang sesuai dengan kebutuhan penelitian. Penyesuaian ini dilakukan dengan mengganti lapisan klasifikasi standar pada arsitektur awal dengan lapisan baru yang secara spesifik dirancang untuk mengenali tiga kategori varietas beras. Modifikasi tersebut memastikan bahwa struktur model selaras dengan tujuan analisis, sekaligus memungkinkan proses pelatihan berjalan secara lebih terarah terhadap kelas yang ditetapkan..

3. **Menentukan parameter pelatihan**

Pengaturan parameter dilakukan dengan menyesuaikan nilai *learning rate*, *batch size*, jenis algoritma optimasi (*optimizer*), serta jumlah *epoch* yang digunakan selama proses pelatihan. Konfigurasi parameter ini memiliki peran penting dalam menentukan stabilitas dan

kecepatan konvergensi model, sehingga pemilihan nilainya harus dilakukan secara cermat agar proses pembelajaran berlangsung efektif dan menghasilkan performa klasifikasi yang optimal..

Pelatihan dan Evaluasi Model

Tahap ini dilaksanakan untuk mengevaluasi sejauh mana model mampu mengenali serta mengklasifikasikan setiap varietas beras secara akurat. Melalui proses evaluasi ini, performa model dapat diukur berdasarkan kemampuan identifikasi pola visual yang terkandung dalam citra, sehingga diperoleh gambaran yang jelas mengenai efektivitas model dalam menjalankan tugas klasifikasi yang telah ditetapkan. Hasil evaluasi pada tahap ini juga menjadi dasar untuk menilai apakah model telah belajar dengan baik dan mampu melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya.

RESULTS AND DISCUSSION

Implementasi Model ConvNeXt

Model yang disajikan adalah arsitektur jaringan saraf tiruan (JST) konvolusional yang dirancang untuk tugas klasifikasi, yang secara umum merupakan pendekatan *transfer learning* atau *fine-tuning*. Arsitektur ini terdiri dari enam lapisan utama yang tersusun secara sekuensial.

Lapisan Masukan dan Pra-pemrosesan

Proses dimulai dengan `input_layer` (`InputLayer`), yang menerima masukan dengan dimensi 224×224 piksel dan tiga saluran warna (RGB). Bentuk *batch* yang tidak ditentukan (`None`) mengindikasikan fleksibilitas dalam ukuran *batch* selama pelatihan atau inferensi. Selanjutnya, data augmentation (`Sequential`) berfungsi sebagai lapisan pra-pemrosesan yang diintegrasikan langsung ke dalam model. Meskipun tidak berkontribusi pada jumlah parameter yang dapat dilatih, lapisan ini esensial untuk meningkatkan *robustness* model dan mengurangi *overfitting* melalui transformasi acak pada data masukan.

Lapisan Fitur Utama (Backbone)

Jantung dari model ini adalah *convnext tiny* (`Functional`), yang merupakan implementasi dari arsitektur ConvNeXt Tiny. Lapisan ini bertindak sebagai *backbone* ekstraksi fitur yang kuat. Output dari lapisan ini memiliki dimensi spasial yang sangat direduksi menjadi 7×7 dengan 768 peta fitur (*feature maps*). Parameter yang Signifikan Lapisan `convnext_tiny` memuat sejumlah \$27.820.128\$ parameter. Berdasarkan ringkasan parameter total, semua parameter pada lapisan ini diklasifikasikan sebagai non-trainable (\$27.820.128\$). Hal ini secara definitif menunjukkan bahwa arsitektur ini memanfaatkan

bobot yang sudah dilatih sebelumnya (*pre-trained weights*), dan *backbone* utamanya dibekukan (*frozen*) selama proses pelatihan. Ini adalah praktik standar dalam *transfer learning* untuk mempertahankan representasi fitur yang telah dipelajari dari *dataset* yang besar (misalnya, ImageNet).

Lapisan Klasifikasi (Head)

Setelah ekstraksi fitur, proses dilanjutkan menuju lapisan klasifikasi:

global_avg_pool (`GlobalAveragePooling2D`): Lapisan ini mereduksi dimensi spasial $7 \times 7 \times 768$ menjadi vektor fitur tunggal berdimensi 768. Dengan menghitung rata-rata spasial di seluruh peta fitur, ia secara efektif menghasilkan representasi ringkas dari fitur yang diekstraksi, sekaligus mengurangi jumlah parameter yang diperlukan untuk lapisan selanjutnya. Lapisan ini tidak memiliki parameter.

dropout_layer (`Dropout`): Lapisan ini berfungsi sebagai mekanisme regularisasi. Dengan mengatur sebagian input menjadi nol secara acak, ia mencegah *co-adaptation* dari fitur dan meningkatkan kemampuan generalisasi model, juga tanpa parameter yang dapat dilatih.

output_layer (`Dense`): Ini adalah lapisan keluaran fully-connected (`Dense`). Jumlah unit keluaran adalah 3, yang mengindikasikan bahwa model ini dirancang untuk menyelesaikan tugas klasifikasi tiga kelas (misalnya, *multiclass classification*).

4. Ringkasan Parameter dan Strategi Pelatihan

Total parameter model adalah \$27.822.435\$. Namun, distribusi parameter yang dapat dilatih (*trainable*) dan tidak dapat dilatih (*non-trainable*) menunjukkan strategi *fine-tuning* yang spesifik:

Non-trainable params: \$27.820.128\$ (Parameter *backbone* yang dibekukan).

Trainable params: \$2.307\$ (Parameter lapisan `Dense` keluaran).

Strategi ini dikenal sebagai *linear probing* atau *head fine-tuning*, di mana hanya *head* klasifikasi (lapisan `Dense`) yang dilatih menggunakan fitur-fitur yang diekstrak oleh *backbone* yang sudah dilatih sebelumnya dan dibekukan. Jumlah parameter yang sangat kecil yang dapat dilatih (\$2.307\$) memungkinkan pelatihan yang cepat dan efisien dengan risiko *overfitting* yang minimal pada *dataset* target yang kemungkinan berukuran lebih kecil.

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 224, 224, 3)	0
data_augmentation (Sequential)	(None, 224, 224, 3)	0
convnext_tiny (Functional)	(None, 7, 7, 768)	27,820,128
global_avg_pool (GlobalAveragePooling2D)	(None, 768)	0
dropout_layer (Dropout)	(None, 768)	0
output_layer (Dense)	(None, 3)	2,307
Total params: 27,822,435 (106.13 MB)		
Trainable params: 2,307 (9.01 KB)		
Non-trainable params: 27,820,128 (106.13 MB)		

Pelatihan dan Evaluasi Model

Analisis Kinerja Pelatihan Model Jaringan Saraf Tiruan Luaran yang disajikan merangkum proses pelatihan tahap awal (Feature Extraction) dari suatu model jaringan saraf tiruan (JST) selama 10 *epoch*. Fase ini umumnya melibatkan pembekuan (*freezing*) bobot lapisan ekstraktor fitur (*backbone*) dan hanya melatih lapisan klasifikasi (*head*) baru, suatu teknik yang dikenal sebagai Transfer Learning.

Konvergensi dan Stabilitas Pelatihan

Proses pelatihan menunjukkan konvergensi yang cepat dalam metrik kinerja, terutama dalam tiga *epoch* pertama:

Epoch 1: Model memulai dengan akurasi pelatihan yang relatif rendah (0.4393) dan *loss* yang tinggi (1.4212), tetapi segera menunjukkan kemampuan generalisasi yang baik dengan val accuracy mencapai 0.8000.

Epoch 2: Terjadi peningkatan signifikan. *Accuracy* pelatihan melonjak menjadi 0.7365 dan val accuracy mencapai 0.9476. Penurunan *loss* yang drastis (dari 1.4212 menjadi 0.6401 pada pelatihan dan dari 0.6951 menjadi 0.3929 pada validasi) mengindikasikan bahwa model dengan cepat mempelajari representasi yang relevan dari *feature* yang sudah diekstrak.

Epoch 3: *Accuracy* pelatihan terus meningkat menjadi 0.9473, sementara val accuracy sedikit menurun menjadi 0.9429, menunjukkan model telah mencapai tingkat kinerja yang sangat tinggi.

2. Performa Akhir dan Generalisasi

Pada akhir 10 *epoch*, model mencapai kinerja yang stabil dan optimal:

Akurasi Pelatihan Akhir: Model mencapai akurasi tertinggi **\$0.9907\$** pada *Epoch 8*, dan stabil di sekitar **\$0.9864\$** pada *Epoch 10*. Hal ini mengindikasikan bahwa model telah berhasil meminimalkan *training loss* (**\$0.0913\$**) dan sangat cocok dengan data pelatihan.

Akurasi Validasi Akhir: Metrik yang paling krusial, val accuracy, mencapai puncaknya pada *Epoch 10* dengan nilai **\$0.9762\$**. *Validation loss* juga mencapai nilai terendah (**\$0.1183\$**).

Kesenjangan Kinerja (*Generalization Gap*): Kesenjangan antara *training accuracy* (\$0.9864\$) dan *validation accuracy* (\$0.9762\$) pada *Epoch 10* relatif kecil. Demikian pula, kesenjangan antara *training loss* (\$0.0913\$) dan *validation loss* (\$0.1183\$) juga minimal. Kesenjangan yang kecil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dan tidak mengalami *overfitting* yang signifikan terhadap data pelatihan.

3. Efisiensi Komputasi


Waktu yang diperlukan per *step* (**time/step**) menunjukkan efisiensi komputasi yang tinggi dan stabil:

Setelah *Epoch 1* yang mungkin mencakup *overhead* awal (158s), waktu pelatihan per *step* sangat cepat dan konsisten, berkisar antara **\$369 \text{ ms/step}\$** hingga **\$402 \text{ ms/step}\$**. Konsistensi ini menegaskan bahwa pelatihan berjalan lancar dan sumber daya komputasi dimanfaatkan secara efisien.


Secara keseluruhan, hasil pelatihan tahap awal ini menunjukkan keberhasilan strategi *transfer learning*. Model berhasil dilatih untuk mencapai akurasi validasi yang sangat tinggi (sekitar 97.6%) hanya dengan melatih lapisan klasifikasi, memanfaatkan efektivitas fitur yang telah dipelajari oleh *backbone* sebelumnya. Hal ini membuka jalan untuk tahap *fine-tuning* selanjutnya (jika diperlukan) untuk memaksimalkan kinerja lebih lanjut.

```
Memulai pelatihan tahap awal (Feature Extraction)...
Epoch 1/10 158s 2s/step - accuracy: 0.4393 - loss: 1.4212 - val_accuracy: 0.8000 - val_loss: 0.6951
Epoch 2/10 27/27 10s 369ms/step - accuracy: 0.7365 - loss: 0.6401 - val_accuracy: 0.9476 - val_loss: 0.3929
Epoch 3/10 27/27 10s 385ms/step - accuracy: 0.9473 - loss: 0.3384 - val_accuracy: 0.9429 - val_loss: 0.2805
Epoch 4/10 27/27 10s 378ms/step - accuracy: 0.9760 - loss: 0.2491 - val_accuracy: 0.9381 - val_loss: 0.2324
Epoch 5/10 27/27 10s 379ms/step - accuracy: 0.9879 - loss: 0.1722 - val_accuracy: 0.9429 - val_loss: 0.1952
Epoch 6/10 27/27 10s 387ms/step - accuracy: 0.9881 - loss: 0.1550 - val_accuracy: 0.9667 - val_loss: 0.1633
Epoch 7/10 27/27 11s 395ms/step - accuracy: 0.9837 - loss: 0.1204 - val_accuracy: 0.9524 - val_loss: 0.1605
Epoch 8/10 27/27 11s 401ms/step - accuracy: 0.9907 - loss: 0.1025 - val_accuracy: 0.9714 - val_loss: 0.1366
Epoch 9/10 27/27 11s 402ms/step - accuracy: 0.9864 - loss: 0.0987 - val_accuracy: 0.9714 - val_loss: 0.1242
Epoch 10/10 27/27 11s 399ms/step - accuracy: 0.9864 - loss: 0.0913 - val_accuracy: 0.9762 - val_loss: 0.1183
Pelatihan tahap awal selesai.
```

Penelitian ini memanfaatkan arsitektur ConvNeXt untuk melakukan klasifikasi varietas beras. Dataset dibagi menjadi 80% sebagai training data dan 20% sebagai validation data. Berdasarkan hasil akurasi dan *loss* pada data pelatihan, pengujian, serta validasi, dapat disimpulkan bahwa model menunjukkan performa yang relatif seimbang. Selanjutnya, grafik akurasi dan *loss* antara data pelatihan dan validasi ditampilkan untuk mengidentifikasi apakah model mengalami *overfitting*, *underfitting*, atau berada pada kondisi *good fit*, sebagaimana terlihat pada Gambar




Gambar 3 Grafik Akurasi Training dan Validasi



Gambar 4 Grafik akurasi loss training dan validasi. Gambar 4 menampilkan grafik akurasi pada data train dan validasi, sedangkan Gambar 4 memperlihatkan grafik loss untuk kedua jenis data tersebut. Garis berwarna biru merepresentasikan kinerja model pada data train, sementara garis berwarna oranye menunjukkan hasil pada data validasi. Berdasarkan pola pada grafik akurasi dan loss, terlihat bahwa model menunjukkan performa yang konsisten, ditandai dengan peningkatan akurasi yang berlangsung secara stabil serta penurunan nilai loss yang juga terjadi secara bertahap. Pola tersebut mengindikasikan bahwa model berada dalam kondisi *good fit*, sehingga tidak menunjukkan gejala *overfitting* maupun *underfitting*, karena performanya pada data train dan validasi relatif sejalan dan tidak mengalami penyimpangan signifikan.

Proses evaluasi dilakukan dengan memanfaatkan *Confusion Matrix* dan *Classification Report*. Pada *Confusion Matrix*, beberapa indikator utama yang dianalisis meliputi *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), yang masing-masing merepresentasikan seluruh kemungkinan kondisi aktual positif (P) maupun negatif (N). Sementara itu, *Classification Report* digunakan untuk menampilkan metrik kinerja model, seperti akurasi, recall, dan precision. Hasil visualisasi *Confusion Matrix* dapat dilihat pada Gambar 4



Gambar 5 Hasil confusion matrix

Berdasarkan Gambar 5 hasil klasifikasi yang dihasilkan model terhadap data test menunjukkan kinerja yang cukup memuaskan. Evaluasi ini mengindikasikan bahwa model mampu mengenali pola pada data uji dengan tingkat ketepatan yang konsisten, sehingga kesalahan prediksi dapat diminimalkan. Pada skenario pengujian ini, terdapat total 1.050 citra yang digunakan sebagai data test, yang masing-masing merepresentasikan variasi kondisi objek sesuai kelas yang telah ditetapkan. Jumlah citra tersebut memungkinkan model untuk diuji secara lebih komprehensif, sehingga performanya dapat diukur tidak hanya berdasarkan ketepatan prediksi, tetapi juga kemampuannya dalam menghadapi distribusi data yang beragam. Melalui jumlah data uji yang memadai ini, evaluasi dapat memberikan gambaran yang lebih objektif mengenai reliabilitas model dalam mengklasifikasikan citra pada konteks penggunaan nyata diantaranya :

Sebanyak 61 citra dari varietas beras arborio berhasil diklasifikasikan oleh model sebagai beras arborio, yang menunjukkan bahwa sebagian besar citra pada kelas ini dapat dikenali dengan tepat. Jumlah tersebut hampir mencakup keseluruhan data test untuk varietas arborio, yaitu 62 citra, sehingga hanya terdapat satu citra yang tidak teridentifikasi secara akurat. Temuan ini mengindikasikan bahwa model memiliki tingkat kesesuaian yang tinggi terhadap karakteristik visual spesifik dari beras arborio. Selain itu, proporsi prediksi benar yang mendekati jumlah total sampel uji juga memberikan gambaran bahwa fitur-fitur yang diekstraksi model telah cukup representatif dalam membedakan varietas ini dari kelas lainnya. Dengan demikian, performa model pada kelas arborio dapat dikategorikan sangat baik dan konsisten dengan hasil evaluasi kuantitatif lainnya.

Sebanyak 68 citra dari varietas beras basmati berhasil diklasifikasikan dengan benar sebagai beras basmati oleh model. Jumlah tersebut hampir mencakup keseluruhan data test untuk kelas ini, yaitu sebanyak 69 citra, sehingga hanya satu citra yang tidak sesuai dengan prediksi seharusnya. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual beras basmati dengan tingkat ketepatan yang sangat tinggi. Konsistensi prediksi tersebut juga mengindikasikan bahwa fitur-fitur yang dipelajari model telah cukup representatif dalam membedakan varietas basmati dari varietas lainnya. Dengan demikian, performa model pada kelas basmati dapat dinilai sangat baik dan selaras dengan evaluasi metrik lainnya yang menunjukkan reliabilitas model dalam proses klasifikasi citra.

Sebanyak 76 citra dari varietas beras ipsala berhasil diklasifikasikan oleh model sebagai beras ipsala, yang menunjukkan bahwa sebagian besar sampel uji pada kelas ini dapat teridentifikasi secara tepat. Dari total 79 citra yang termasuk dalam data test untuk varietas ipsala, hanya terdapat tiga citra yang tidak sesuai dengan prediksi ideal. Proporsi prediksi benar yang sangat mendekati jumlah keseluruhan sampel uji mengindikasikan bahwa model mampu mengenali fitur-fitur visual khas beras ipsala dengan baik. Kinerja ini juga mencerminkan bahwa proses ekstraksi dan pemelajaran fitur yang dilakukan model telah cukup representatif dalam membedakan varietas ipsala dari varietas lainnya. Selain itu, ketepatan klasifikasi yang tinggi pada kelas ini turut memperkuat konsistensi performa model secara keseluruhan dalam tugas identifikasi citra. Dengan demikian, hasil evaluasi pada varietas ipsala menegaskan bahwa model memiliki kapabilitas klasifikasi yang andal pada skenario pengujian nyata.

Tabel 1 menampilkan classification report yang menunjukkan hasil akurasi, precision dan recall.

Tabel 1 Classification Report

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>support</i>
Arborio	0.95	0.98	0.97	62
Basmati	1.00	0.99	0.99	69
Ipsala	0.97	0.96	0.97	79
Accuracy			0.98	210
Macro avg	0.98	0.98	0.98	210
Weighted avg	0.98	0.98	0.98	210

Hasil penelitian menunjukkan bahwa arsitektur ConvNeXt mampu menghasilkan kinerja yang sangat optimal dalam melakukan klasifikasi citra butiran beras. Model tersebut berhasil mencapai akurasi validasi dan pengujian sebesar 98%, yang mengindikasikan kemampuan generalisasi yang kuat terhadap data yang belum pernah dilihat sebelumnya. Penerapan data augmentation juga memberikan kontribusi penting dalam mencegah terjadinya overfitting, terutama karena ukuran dataset yang hanya berjumlah 1.050 citra dan tergolong kategori sedang. Melalui analisis confusion matrix, terlihat bahwa tingkat kesalahan prediksi berada pada level yang sangat rendah, sehingga model terbukti mampu membedakan karakteristik visual setiap varietas beras secara akurat. Varietas Basmati muncul sebagai kelas yang paling mudah teridentifikasi karena bentuk

butirannya yang relatif panjang dan khas, sementara tingkat kekeliruan tertinggi terjadi pada varietas Ipsala yang memiliki kemiripan bentuk dengan Arborio. Secara keseluruhan, temuan ini menegaskan bahwa penerapan transfer learning dengan backbone ConvNeXt sangat efektif untuk menyelesaikan permasalahan klasifikasi objek berukuran kecil, seperti butiran beras, dan bahkan memiliki potensi besar untuk dikembangkan pada aplikasi serupa di bidang pertanian digital.

CONCLUSION

Berdasarkan hasil pengujian yang telah dilaksanakan, dapat dirumuskan suatu kesimpulan umum yang merangkum temuan utama penelitian ini. Perumusan kesimpulan ini mencakup interpretasi terhadap kinerja model, efektivitas metode yang diterapkan, serta konsistensi hasil di berbagai skenario pengujian. Kesimpulan tersebut disusun dengan mempertimbangkan keseluruhan analisis kuantitatif dan kualitatif, termasuk akurasi model, stabilitas proses pelatihan, serta evaluasi menggunakan metrik tambahan seperti confusion matrix dan classification report. Dengan demikian, rangkuman ini tidak hanya menggambarkan pencapaian model secara numerik, tetapi juga memberikan gambaran komprehensif mengenai kapabilitas model dalam menyelesaikan tugas klasifikasi citra yang menjadi fokus penelitian. Kesimpulan tersebut kemudian menjadi dasar untuk memberikan rekomendasi pengembangan lebih lanjut, baik dalam aspek metodologis maupun penerapan praktis pada domain terkait. Oleh karena itu, bagian ini dibagi menjadi tiga bagian yaitu:

1. Model ConvNeXt mampu melakukan klasifikasi varietas beras dengan tingkat akurasi yang sangat tinggi, yaitu 98%, serta hanya menghasilkan 5 kesalahan dari total 210 sampel. Ini menunjukkan bahwa model dapat mengenali perbedaan antar varietas seperti Arborio, Basmati, dan Ipsala dengan sangat baik.
2. Model menunjukkan kemampuan yang sangat baik dalam menangkap tekstur, bentuk butir, serta pola visual khas dari masing-masing varietas. Hal ini terlihat dari minimnya kesalahan prediksi dan konsistensinya dalam mengidentifikasi kelas meskipun beberapa varietas memiliki kemiripan visual.
3. Semua matrix evaluasi menunjukkan nilai yang tinggi dan stabil dengan nilai akurasi sebesar 98%, nilai precision 98% dan nilai recall 98%. Nilai yang dihasilkan membuktikan bahwa arsitektur ini terbukti mampu digunakan untuk klasifikasi varietas beras.

REFERENCE

- Acosta-Prado, J. C., Rojas Rincón, J. S., Mejía Martínez, A. M., & Riveros Tarazona, A. R. (2024). Trends in the Literature About the Adoption of Digital Banking in Emerging Economies: A Bibliometric Analysis. *Journal of Risk and Financial Management*, 17(12). <https://doi.org/10.3390/jrfm17120545>
- Apau, R., Titis, E., & Lallie, H. S. (2025). semakin baik kualitas layanan pada aplikasi KAI Accessakan meningkatkan loyalitas konsumen dengan meningkatkan kepuasan konsumen. *Computers*, 14(4).
- Aung, S. T., Funabiki, N., Aung, L. H., Kinari, S. A., Mentari, M., & Wai, K. H. (2024). A Study of Learning Environment for Initiating Flutter App Development Using Docker. *Information (Switzerland)*, 15(4). <https://doi.org/10.3390/info15040191>
- Bangun, N., Intarti, K., Karo, S. B., Dewiningsih, S., & Tahar, S. (2023). *System quality , information quality , system design quality website PT KCI berpengaruh terhadap user satisfaction*. 9(2), 944–958.
- Berihun, N. G., Dongmo, C., & Van der Poll, J. A. (2023). The Applicability of Automated Testing Frameworks for Mobile Application Testing: A Systematic Literature Review. *Computers*, 12(5). <https://doi.org/10.3390/computers12050097>
- Chen, H., Chu, Y. C., & Lai, F. (2023). Mobile time banking on blockchain system development for community elderly care. *Journal of Ambient Intelligence and Humanized Computing*, 14(10), 13223–13235. <https://doi.org/10.1007/s12652-022-03780-6>
- Ilham Tri Maulana. (2022). Penerapan Metode Sdlc (System Development Life Cycle) Waterfall Pada E-Commerce Smartphone. *Jurnal Ilmiah Sistem Informasi Dan Ilmu Komputer*, 2(2), 1–6. <https://doi.org/10.55606/juisik.v2i2.162>
- Jafri, J. A., Mohd Amin, S. I., Abdul Rahman, A., & Mohd Nor, S. (2024). A systematic literature review of the role of trust and security on Fintech adoption in banking. *Heliyon*, 10(1), e22980. <https://doi.org/10.1016/j.heliyon.2023.e22980>
- Marpid, N. N., Kurniawan, Y. I., & Rahayu, S. P. (2025). Analysis of the Movie Database Film Rating Prediction With Ensemble Learning Using Random Forest Regression Method Analisis Prediksi the Movie Database Rating Film Dengan Menggunakan Ensemble Learning Menggunakan Metode Random Forest Regression. *Jurnal Teknik Informatika (JUTIF)*, 6(1), 1–10. <https://doi.org/10.52436/1.jutif.2025.6.1.1563>
- Meneses, B., & Varajão, J. (2022). A Framework of Information Systems Development Concepts. *Business Systems Research*, 13(1), 84–103. <https://doi.org/10.2478/bsrj-2022-0006>
- Ramayanti, R., Rachmawati, N. A., Azhar, Z., & Nik Azman, N. H. (2024). Exploring intention and actual use in digital payments: A systematic review and roadmap for future research. *Computers in Human Behavior Reports*, 13(October 2023), 100348. <https://doi.org/10.1016/j.chbr.2023.100348>
- Saifudin, A., Saputra, A., Saputra, B., Subhan, F., Maulana, F., & Kusyadi, I. (2022). Pengembangan Aplikasi Sistem Informasi Persediaan Barang Menggunakan Model Waterfall. *Jurnal Teknologi Sistem Informasi Dan Aplikasi*, 5(4), 247–254. <https://doi.org/10.32493/jtsi.v5i4.21197>
- Saravanos, A., & Curinga, M. X. (2023). Simulating the Software Development Lifecycle: The Waterfall Model. *Applied System Innovation*, 6(6). <https://doi.org/10.3390/asi6060108>
- Sasmoko, Indrianti, Y., Manalu, S. R., & Danaristo, J. (2024). Analyzing Database Optimization Strategies in Laravel for an Enhanced Learning Management. *Procedia Computer Science*, 245(C), 799–804. <https://doi.org/10.1016/j.procs.2024.10.306>
- Souha, A., Benaddi, L., Ouaddi, C., & Jakimi, A. (2024). Comparative analysis of mobile application Frameworks: A developer's guide for choosing the right tool. *Procedia Computer Science*, 236, 597–604. <https://doi.org/10.1016/j.procs.2024.05.071>