

Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Kualitas Beras sebagai Strategi Peningkatan Keamanan Pangan di Indonesia

Application of Convolutional Neural Network (CNN) for Rice Quality Classification as A Strategic Approach to Enhancing Food Safety in Indonesia

Ade Bastian^{1*}, Deni Priyadi², Dadan Zaliluddin³, Ardi Mardiana⁴, Abrar Wahid⁵, Muhammad Rifki⁶,
Muhammad Fahmi Ajiz⁷

^{1,2,3,4,5,6,7}Jurusan Informatika, Fakultas Teknik, Universitas Majalengka

¹adebastian@unma.ac.id, ²denipriyadi90@gmail.com, ³dadanz@unma.ac.id, ³aim@unma.ac.id, ⁵221410088@unma.ac.id,
⁶211410128@unma.ac.id, ⁷fahmiajiz@unma.ac.id

Abstract

Food fraud has emerged as a significant global issue, threatening public health, economic stability, and consumer trust across the food supply chain. In the context of rice—a staple consumed by more than half of the world's population—the proliferation of counterfeit products poses a critical risk. This study aims to develop a deep learning-based classification model using Convolutional Neural Networks (CNN) to accurately distinguish between medium-grade, premium, and counterfeit rice. The research involved the systematic collection of 100 grain images per rice category, followed by preprocessing, data augmentation, and model training using an optimized CNN architecture for image-based classification. The dataset was split into training, validation, and testing subsets with a 60:20:20 ratio. The model was trained over 12 epochs, achieving a training accuracy of 95%. Evaluation using the test set yielded identical accuracy, with the confusion matrix confirming perfect classification across categories. External validation further demonstrated the model's robustness and generalizability. The findings highlight CNN's potential as an effective tool for enhancing food safety monitoring systems and combating rice fraud. This AI-driven approach contributes to agricultural quality control and emphasizes the role of machine learning in promoting food security and authenticity assurance. However, CNN models face limitations, including susceptibility to overfitting when trained on insufficiently diverse data and high computational demands during training. These challenges underscore the need for diversified datasets and the exploration of alternative architectures offering comparable performance with greater computational efficiency.

Keywords: Convolutional Neural Network, Deep Learning, Fake Rice, Food Safety, Quality Detection.

Abstrak

Penipuan makanan telah muncul sebagai masalah global yang signifikan, mengancam kesehatan masyarakat, stabilitas ekonomi, dan kepercayaan konsumen di seluruh rantai pasokan makanan. Dalam konteks beras, makanan pokok yang dikonsumsi oleh lebih dari setengah populasi dunia, proliferasi produk palsu menimbulkan risiko yang kritis. Studi ini bertujuan untuk mengembangkan model klasifikasi berbasis *Deep Learning* menggunakan *Convolutional Neural Network* (CNN) untuk mengidentifikasi dan membedakan dengan akurat antara beras medium, premium, dan palsu. Penelitian ini melibatkan pengumpulan data sistematis gambar butiran beras, dengan masing-masing 100 gambar untuk setiap kategori kualitas beras, diikuti dengan pra-pemrosesan, augmentasi, dan pelatihan model menggunakan arsitektur CNN yang dioptimalkan untuk klasifikasi berbasis gambar. Dataset dibagi menjadi subset pelatihan, validasi, dan pengujian dengan rasio 60:20:20. Model dilatih dengan 12 *epoch* dan menghasilkan akurasi pelatihan sebesar 95%. Evaluasi model dengan menggunakan data pengujian menghasilkan akurasi yang sama persis dengan akurasi di saat pelatihan, dengan klasifikasi sempurna dapat membedakan beras dengan kategorinya masing-masing. Sebuah *confusion matrix* dan pengujian eksternal mengkonfirmasi ketahanan dan generalisasi model tersebut. Hasilnya menunjukkan bahwa CNN dapat berfungsi sebagai alat yang efektif untuk mendukung sistem pemantauan keamanan pangan dan mencegah penipuan beras. Model yang diusulkan berkontribusi pada pengembangan solusi berbasis AI dalam pengendalian kualitas pertanian dan menyoroti relevansi pembelajaran mesin dalam meningkatkan keamanan pangan dan jaminan keaslian. Meski menunjukkan hasil yang baik, pendekatan CNN memiliki beberapa keterbatasan. Arsitektur ini rentan terhadap *overfitting* apabila gambar yang digunakan saat pelatihan tidak cukup representatif. Selain itu, proses pelatihan model CNN memerlukan sumber daya komputasi yang tinggi. Tantangan ini menekankan betapa pentingnya pengumpulan data secara beragam serta eksplorasi arsitektur alternatif yang mampu memberikan performa serupa dengan efisiensi komputasi yang lebih baik.

1. Pendahuluan

Dalam sepuluh tahun terakhir, ketahanan rantai pasokan makanan telah diperiksa secara terus-menerus, terutama mengingat peningkatan signifikan dalam kejadian penipuan makanan [1]. Contoh peningkatan konsumsi makanan di seluruh dunia telah menciptakan peluang bagi penipu untuk memasuki industri makanan dengan produk-produk substandar [2]. Penipuan makanan merupakan ancaman besar terhadap integritas sistem agri-food global. Pencemaran makanan telah menjadi perhatian internasional. Organisasi Kesehatan Dunia (WHO) dan Organisasi Pangan dan Pertanian Perserikatan Bangsa-Bangsa (FAO) mengelola survei anggota tentang penipuan makanan dan berbagai kriteria. Mayoritas responden mengakui kebutuhan mereka akan dukungan dan informasi tentang pengelolaan keamanan pangan terkait penipuan pangan dan pencegahannya. Karakteristik utama dari penipuan makanan adalah penggunaan bahan-bahan substandar untuk meniru produk asli [3]. Penurunan tangkapan ikan memerlukan keberlanjutan populasi ikan. Metabarcoding DNA lingkungan forensik (eDNA) digunakan di Ekuador untuk menyelamatkan spesies ikan asli [4]. Kurangnya akses terhadap benih legal berkontribusi pada penyebaran produk dan benih pertanian palsu di pasar [5]. Pencantuman label yang salah pada produk perikanan merupakan tindakan pemalsuan produk, seperti yang ditunjukkan dalam beberapa studi di Afrika [6], Amerika Serikat [7], Amerika Selatan [8], dan Eropa [9]. Jahe adalah komoditas Tiongkok yang diekspor ke Uni Eropa, di mana penduduknya memiliki preferensi yang kuat terhadap rempah ini. Bukti menunjukkan adanya penipuan makanan di dalam rantai pasokan jahe dari China ke Uni Eropa [10]. Daging Bison Amerika rentan terhadap kesalahan pelabelan spesies karena kesamaannya dengan sapi domestik, masalah yang mungkin dapat diatasi dengan penggunaan DNA barcoding [11]. Penipuan makanan terkait asal geografis dapat diprediksi dengan akurat melalui pendekatan dinamis yang memodifikasi parameter model berbasis daun khusus buah dan model isotop fisiologis tanaman [12]. Pengolahan industri ginseng rentan terhadap pencemaran, dan pengujian untuk *Panax ginseng* dan *Panax quinquefolius* dapat mendeteksi pencemaran tersebut dengan efisien. Sistem deteksi jamur ilegal telah didirikan di Italia untuk menjamin keselamatan pelanggan [13]. Kualitas biji ketumbar dapat dievaluasi menggunakan spektroskopi inframerah dekat [14]. Dalam sepuluh tahun terakhir, pemalsuan produk daging sering terlihat di Tiongkok [15]. Pendekatan deteksi menggunakan keselarasan digital-fisik bersama dengan model pembelajaran mesin untuk membedakan grade daging [16] atau metodologi sensor berdasarkan spektroskopi [17].

Produksi beras global diproyeksikan meningkat sebesar 58 hingga 567 juta ton (Mt) pada tahun 2030. Beras kaya kalori dan mengandung berbagai vitamin, mineral, dan nutrisi esensial. Ia mengandung konsentrasi nutrisi yang lebih tinggi daripada kentang, jagung, dan gandum [18]. Lima puluh persen dari populasi global [19], termasuk mereka yang di Vietnam mengonsumsi nasi sebagai hidangan utama [20]. Selain berfungsi sebagai makanan pokok, nasi memiliki makna budaya yang cukup besar dalam masyarakat Jepang [21]. Padi merupakan makanan pokok bagi lebih dari setengah populasi dunia dan dibudidayakan di lebih dari 100 negara, dengan 90% produksi global berasal dari Asia [22]. Beras, biji-bijian pokok yang paling banyak dikonsumsi oleh hampir setengah populasi dunia, menawarkan peluang signifikan untuk penipuan, menimbulkan kekhawatiran dan menimbulkan risiko bagi kesehatan dan ekonomi banyak individu [23]. Asal geografis dan jenis beras sangat penting untuk perdagangan dan konsumsi ekonomi [24]. Pencampuran beras dan susu adalah masalah umum di Nigeria [25]. Beras non-aromatik umumnya dihargai sebanding dengan beras aromatik untuk meningkatkan keuntungan [26]. Beras harus diklasifikasikan dengan akurat sesuai dengan kualitasnya [27].

Kecerdasan buatan telah diciptakan untuk mengatasi beberapa tantangan global dan telah menunjukkan efektivitasnya sebagai solusi yang layak [28]. Kecerdasan buatan memfasilitasi tugas-tugas menantang seperti kategorisasi, penilaian kualitas, dan evaluasi sensorik dari sampel yang luas [29]. Pembelajaran mendalam (DL) adalah bidang penelitian yang efektif untuk mengidentifikasi pola pertanian yang dapat secara efektif mengatasi masalah identifikasi penyakit [30]. Klusterisasi objek adalah prosedur dalam penambangan objek yang bertujuan untuk membagi item yang ada menjadi satu atau lebih kelompok berdasarkan fitur-fitur mereka [31]. *Neuro-Fuzzy* adalah solusi optimal untuk pelacakan dokumen karena mengatasi kekurangan *Fuzzy Logic* dan *Neural Networks* sambil memperkuat keunggulan masing-masing komponen [32]. Penggunaan DNFS telah berkembang pesat dalam bidang komputasi, kesehatan, transportasi, dan keuangan, menunjukkan interpretabilitas yang patut dipuji dan akurasi yang sederhana [28]. Berbagai pendekatan telah digunakan untuk mendeteksi beras palsu dan membedakan kualitas beras, namun sebagian besar masih bergantung pada teknik manual atau metode konvensional berbasis fitur yang terbatas dalam menghadapi keragaman visual butiran beras di lapangan. Selain itu, studi yang secara spesifik mengkaji penerapan pembelajaran mendalam—khususnya Convolutional Neural Network (CNN)—untuk klasifikasi kualitas beras berbasis citra masih tergolong minim, terutama dalam konteks lokal


seperti Indonesia. Penelitian ini hadir untuk menjawab kesenjangan tersebut dengan mengembangkan dan mengevaluasi model CNN yang dirancang untuk mengklasifikasikan beras ke dalam tiga kategori utama: palsu, sedang, dan premium, secara otomatis dan akurat. Adapun pertanyaan penelitian yang diangkat adalah: Dapatkah model CNN secara andal membedakan dan mengklasifikasikan kualitas beras berdasarkan citra visual butirannya? Studi ini memberikan kontribusi penting dalam bidang keamanan pangan dengan menawarkan pendekatan berbasis kecerdasan buatan yang aplikatif, efisien, dan relevan untuk diterapkan dalam sistem pengawasan mutu beras. Lebih jauh, hasil dari penelitian ini diharapkan dapat memperkuat upaya perlindungan konsumen serta mendorong pemanfaatan teknologi cerdas dalam memperkuat integritas rantai pasok pangan di Indonesia.

2. Metode Penelitian

Penelitian kualitas beras dapat dibagi menjadi langkah-langkah berikut, seperti yang ditunjukkan dalam grafik dalam Gambar 1 yang menggambarkan kerangka fase penelitian, mencakup beberapa tahap kunci. Penelitian dimulai dengan perumusan masalah, di mana subjek penelitian dijelaskan dengan baik untuk memberikan arahan yang spesifik. Studi literatur dilakukan untuk mengidentifikasi bahan-bahan yang relevan dan pendekatan terkini terkait dengan masalah penelitian. Tahap selanjutnya melibatkan pengambilan gambar butir beras dari setiap kategori secara mandiri, mengingat dataset ini tidak berasal dari sumber publik, melainkan dikembangkan khusus untuk keperluan penelitian ini. Data tersebut menjalani persiapan, termasuk normalisasi dan pembersihan, untuk menjamin kualitasnya. Selanjutnya, dilakukan penerapan metode augmentasi data dengan tujuan memperluas variasi dataset, guna meningkatkan kinerja dan generalisasi model. Melalui proses ini, jumlah gambar pada setiap kategori yang semula 100 diperbanyak menjadi 1000.

Tahap selanjutnya melibatkan pembagian data menjadi data pelatihan, validasi dan data pengujian. Data latih digunakan disaat pelatihan model, data validasi digunakan untuk mengawasi dan mengurangi overfitting sementara untuk data pengujian akan digunakan di tahap evaluasi model guna menentukan efektivitasnya. Model CNN dikembangkan menggunakan framework TensorFlow dan Keras, yang menyediakan fungsionalitas untuk membangun, melatih dan mengevaluasi arsitektur jaringan saraf secara efisien. Tahap selanjutnya, evaluasi model dilakukan berdasarkan pembagian dataset tunggal dengan rasio 60:20:20 tanpa menerapkan teknik *cross-validation*. Pendekatan ini dipilih untuk menjaga alur proses yang ringkas dan efisien, serta mempertimbangkan bahwa pembagian data secara

proporsional dinilai sudah cukup untuk mendukung tujuan evaluasi dalam konteks penelitian. Selanjutnya, pengujian dilakukan menggunakan data eksternal untuk mengevaluasi kapasitas generalisasi model terhadap data baru.



Gambar 1. Tahap Penelitian

Hasil evaluasi kemudian dianalisis dan disajikan sebagai laporan penelitian. Studi ditutup dengan menyebarluaskan hasilnya, memungkinkan temuan tersebut untuk meningkatkan pengetahuan atau penggunaan di masa depan. Fase ini menyediakan kerangka sistematis untuk memperoleh hasil yang valid dan dapat diandalkan.

3. Hasil dan Pembahasan

3.1. Pengumpulan Data Gambar

Penelitian untuk mengidentifikasi beras palsu mengklasifikasikannya ke dalam tiga kategori: beras medium, beras palsu, dan beras premium. Data gambar beras diperoleh menggunakan kamera DSLR Canon 800D dengan jarak pengambilan gambar sekitar 20 cm, dengan kardus hitam sebagai latar belakang dan dua bohlam 45W untuk bantuan pencahayaan. Dataset gambar beras mencakup 300 sampel: 100 sampel beras medium, 100 sampel beras palsu, dan 100 sampel beras premium. Data pencitraan yang ditunjukkan pada Gambar 2, 3 dan 4.



Gambar 2. Beras Medium



Gambar 3. Beras Palsu






Gambar 4. Beras Premium

3.2. Pra-pemrosesan Data

Fase selanjutnya melibatkan praproses data untuk memfasilitasi klasifikasi gambar beras. Tahap pertama persiapan data dalam penelitian melibatkan penghapusan daerah yang tidak relevan dalam setiap gambar. Selain itu, ukuran gambar distandarisasi untuk memberikan dimensi yang seragam di semua foto, sehingga meningkatkan efisiensi komputasi selama pelatihan model klasifikasi, diikuti dengan segmentasi objek utama dalam gambar. Latar belakang digunakan untuk memastikan bahwa model berkonsentrasi pada bentuk, ukuran, dan warna objek utama tanpa gangguan dari elemen lain. Ketika subjek utama dalam gambar terpisah dari latar belakang, format gambar untuk pelatihan model selanjutnya akan menjadi png.


Gambar 5 adalah gambar yang telah dipotong untuk menghilangkan bagian-bagian yang tidak perlu, diubah ukurannya untuk menekankan subjek utama, dan dibedakan dari latar belakang. Dimensi gambar asli 6000×4000 piksel dipotong menggunakan parameter: kiri = 2500, atas = 1500, kanan = 3500, bawah = 2500, menghasilkan ukuran gambar 1000×1000 piksel.




Gambar 5. Hasil pemotongan, penyesuaian ukuran, dan pemisahan objek utama dari latar belakang

3.3. Augmentasi Data

Setelah prosedur pemotongan gambar, langkah selanjutnya adalah melakukan augmentasi data untuk memperkenalkan variasi pada dataset gambar yang diperoleh. Augmentasi data memerlukan penyertaan parameter. Gambar diubah ukurannya menjadi 200×200 piksel untuk studi ini, dan data diperbesar menggunakan parameter berikut: $\text{rescale} = 1/255$, $\text{rotation_range} = 15$, $\text{shear_range} = 0.2$, $\text{zoom_range} = 0.2$, $\text{horizontal_flip} = \text{True}$, $\text{vertical_flip} = \text{True}$, dan $\text{fill_mode} = \text{constant}$. Untuk membedakan antara hasil gambar yang ditingkatkan dan gambar yang telah diproses sebelumnya, data dicatat sepuluh kali dan disimpan di direktori yang berbeda. Hasil augmentasi data dalam penelitian ini ditunjukkan pada Gambar 6.





Gambar 6. Hasil Augmentasi Data

3.4. Pembagian Data


Langkah kedua adalah menggunakan skenario berbagi data yang memfasilitasi pembuatan berbagai set data untuk tujuan pelatihan, validasi, dan pengujian. Alokasikan 60% dari data untuk pelatihan, 20% untuk validasi, dan 20% untuk pengujian sejak awal.

3.5. Convolutional Neural Network

Setelah pemisahan data, fase berikutnya melibatkan pengurutan ulang data, diikuti dengan transformasinya ke skala gambar. Ini digunakan untuk memberikan kinerja optimal dan mengurangi beban selama pelatihan. Tahap penutup melibatkan konstruksi arsitektur model klasifikasi menggunakan pendekatan *Convolutional Neural Network (CNN)*. Pekerjaan ini menggunakan dua lapisan konvolusi, masing-masing dengan 128 filter, ukuran kernel 3x3, dan aktivasi ReLU. Selanjutnya, tiga lapisan MaxPooling, satu lapisan BatchNormalization, satu lapisan Flatten, satu lapisan dropout dengan rasio 0,2, dan akhirnya, satu lapisan Dense yang terdiri dari 128 unit, regularisasi L2 (ukuran kernel 0,001), dan aktivasi ReLU. Selain itu, setiap gambar input dikategorikan ke dalam salah satu dari tiga kelas yang telah ditentukan sebelumnya menggunakan lapisan Dense dengan tiga fungsi aktivasi softmax, lapisan Dense dengan 64 fungsi aktivasi ReLU, dan lapisan Dense dengan 128 fungsi aktivasi ReLU, semuanya tanpa regularisasi kernel. Studi ini menggunakan optimizer Adam dengan laju pembelajaran sebesar 0,0001. Akurasi dinilai menggunakan categorical crossentropy sebagai metrik kerugian. Ukuran *batch* dikonfigurasi menjadi 64, dan fungsi *early_stopping_loss* dimasukkan. Jika loss validasi tetap konstan selama lima epoch pelatihan berturut-turut, pelatihan model akan dihentikan segera.

Fungsi ini bermanfaat untuk melacak kemajuan pelatihan melalui loss validasi.

Setelah memperoleh arsitektur model, kami dapat memulai pelatihan dan memantau kemajuan pelatihan dengan skenario rasio pembagian data yang telah ditetapkan. Gambar 7 menggambarkan grafik yang mewakili perkembangan akurasi pelatihan, akurasi validasi, dan kehilangan validasi untuk setiap skenario rasio.



Gambar 7. Grafik hasil pelatihan menggunakan rasio 6:2:2

Pelatihan model klasifikasi padi ditunjukkan pada Gambar 7, yang juga menunjukkan pertumbuhan loss dan akurasi. Gambar tersebut menggambarkan dua grafik garis yang memvisualisasikan kinerja pelatihan model pembelajaran mesin selama 12 epoch. Grafik di sebelah kiri menunjukkan akurasi, sementara yang di sebelah kanan menunjukkan loss—baik untuk dataset pelatihan maupun validasi.

Dalam grafik akurasi, garis biru mewakili akurasi pelatihan, dan garis oranye mewakili akurasi validasi. Selama 12 epoch, akurasi pelatihan meningkat secara konsisten, mencapai sekitar 96,5% pada epoch terakhir. Ini menunjukkan bahwa model secara efektif mempelajari pola dari data pelatihan. Akurasi validasi, di sisi lain, berfluktuasi tetapi umumnya mengikuti tren naik, mencapai puncaknya mendekati akurasi pelatihan. Ketidakberaturan tersebut menunjukkan bahwa meskipun model ini cukup baik dalam generalisasi, terkadang model ini mengalami overfitting atau kesulitan dengan data validasi pada epoch tertentu—terlihat dari penurunan akurasi (misalnya, epoch 2, 7, dan 9).

Garis biru menunjukkan penurunan yang stabil dalam kerugian pelatihan, yang menunjukkan minimisasi kesalahan prediksi yang efektif selama pelatihan. Garis oranye, yang menggambarkan kerugian validasi, kurang stabil. Ia berfluktuasi secara signifikan, terutama antara epoch 2–9, menunjukkan peningkatan dan penurunan tajam. Perilaku seperti itu sering kali menandakan overfitting, di mana model menjadi terlalu disesuaikan dengan data pelatihan dan kurang mampu untuk menggeneralisasi ke data yang belum terlihat. Ini terutama terlihat jelas sekitar epoch 8, di mana kerugian validasi meningkat tajam sementara kerugian pelatihan tetap rendah.

Dari perspektif kritis, visualisasi ini menyediakan dasar yang kaya untuk menginterpretasikan kinerja model, dinamika pembelajaran, dan perilaku generalisasi. Peningkatan konsisten dalam akurasi pelatihan dan penurunan kerugian mencerminkan optimasi yang berhasil. Namun, volatilitas dalam metrik validasi menunjukkan adanya ruang untuk perbaikan—mungkin melalui regularisasi, peningkatan keragaman data, atau penghentian dini. Epistemik, grafik ini mencerminkan narasi umum dalam pembelajaran mesin: pencarian keseimbangan yang halus antara pembelajaran dan generalisasi.

3.6. Evaluasi Model

Setelah memperoleh hasil kinerja untuk model dengan akurasi yang berbeda, setiap model akan dievaluasi menurut rasio berbagi data tertentu dengan menggunakan metrik presisi, recall, F1-score, dan akurasi. Evaluasi akan ditampilkan sebagai tabel hasil yang dihasilkan dari `classification_report`. Laporan kategorisasi menawarkan ringkasan komprehensif dari prediksi untuk setiap kategori.

Tabel 1 menampilkan laporan klasifikasi untuk rasio model 6.2.2, menggunakan metrik evaluasi. Tingkat akurasi yang dicapai adalah 95%, menunjukkan hasil yang sangat dapat diandalkan untuk deteksi padi.

Tabel 1. Tabel Laporan Klasifikasi 6.2.2

	Precision	Recall	F1-Score	Support
Beras Medium	0.94	0.92	0.93	299
Beras Palsu	1.00	1.00	1.00	312
Beras Premium	0.92	0.93	0.93	274
Accuracy			0.95	885
Macro avg	0.95	0.95	0.95	885
Weighted avg	0.95	0.95	0.95	885

3.6.1. Perbandingan Kinerja

Dalam studi ini, model CNN dilatih dan ditemukan menunjukkan kinerja yang sangat baik di semua kategori kualitas (medium, premium, dan palsu) dengan akurasi 95%. Keefektifan model ini terutama terlihat pada fase deteksi urine, di mana tekanan dan pengingatan mendekati 1.00. Dibandingkan dengan penelitian tingkat spesies yang menggunakan algoritma k-means clustering untuk klasifikasi atau deteksi kualitas makanan, kinerja ini cukup kompetitif. Sebagai contoh, Dar et al. (2022) juga menggunakan jaringan saraf konvolusional dalam untuk klasifikasi varietas beras; namun, fokus mereka bukan pada deteksi bau. Selain itu, penelitian oleh He et al. (2023) mengembangkan sistem deteksi fitur otomatis menggunakan jaringan saraf konvolusional (CNN) dan visi mesin. Sistem ini unggul dalam atribut visual tetapi mungkin memiliki persyaratan berbeda untuk kategori objek tertentu.

Meskipun terdapat perbedaan dalam fokus dan jenis dataset, akurasi 95% yang dicapai oleh model kami menunjukkan efektivitas fitur visual yang diekstraksi oleh CNN dalam membedakan beras palsu. Dalam konteks yang berbeda dari pendekatan berbasis gambar, penelitian oleh Liu et al. (2020) mengungkapkan bahwa spektroskopi near-infrared dapat berfungsi sebagai metode yang efektif dalam mendeteksi penipuan pada beras berkualitas tinggi. Aznan et al. (2022) mengeksplorasi deteksi beras palsu dengan menggunakan perangkat sensor digital berbiaya rendah dan machine learning, yang menunjukkan potensi solusi yang lebih terjangkau, meskipun diperlukan perbandingan langsung untuk menilai kinerja akurasi. Oleh karena itu, temuan kami menegaskan kemampuan model CNN dalam mengatasi masalah penipuan makanan yang spesifik ini, sambil mengakui adanya variasi dalam fokus dan metodologi di dalam literatur yang relevan.

3.7. Pengujian

Setelah penilaian model menggunakan berbagai rasio, tahap berikutnya untuk menentukan kualitas kinerja model adalah mengujinya menggunakan data eksternal yang tidak termasuk dalam dataset. Gambar 8 menampilkan hanya satu gambar untuk data uji. Gambar 8 menggambarkan gambar beras palsu, yang selanjutnya akan dievaluasi pada model dengan rasio yang bervariasi secara bergantian.




Gambar 8. Foto Beras Palsu

Uji coba dilakukan pada model yang menunjukkan rasio 6.2.2. Tabel 2 menyajikan hasil, menunjukkan bahwa model mengklasifikasikan gambar input sebagai Nasi Palsu, dengan tingkat kepercayaan sebesar 99,96%. Matriks kebingungan yang diilustrasikan dalam Gambar 9 menunjukkan bahwa model mengklasifikasikan gambar masukan sebagai Nasi Palsu berdasarkan input gambar yang diberikan.

Tabel 2. Tabel Model Hasil uji 6.2.2

	Confidence Score
Beras Medium	0.01%
Beras Palsu	99.96%
Beras Premium	0.04%



Gambar 9. Confusion Matrix Hasil Uji Model 6.2.2

Gambar 9 menggambarkan sebuah *confusion matrix* yang mewakili kinerja model klasifikasi multi-kelas dalam membedakan antara tiga kelas beras: Beras Medium, Beras Palsu, dan Beras Premium. Matriks ini disusun sedemikian rupa sehingga baris-barisnya sesuai dengan label sebenarnya atau label kebenaran dasar, sementara kolom-kolomnya mewakili label yang diprediksi yang dihasilkan oleh model. Entri diagonal menunjukkan klasifikasi yang benar, sedangkan entri non-diagonal mewakili klasifikasi yang salah. Sebanyak 276 contoh Beras Medium diklasifikasikan dengan akurat, dengan 23 contoh salah diklasifikasikan sebagai Beras Premium dan tidak ada yang salah diklasifikasikan sebagai Beras Palsu. Semua 312 instance Beras Palsu diprediksi dengan sempurna tanpa satu pun kesalahan klasifikasi. Untuk Beras Premium, model dengan benar mengidentifikasi 256 contoh, sementara 18 salah diklasifikasikan sebagai Beras Medium, dan tidak ada yang salah diklasifikasikan sebagai Beras Palsu.

Confusion Matrix ini mengungkapkan bahwa pengklasifikasi menunjukkan presisi dan recall yang sangat tinggi untuk kategori Beras Palsu, mencapai klasifikasi sempurna dalam kedua arah. Kinerja seperti ini mungkin menunjukkan bahwa fitur-fitur yang membedakan nasi palsu jauh lebih menonjol atau terpisah dibandingkan dengan kategori lainnya. Sebaliknya, kesalahan klasifikasi terjadi terutama antara Beras Medium dan Beras Premium, menunjukkan bahwa kedua kategori ini memiliki karakteristik yang tumpang tindih dalam ruang fitur. Ini bisa disebabkan oleh kesamaan dalam sifat visual, tekstur, atau kimia, yang mungkin tidak cukup terpisah oleh mekanisme ekstraksi fitur model saat ini.

Akurasi tinggi dalam mendeteksi beras palsu sangat berharga dalam keamanan pangan dan integritas rantai pasokan. Namun, kecenderungan untuk mencampuradukkan varietas medium dan premium

mungkin memerlukan pra-pemrosesan tambahan. Matriks ini tidak hanya berfungsi sebagai alat evaluasi tetapi juga sebagai lensa analitis untuk memahami perilaku model, dinamika kelas, dan potensi domain perbaikan dalam konteks pembelajaran mesin terapan.

3.8. Keterbatasan Model dan Tantangan Implementasi di Dunia Nyata

Model CNN menunjukkan hasil yang sangat baik dalam klasifikasi kualitas beras, dengan akurasi mencapai 95% dan presisi sempurna untuk beras palsu. Namun, terdapat beberapa keterbatasan yang perlu diakui. Arsitektur CNN memiliki kerentanan terhadap overfitting ketika dataset pelatihan tidak cukup representatif atau beragam. Hal ini dapat terlihat dari fluktuasi akurasi validasi, meskipun telah dilakukan augmentasi data.

Proses pelatihan model CNN memerlukan sumber daya komputasi yang signifikan, yang dapat menjadi kendala untuk penerapan di lokasi dengan infrastruktur yang terbatas. Implementasi di dunia nyata menghadapi variabilitas kondisi lingkungan pengambilan gambar, seperti pencahayaan, kotoran, atau benda asing, mengingat gambar dalam penelitian ini diambil dalam kondisi terkontrol. Model mungkin memerlukan adaptasi atau teknik pra-pemrosesan yang lebih canggih untuk mengatasi variabilitas tersebut. Selain itu, kecepatan inferensi harus diminimalkan untuk aplikasi real-time.

3.9. Potensi Implementasi dan Integrasi Teknologi

Dengan mempertimbangkan potensi signifikan dari model ini dalam memperkuat keamanan pangan dan mencegah penipuan beras, model CNN yang telah dilatih menunjukkan relevansi yang tinggi untuk diterapkan secara praktis oleh petani, distributor, atau petugas keamanan pangan.

Integrasi ke aplikasi seluler merupakan salah satu opsi deployment yang mungkin, di mana pengguna dapat memindai sampel beras dengan kamera smartphone untuk melakukan klasifikasi kualitas secara real-time, baik melalui komputasi edge maupun dengan memindahkan proses ke cloud. Model ini juga dapat diterapkan pada perangkat Internet of Things (IoT) yang terhubung dengan sistem kontrol kualitas di gudang atau fasilitas pengolahan beras. Hal ini memungkinkan pemantauan otomatis dan klasifikasi yang berkelanjutan, serta dapat memicu mekanisme penolakan untuk beras yang tidak memenuhi standar. Masa depan implementasi dapat mencakup pengembangan sistem yang lebih canggih, seperti federated learning untuk menjaga privasi data, serta antarmuka pengguna yang intuitif untuk memfasilitasi adopsi luas di kalangan pengguna non-teknis.

4. Kesimpulan

Studi penelitian ini menyajikan analisis mendalam mengenai penerapan Convolutional Neural Network (CNN) dalam klasifikasi kualitas beras, sebagai langkah strategis untuk menangani masalah penipuan pangan yang semakin meningkat di Indonesia. Model pembelajaran mendalam yang telah dikembangkan menunjukkan kemampuan yang signifikan dalam membedakan antara beras medium, premium, dan palsu, berdasarkan analisis dataset citra yang telah dikurasi dengan teliti. Setiap gambar diambil dalam kondisi yang terstandarisasi dan melalui proses yang sistematis, termasuk resizing, cropping, dan segmentasi, untuk mengidentifikasi fitur visual yang signifikan. Penggunaan teknik augmentasi data berperan penting dalam meningkatkan kemampuan generalisasi model terhadap variasi yang ada, seperti pencahayaan, orientasi, dan tekstur. Model CNN dibangun dengan sejumlah lapisan konvolusi dan pooling, serta dilengkapi dengan mekanisme normalisasi dan dropout untuk meminimalkan kemungkinan terjadinya overfitting. Pelatihan dilaksanakan selama 12 epoch, dengan alokasi data yang terdiri dari 60% untuk pelatihan, 20% untuk validasi, dan 20% untuk pengujian. Selama pelatihan, terdapat pola peningkatan yang jelas pada akurasi, sedangkan nilai loss menunjukkan penurunan yang signifikan. Meskipun ada variasi dalam akurasi validasi, tren keseluruhan menunjukkan arah yang positif dan mendekati kinerja pelatihan. Evaluasi yang dilakukan menunjukkan bahwa tingkat akurasi klasifikasi mencapai 95%. Analisis terhadap confusion matrix menunjukkan bahwa model berhasil mengklasifikasikan semua 312 sampel beras palsu dengan akurasi yang sangat tinggi, mencerminkan kemampuannya dalam mendeteksi anomali. Pengujian eksternal pada sampel beras palsu menunjukkan kekuatan model, dengan tingkat kepercayaan klasifikasi mencapai 99,96%. Hal ini mengindikasikan bahwa model menunjukkan kemampuan generalisasi yang memadai, bahkan ketika dihadapkan pada data yang tidak termasuk dalam pelatihan. Secara keseluruhan, penelitian ini menunjukkan kemampuan CNN sebagai pendekatan berbasis AI dalam mengidentifikasi keaslian pangan. Implementasi klasifikasi kualitas beras menunjukkan peran signifikan teknologi informasi dalam sektor pertanian dan keamanan pangan. Hal ini juga menciptakan peluang untuk pengembangan riset lintas disiplin yang menghubungkan informatika, pertanian, dan kesehatan masyarakat.

Namun, penting untuk mengakui bahwa penelitian ini memiliki keterbatasan, termasuk potensi overfitting pada model CNN jika dataset pelatihan tidak cukup representatif, serta kebutuhan akan sumber daya komputasi yang tinggi untuk pelatihan model. Variabilitas kondisi lingkungan saat pengambilan

gambar di dunia nyata memiliki potensi untuk memengaruhi kinerja model yang telah dilatih dalam kondisi terkontrol. Untuk riset lanjutan, disarankan untuk mengeksplorasi penggunaan dataset multispektral yang dapat menangkap fitur-fitur yang tidak terlihat oleh mata manusia, mengembangkan aplikasi seluler untuk deteksi kualitas beras di lapangan, dan melakukan pengujian model secara ekstensif dalam skenario dunia nyata untuk memastikan ketahanan dan adaptabilitasnya terhadap berbagai kondisi. Penerapan model ini menawarkan kemungkinan untuk diintegrasikan ke dalam sistem kontrol kualitas real-time di pabrik penggilingan atau distribusi. Selain itu, terdapat potensi untuk mengembangkan alat bantu yang memungkinkan petani dan konsumen memverifikasi keaslian dan kualitas beras secara mandiri.

Ucapan Terimakasih

Terimakasih kepada Universitas Majalengka yang telah mendanai penelitian ini.

Daftar Rujukan

- [1] B. Popping *et al.*, "Food inauthenticity: Authority activities, guidance for food operators, and mitigation tools," *Compr Rev Food Sci Food Saf*, vol. 21, no. 6, pp. 4776–4811, Nov. 2022, doi: 10.1111/1541-4337.13053.
- [2] R. Kwasi Bannor, K. K. Arthur, D. Oppong, and H. Oppong-Kyeremeh, "A comprehensive systematic review and bibliometric analysis of Food Safety from a global perspective," *J Agric Food Res*, vol. 14, Dec. 2023, doi: 10.1016/j.jafr.2023.100686.
- [3] Y. Liu, Y. Li, Y. Peng, Y. Yang, and Q. Wang, "Detection of fraud in high-quality rice by near-infrared spectroscopy," *J Food Sci*, vol. 85, no. 9, pp. 2773–2782, Sep. 2020, doi: 10.1111/1750-3841.15314.
- [4] D. A. Willette, G. Navarrete-Forero, Z. Gold, A. M. D. Lizano, L. Gonzalez-Smith, and G. Sotil, "Characterizing Industrial and Artisanal Fishing Vessel Catch Composition Using Environmental DNA and Satellite-Based Tracking Data," *Foods*, vol. 10, no. 6, p. 1425, Jun. 2021, doi: 10.3390/foods10061425.
- [5] J. B. Machibya, I. Kadigi, and J. Njeru, "The causes and detrimental effects associated with the use of 'fake' inputs and seeds to the smallholder farmers in Tanzania I," Tanzania, 2021. [Online]. Available: <https://www.researchgate.net/publication/354248198>
- [6] A. Galal-Khalla, A. Ardura, K. Mohammed-Geba, Y. J. Borrell, and E. Garcia-Vazquez, "DNA barcoding reveals a high level of mislabeling in Egyptian fish fillets," *Food Control*, vol. 46, pp. 441–445, 2014, doi: 10.1016/j.foodcont.2014.06.016.
- [7] J. L. Garcia *et al.*, "Fishy business in Seattle: Salmon mislabeling fraud in sushi restaurants vs grocery stores," *PLoS One*, vol. 19, no. 11, p. e0311522, Nov. 2024, doi: 10.1371/journal.pone.0311522.
- [8] D. C. Carvalho, D. Guedes, M. da Gloria Trindade, R. M. S. Coelho, and P. H. de Lima Araujo, "Nationwide Brazilian governmental forensic programme reveals seafood mislabelling trends and rates using DNA barcoding," *Fish Res*, vol. 191, pp. 30–35, Jul. 2017, doi: 10.1016/j.fishres.2017.02.021.
- [9] M. C. Calosso, J. A. B. Claydon, S. Mariani, and D. M. Cawthorn, "Global footprint of mislabelled seafood on a small island nation," *Biol Conserv*, vol. 245, May 2020, doi: 10.1016/j.biocon.2020.108557.

- [10] Q. Han, S. W. Erasmus, C. T. Elliott, and S. M. van Ruth, "A sense of ginger fraud: prevalence and deconstruction of the China-European union supply chain," *NPJ Sci Food*, vol. 6, no. 1, p. 51, Nov. 2022, doi: 10.1038/s41538-022-00166-y.
- [11] Z. M. Scales, E. Narbay, and R. S. Hellberg, "Use of DNA Barcoding Combined with PCR-SFLP to Authenticate Species in Bison Meat Products," *Foods*, vol. 10, no. 2, p. 347, Feb. 2021, doi: 10.3390/foods10020347.
- [12] F. Cueni, D. B. Nelson, M. Boner, and A. Kahmen, "Using plant physiological stable oxygen isotope models to counter Food Safety," *Sci Rep*, vol. 11, no. 1, p. 17314, Aug. 2021, doi: 10.1038/s41598-021-96722-9.
- [13] A. Giusti *et al.*, "Building of an internal transcribed spacer (ITS) gene dataset to support the Italian health service in mushroom identification," *Foods*, vol. 10, no. 6, 2021, doi: 10.3390/foods10061193.
- [14] C. McVey, U. Gordon, S. A. Haughey, and C. T. Elliott, "Assessment of the analytical performance of three near-infrared spectroscopy instruments (Benchtop, handheld and portable) through the investigation of coriander seed authenticity," *Foods*, vol. 10, no. 5, 2021, doi: 10.3390/foods10050956.
- [15] X. Li, M. Zang, D. Li, K. Zhang, Z. Zhang, and S. Wang, "Meat Food Safety risk in Chinese markets 2012–2021," *NPJ Sci Food*, vol. 7, no. 1, Dec. 2023, doi: 10.1038/s41538-023-00189-z.
- [16] S. K. Lo *et al.*, *Digital-Physical Parity for Food Safety Detection*, vol. 11521 LNCS, no. June. Springer International Publishing, 2019. doi: 10.1007/978-3-030-23404-1_5.
- [17] L. C. Fengou, A. Lianou, P. Tsakanikas, F. Mohareb, and G. J. E. Nychas, "Detection of meat adulteration using spectroscopy-based sensors," *Foods*, vol. 10, no. 4, 2021, doi: 10.3390/foods10040861.
- [18] N. A. Mohidem, N. Hashim, R. Shamsudin, and H. C. Man, "Rice for Food Security: Revisiting Its Production, Diversity, Rice Milling Process and Nutrient Content," Jun. 01, 2022, *MDPI*. doi: 10.3390/agriculture12060741.
- [19] R. A. Dar *et al.*, "Classification of Rice Grain Varieties using Deep Convolutional Neural Network Architectures," 2022. [Online]. Available: <https://ssrn.com/abstract=4129842>
- [20] D. Le Nguyen Doan, Q. Cuong Nguyen, F. Marini, A. Biancolillo, and H. Chi Minh City, "Authentication of Rice (*Oryza sativa* L.) Using Near Infrared Spectroscopy Combined with Different Chemometric Classification Strategies," *Applied Sciences*, vol. 11, no. 362, pp. 1–11, 2021, doi: 10.3390/app.
- [21] N. Rathnayake, A. Miyazaki, T. L. Dang, and Y. Hoshino, "Age Classification of Rice Seeds in Japan Using Gradient-Boosting and ANFIS Algorithms," *Sensors*, vol. 23, no. 5, Mar. 2023, doi: 10.3390/s23052828.
- [22] USDA ARS Beltsville Human Nutrition Research Center; USDA ARS Adaptive Cropping Systems Laboratory. Rice: Importance for Global Nutrition. *J Nutr Sci Vitaminol* (Tokyo). 2019;65(Suppl):S2–S3. doi:10.3177/jnsv.65.S2. PMID: 31619630
- [23] M. Śliwińska-Bartel, D. T. Burns, and C. Elliott, "Rice fraud a global problem: A review of analytical tools to detect species, country of origin and adulterations," Oct. 01, 2021, *Elsevier Ltd*. doi: 10.1016/j.tifs.2021.06.042.
- [24] S. Asimi *et al.*, "Fingerprinting of Volatile Organic Compounds for the Geographical Discrimination of Rice Samples from Northeast China," *Foods*, vol. 11, no. 12, Jun. 2022, doi: 10.3390/foods11121695.
- [25] H. Onyeaka *et al.*, "Navigating Food Safety: A Survey of Nigerian Consumer Knowledge and Attitudes," *Foods*, vol. 13, no. 20, Oct. 2024, doi: 10.3390/foods13203270.
- [26] Y. Jie, T. Shi, Z. Zhang, and Q. Yan, "Identification of key volatiles differentiating aromatic rice cultivars using an untargeted metabolomics approach," *Metabolites*, vol. 11, no. 8, Aug. 2021, doi: 10.3390/metabo11080528.
- [27] G. Çınarlar, N. Erbaş, and A. Öcal, "Rice Classification and Quality Detection Success with Artificial Intelligence Technologies," *Brazilian Archives of Biology and Technology*, vol. 67, 2024, doi: 10.1590/1678-4324-2024220754.
- [28] N. Talpur, S. J. Abdulkadir, H. Alhussian, M. H. Hasan, N. Aziz, and A. Bamhdi, *Deep Neuro-Fuzzy System application trends, challenges, and future perspectives: a systematic survey*, vol. 56, no. 2. Springer Netherlands, 2023. doi: 10.1007/s10462-022-10188-3.
- [29] A. Choudhary *et al.*, "Artificial intelligence and its applications in the food," *The Pharma Innovation Journal*, no. 7, pp. 1351–1355, 2023, [Online]. Available: <https://www.researchgate.net/publication/372829511>
- [30] T. Daniya and S. Vigneshwari, "Rice Plant Leaf Disease Detection and Classification Using Optimization Enabled Deep Learning," *Journal of Environmental Informatics*, vol. 42, no. 1, pp. 25–38, 2023, doi: 10.3808/jei.202300492.
- [31] Bastian A, Sujadi H, Febrianto G. Penerapan Algoritma K-Means Clustering Analysis Pada Penyakit Menular Manusia (Studi Kasus Kabupaten Majalengka). *Jurnal Sistem Informasi*. 2018 Apr;14(1):26–32. doi:10.21609/jsi.v14i1.566
- [32] C. Ituma, G. G. James, and F. U. Onu, "Design of Intelligent Neuro-Fuzzy Based Document Retrieval System," *Int J Sci Eng Res*, vol. 11, no. 2, pp. 1–7, Feb. 2020.
- [33] Y. He *et al.*, "Rapid appearance quality of rice based on machine vision and convolutional neural network research on automatic detection system," *Front Plant Sci*, vol. 14, 2023, doi: 10.3389/fpls.2023.1190591.
- [34] A. Aznan, C. Gonzalez Viejo, A. Pang, and S. Fuentes, "Rapid Detection of Fraudulent Rice Using Low-Cost Digital Sensing Devices and Machine Learning," *Sensors*, vol. 22, no. 22, Nov. 2022, doi: 10.3390/s22228655.