

## Penerapan CNN Berbasis Arsitektur ResNet-50 untuk Klasifikasi Citra Mikroskopik Beras Organik dan Anorganik

Rafi Muzhaffar<sup>1</sup>, Imam Suharjo<sup>2</sup>

Informatika, Teknologi Informasi, Universitas Mercu Buana Yogyakarta

<sup>1</sup>rafimuzhaffar123@gmail.com, <sup>2</sup>imam@mercubuana-yogya.ac.id

### Abstract

*Rice is the main staple food for Indonesian society, with organic and inorganic variants widely circulated in the market. However, both types are visually difficult to distinguish due to their similar shape and color. The invisible characteristic differences necessitate a technology-based approach for objective and accurate rice type identification. This study utilizes digital image processing techniques and deep learning algorithms with Convolutional Neural Network (CNN) architecture based on ResNet-50 to classify microscopic images of organic and inorganic rice. The dataset consists of 1,000 images captured using a digital microscope with 640×480 pixel resolution, which underwent cropping, resizing, and augmentation processes to improve model generalization. The data was then divided into training, validation, and testing subsets with a ratio of 70:15:15. Evaluation was conducted using confusion matrix, classification report, and visualization of training loss and accuracy graphs. The evaluation results show that the model can classify rice with an accuracy of 96.67%, along with high and balanced precision, recall, and F1-score values for both classes. These findings demonstrate that the CNN approach with ResNet-50 architecture is effective for automatically identifying visual differences between organic and inorganic rice and has potential application as an image-based classification assistance system in the agricultural industry.*

**Keywords:** Organic Rice, Inorganic Rice, CNN, ResNet-50, Image Classification

### Abstrak

Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis untuk membedakan beras organik dan anorganik yang secara visual sulit dibedakan oleh mata manusia. Beras merupakan bahan pangan pokok utama masyarakat Indonesia, dengan varian organik dan anorganik yang kini banyak beredar di pasaran. Namun, secara visual keduanya sulit dibedakan karena memiliki bentuk dan warna yang serupa. Perbedaan karakteristik yang tidak tampak secara kasat mata mendorong perlunya pendekatan berbasis teknologi untuk mengidentifikasi jenis beras secara objektif dan akurat. Penelitian ini memanfaatkan teknik pengolahan citra digital dan algoritma deep learning dengan arsitektur Convolutional Neural Network (CNN) berbasis ResNet-50 untuk mengklasifikasikan citra mikroskopik beras organik dan anorganik. Dataset terdiri dari 1.000 citra hasil tangkapan mikroskop digital dengan resolusi 640×480 piksel, yang melalui proses cropping, resize, dan augmentasi untuk meningkatkan generalisasi model. Data kemudian dibagi ke dalam subset training, validasi, dan testing dengan rasio 70:15:15. Model ResNet-50 dimodifikasi pada lapisan classifier dengan multilayer perceptron dan dilatih menggunakan transfer learning. Evaluasi dilakukan menggunakan confusion matrix, classification report, serta visualisasi grafik training loss dan accuracy. Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan beras dengan akurasi sebesar 96,67%, serta nilai precision, recall, dan F1-score yang tinggi dan seimbang pada kedua kelas. Temuan ini membuktikan bahwa pendekatan CNN dengan arsitektur ResNet-50 efektif digunakan untuk mengidentifikasi perbedaan visual antara beras organik dan anorganik secara otomatis, dan berpotensi diterapkan sebagai sistem bantu klasifikasi berbasis citra dalam industri pertanian serta laboratorium pengujian mutu pangan.

**Kata kunci:** Beras Organik, Beras Anorganik, CNN, ResNet-50, Klasifikasi Citra



## 1. Pendahuluan

Indonesia sebagai negara agraris memiliki peran strategis dalam sektor pertanian yang memberikan kontribusi signifikan terhadap struktur pembangunan perekonomian nasional. Beras sebagai makanan pokok utama masyarakat Indonesia tidak hanya menjadi sumber nutrisi penting dalam pola konsumsi sehari-hari, tetapi juga berperan sebagai sumber pendapatan dan lapangan pekerjaan bagi jutaan rakyat Indonesia [1], [2]. Meskipun produksi padi nasional pada tahun 2015 mencapai 75,40 juta ton Gabah Kering Giling (GKG) dengan peningkatan sebesar 6,42 persen, Indonesia masih memerlukan impor untuk memenuhi kebutuhan domestik karena ketergantungan masyarakat terhadap beras yang sangat tinggi [1].

Upaya peningkatan produksi melalui teknologi Revolusi Hijau dengan penggunaan pupuk dan pestisida kimia telah menimbulkan dampak negatif berupa penurunan kualitas bahan pangan dan degradasi lahan pertanian [1], [3]. Sebagai solusi, beras organik yang dibudidayakan tanpa menggunakan pestisida, herbisida, atau bahan kimia sintetis menjadi alternatif yang mengutamakan keberlanjutan lingkungan dan kesehatan tanah [4]. Sistem pertanian organik menghasilkan tanaman yang terbebas dari residu bahan kimia aktif, sehingga hasil produksi menjadi lebih sehat dengan kandungan nutrisi dan mineral yang melimpah serta mudah dicerna [5], [6]. Permintaan beras organik terus meningkat dengan total area mencapai sekitar 53.000 hektar pada tahun 2017-2018, menjadikannya produk organik kedua yang paling sering dibeli konsumen setelah sayur dan buah organik [7].

Seiring meningkatnya permintaan, kebutuhan akan metode identifikasi beras yang akurat dan efisien pun semakin penting, khususnya untuk memastikan keaslian produk beras organik. Permasalahan utama yang dihadapi masyarakat adalah kesulitan membedakan beras organik dan anorganik secara visual, karena adanya kemiripan bentuk, warna, dan tekstur butiran pada berbagai varian beras. Sistem identifikasi beras saat ini masih mengandalkanindra penglihatan manusia yang rentan terhadap penilaian subjektif, kesalahan akibat kelelahan, serta keterbatasan waktu dalam proses identifikasi manual [8], [9].

Berbagai penelitian telah dilakukan untuk mengatasi tantangan identifikasi beras secara otomatis menggunakan teknologi pengolahan citra digital dan kecerdasan buatan. Nurfalah et al. (2021) berhasil mengidentifikasi tiga jenis beras impor dengan algoritma Multi-SVM yang mencapai akurasi

96,296%, menggunakan kombinasi fitur morfologi dan *Gray Level Co-Occurrence Matrix* (GLCM) [10]. Perkembangan selanjutnya menunjukkan keunggulan *Convolutional Neural Network* (CNN) dalam klasifikasi beras, seperti yang ditunjukkan oleh Prabowo dan Hadikurniawati (2023) yang mencapai akurasi 88,15% untuk 12 jenis beras lokal Indonesia [8], serta Altim et al. (2022) yang berhasil mengklasifikasi delapan kelas beras dengan akurasi di atas 90% [11]. Penelitian Ardiansyah dan Sela (2023) bahkan mencapai akurasi 98,06% untuk empat jenis beras menggunakan CNN dengan teknik augmentasi data [9].

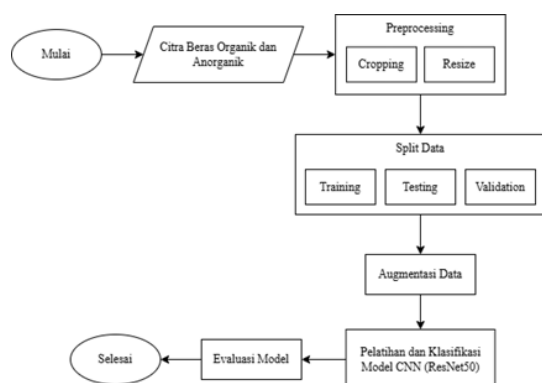
Arsitektur CNN yang lebih canggih, khususnya *ResNet-50*, telah menunjukkan potensi besar dalam klasifikasi citra produk pertanian. Kulsum dan Cherid (2023) membuktikan efektivitas *ResNet-50* dengan akurasi 91% untuk klasifikasi daun apel [12], sementara Oktafanda (2022) mencapai akurasi 95% dalam klasifikasi kualitas bibit kelapa sawit [13]. Keberhasilan ini menunjukkan bahwa *ResNet-50* memiliki kemampuan unggul dalam mengenali pola visual yang kompleks, bahkan dengan dataset yang relatif terbatas, melalui penerapan *transfer learning* dan strategi augmentasi data yang tepat.

Meskipun berbagai metode telah dikembangkan, pendekatan berbasis algoritma tradisional masih memerlukan tahapan pre-processing dan ekstraksi fitur yang kompleks serta rawan kesalahan, sedangkan sebagian model CNN yang ada belum memanfaatkan arsitektur mendalam atau hanya terbatas pada klasifikasi jenis beras tertentu. Sebagai solusi atas permasalahan tersebut, penelitian ini mengembangkan pendekatan berbasis *Convolutional Neural Network* (CNN) dengan arsitektur *ResNet-50* yang mampu mengklasifikasikan beras organik dan anorganik secara otomatis berdasarkan ciri visual. *ResNet-50* dipilih karena unggul dalam mengidentifikasi detail visual yang halus, seperti perbedaan warna dan bentuk butiran beras, yang sering kali sulit diamati oleh manusia secara langsung. Sistem klasifikasi yang dikembangkan ditujukan sebagai alat bantu analisis visual untuk kalangan profesional seperti peneliti, akademisi, atau teknisi laboratorium mutu pangan, yang bekerja dalam lingkungan dengan akses terhadap perangkat mikroskop digital. Dengan pendekatan ini, diharapkan proses identifikasi beras dapat dilakukan secara lebih akurat, objektif, dan efisien dalam skenario pengujian atau penelitian berbasis citra. Namun, penelitian yang mengkaji penggunaan *ResNet-50* untuk klasifikasi beras berbasis citra mikroskopik masih sangat terbatas.

## 2. Metode Penelitian

Penelitian ini dilaksanakan dengan menggunakan perangkat keras berupa laptop yang memiliki spesifikasi prosesor Intel Core i5 generasi ke-11. Perangkat lunak yang digunakan meliputi MATLAB untuk proses pra-pemrosesan citra, serta *Jupyter Notebook* sebagai lingkungan pengembangan utama dengan bahasa pemrograman *Python*.

Alur penelitian yang digunakan dalam penelitian ini terdiri dari enam tahap yang berurutan dan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian


### 2.1. Pengumpulan Data

Penelitian ini menggunakan data berupa citra beras organik dan anorganik yang diperoleh melalui proses pengambilan gambar langsung menggunakan mikroskop digital dengan sensor CMOS. Mikroskop ini memiliki kemampuan pembesaran hingga 1600X, dengan fokus pada jarak 15 mm hingga 40 mm dan resolusi citra maksimal 1920×1440 piksel, meskipun dalam penelitian ini digunakan pada resolusi 640×480 piksel agar sesuai dengan standar input model.

Proses pengambilan gambar dilakukan dengan menghubungkan mikroskop ke laptop melalui antarmuka USB 3.0/2.0/1.1 dan menggunakan perangkat lunak *HiView20230724* sebagai penampil serta penyimpanan citra. Mikroskop dilengkapi dengan 8 lampu LED bawaan yang dapat disesuaikan intensitasnya, sehingga pencahayaan selama proses pengambilan citra dapat dijaga agar konsisten. Gambar diambil dari jarak fokus optimal agar butiran beras terlihat jelas dan tajam, kemudian disimpan dalam format .JPG sesuai dengan kemampuan penyimpanan alat.

Setiap sampel beras ditempatkan pada permukaan datar dan diamati melalui mikroskop dalam kondisi pencahayaan terkendali. Untuk menjaga konsistensi data, seluruh pengambilan gambar dilakukan pada posisi dan sudut yang seragam, serta menggunakan dimensi citra tetap yaitu 640×480 piksel. Dataset yang dikumpulkan terdiri dari 1.000 citra, yang terdiri dari 500 citra beras organik dan 500 citra beras anorganik. Contoh visual dari hasil pengambilan citra ditunjukkan pada Gambar 2, yang memperlihatkan

tampilan citra mikroskopik beras organik dan anorganik secara berurutan.




Gambar 2. Citra Mikroskopik Beras Organik dan Anorganik

### 2.2. Pre-processing

#### 2.2.1. Cropping


Proses *cropping* (pemotongan citra) yang bertujuan untuk memusatkan perhatian pada objek utama dengan menghilangkan bagian latar belakang, sehingga bagian citra yang diinginkan dapat diperoleh secara lebih jelas [14]. Pada penelitian ini, tahap pra-proses dilakukan dengan melakukan *cropping* terhadap citra awal berukuran 640 × 480 piksel, dimana proses pemotongan disesuaikan dengan area permukaan beras untuk menghilangkan latar belakang yang tidak diperlukan. Langkah ini bertujuan untuk memfokuskan analisis pada objek utama, yaitu butiran beras. Hasil dari proses *cropping* ditunjukkan pada Gambar 3.




Gambar 3. Citra Mikroskopik Beras Organik dan Anorganik

#### 2.2.2. Resize

Resize merupakan teknik untuk mengecilkan ukuran ataupun resolusi dari sebuah citra tanpa menghilangkan informasi khusus yang terdapat pada citra tersebut [15]. Setelah proses *cropping*, dilakukan *resize* atau mengubah ukuran citra menjadi 224 × 224 piksel untuk menyesuaikan dengan input standar arsitektur *ResNet-50*. Dalam proses *resize* ini, agar proporsi objek beras tetap terjaga dan tidak mengalami distorsi, penambahan *padding* dilakukan pada bagian atas dan bawah citra. Langkah ini memastikan bahwa bentuk butiran beras tetap utuh tanpa mengalami peregangan secara vertikal. Contoh hasil citra setelah proses *resize* dapat dilihat pada Gambar 4.



Gambar 4. Citra Mikroskopik Beras Organik dan Anorganik




Gambar 5. Augmentasi Citra Training

### 2.3. Split Data

Setelah proses *pre-processing* selesai, dataset dibagi menjadi tiga subset menggunakan teknik data splitting. Dataset dibagi dengan rasio 70% untuk data *training* (700 sampel), 15% untuk data validasi (150 sampel), dan 15% untuk data *testing* (150 sampel). Pembagian ini dilakukan secara acak (*random shuffle*) untuk memastikan distribusi data yang merata pada setiap subset. Data *training* digunakan untuk melatih model, data validasi untuk evaluasi selama proses pelatihan, dan data *testing* untuk menguji performa akhir model. Struktur folder yang dihasilkan adalah train, val, dan test, dengan masing-masing folder berisi subfolder untuk setiap kelas beras (Organik dan Anorganik).

### 2.4. Augmentasi Data

Augmentasi data adalah proses menambah jumlah dataset melalui manipulasi data pada dataset yang ingin digunakan, berupa manipulasi citra dengan mengubah piksel pada citra yang mengakibatkan terbentuknya citra baru tanpa menghilangkan informasi-informasi penting yang ada dalam citra tersebut [16]. Untuk meningkatkan keragaman data dan mencegah *overfitting*, dilakukan augmentasi data pada subset training dengan menerapkan beberapa teknik augmentasi yang meliputi *random horizontal flip* dengan probabilitas 50%, rotasi acak hingga 20 derajat, dan color jitter yang mengubah *brightness*, *contrast*, *saturation*, dan *hue* secara acak. Sementara itu, data validasi dan testing hanya dilakukan normalisasi menggunakan nilai *mean* dan *standard deviation ImageNet* tanpa augmentasi untuk memastikan konsistensi evaluasi. Normalisasi dilakukan pada semua subset dengan nilai *mean* [0.485, 0.456, 0.406] dan *standard deviation* [0.229, 0.224, 0.225] sesuai standar *ImageNet*. Gambar 5 dan 6 menunjukkan perbandingan antara citra *training* yang telah diaugmentasi dengan citra testing yang tidak diaugmentasi.

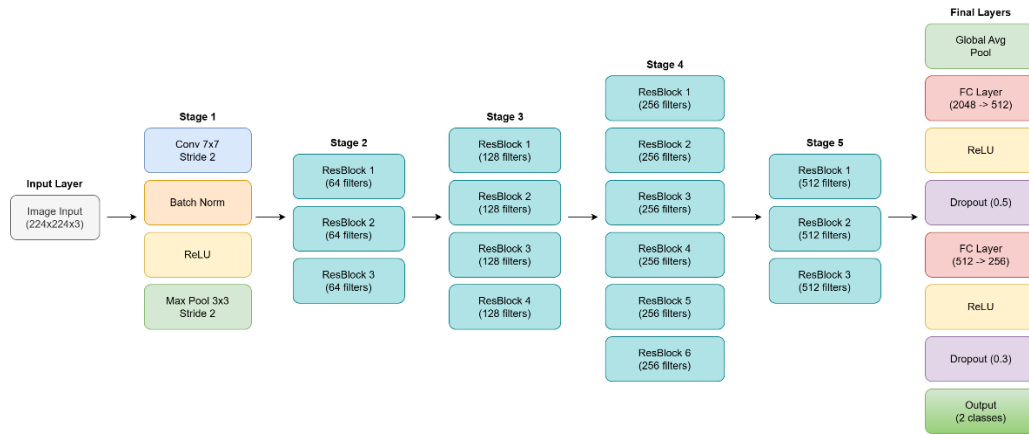


Gambar 6. Citra Testing tanpa Augmentasi

### 2.5. Klasifikasi CNN Berbasis ResNet-50

*Convolutional Neural Network* (CNN) merupakan salah satu algoritma paling efektif dalam *deep learning* yang dirancang khusus untuk mengolah data citra. CNN termasuk bagian dari deep neural network yang dikembangkan dari *Artificial Neural Network* (ANN) dan memiliki kemampuan untuk mengenali serta mengklasifikasi objek dalam gambar secara otomatis [17]. *ResNet-50* adalah salah satu varian dari arsitektur *ResNet* yang memiliki kedalaman 50 lapisan dan telah dilatih pada jutaan gambar dari basis data *ImageNet* [18]. Model klasifikasi citra pada penelitian ini menggunakan arsitektur CNN berbasis *ResNet-50* dengan bobot awal (*pre-trained weights*) dari *ImageNet*. Lapisan fitur bawaan dari *ResNet-50* dibekukan (*frozen*) untuk menjaga representasi fitur dasar, sementara bagian akhir dari jaringan dimodifikasi menggunakan *multilayer perceptron* (MLP) yang terdiri dari tiga lapisan *fully connected* dengan fungsi aktivasi *ReLU* dan *dropout* untuk mencegah *overfitting*. Model dilatih menggunakan fungsi *loss CrossEntropyLoss* dan dioptimalkan dengan algoritma Adam, serta diatur menggunakan *learning rate scheduler*. Proses pelatihan dilakukan selama maksimal 25 *epoch* dengan mekanisme *early stopping* untuk menghentikan pelatihan jika akurasi validasi tidak mengalami peningkatan selama beberapa *epoch* berturut-turut. Model terbaik kemudian digunakan untuk proses evaluasi pada data pengujian. Struktur lengkap dari arsitektur klasifikasi yang dimodifikasi dari *ResNet-50* disajikan pada Gambar 7.





Gambar 7. Struktur Klasifikasi pada Model ResNet-50 yang Dimodifikasi

## 2.6. Evaluasi Model

Evaluasi kinerja model klasifikasi dalam penelitian ini dilakukan dengan menggunakan metode *Confusion Matrix*, yang merupakan sebuah tabel untuk menggambarkan performa model klasifikasi dengan menunjukkan jumlah data uji yang diklasifikasikan secara benar maupun salah [19]. *Confusion matrix* memuat empat komponen utama, yaitu *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)*, yang menjadi dasar untuk menghitung metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Adapun rumus-rumus perhitungan metrik tersebut ditunjukkan pada persamaan 1 hingga 4.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

Keterangan:

TP (*True Positive*): Positif yang diprediksi benar.

TN (*True Negative*): Negatif yang diprediksi benar.

FP (*False Positive*): Negatif yang salah diprediksi sebagai positif.


FN (*False Negative*): Positif yang salah diprediksi sebagai negatif.

*Accuracy* menunjukkan sejauh mana model mampu mengklasifikasikan seluruh data dengan benar, *precision* mengukur ketepatan klasifikasi positif, *recall* (juga dikenal sebagai *True Positive Rate*) mengukur sensitivitas model dalam mendeteksi kelas positif yang sebenarnya, sedangkan *F1-score* memberikan keseimbangan antara *precision* dan *recall* dalam satu metrik [20].

Selain *confusion matrix*, evaluasi juga diperkuat dengan menggunakan *classification report* yang memberikan ringkasan metrik-metrik tersebut untuk masing-masing kelas. Laporan ini sangat berguna dalam memahami kekuatan dan kelemahan model pada tiap kategori klasifikasi. Di samping itu, grafik *training loss* dan *validation loss* turut digunakan untuk memvisualisasikan performa model selama proses pelatihan. Grafik ini menggambarkan bagaimana tingkat kesalahan model menurun dari waktu ke waktu pada data pelatihan dan validasi. Pola konvergensi yang baik dari grafik ini menunjukkan bahwa model belajar secara optimal dan tidak mengalami *overfitting* atau *underfitting* terhadap data.

## 3. Hasil dan Pembahasan


Grafik *Model Loss* pada Gambar 8 menggambarkan perubahan nilai *loss* selama proses pelatihan model. Meskipun pelatihan ditetapkan selama maksimal 25 *epoch*, proses pelatihan secara otomatis berhenti pada *epoch* ke-20 karena akurasi validasi tidak mengalami peningkatan selama beberapa *epoch* berturut-turut, sesuai dengan mekanisme *early stopping*. Baik pada data pelatihan (*training loss*) maupun data validasi (*validation loss*). Pada awal proses pelatihan (*epoch* 1–3), terlihat penurunan *loss* yang sangat tajam pada kedua data, menunjukkan bahwa model dengan cepat mempelajari pola dasar dari data input. Selanjutnya, *training loss* terus mengalami penurunan secara konsisten hingga mencapai nilai mendekati nol pada *epoch* akhir, mengindikasikan bahwa model semakin optimal dalam meminimalkan kesalahan terhadap data pelatihan.



Gambar 8. Grafik Training Loss dan Validation Loss

Sementara itu, *validation loss* juga menurun pada awal *epoch*, namun setelah mencapai titik minimum di sekitar *epoch* ke-5 hingga ke-10, nilai tersebut mulai mengalami sedikit fluktuasi. Meskipun demikian, fluktuasi tersebut masih dalam rentang yang stabil dan tidak menunjukkan lonjakan drastis, sehingga tidak mengindikasikan adanya *overfitting* yang serius. Perbedaan kecil antara *training loss* dan *validation loss* menunjukkan bahwa model mampu mempertahankan kemampuan generalisasi yang baik. Dengan demikian, grafik ini mengonfirmasi bahwa proses pelatihan berlangsung secara efektif dan stabil.


Adapun Grafik yang ditunjukkan pada Gambar 9 memperlihatkan bahwa *Model Accuracy* pada data pelatihan (*training accuracy*) dan validasi (*validation accuracy*) selama 20 *epoch*. Akurasi model meningkat secara drastis pada awal pelatihan, khususnya antara *epoch* ke-1 hingga ke-3, yang menandakan bahwa model dengan cepat mampu mengenali pola dalam data. Setelah itu, baik *training accuracy* maupun *validation accuracy* terus mengalami peningkatan dan cenderung stabil, dengan nilai akurasi yang tinggi, yaitu di atas 95%.



Gambar 9. Grafik Training Accuracy dan Validation Accuracy

Garis akurasi pelatihan dan validasi yang saling berdekatan juga memperkuat indikasi bahwa model tidak mengalami *overfitting* atau *underfitting*. Tidak terdapat perbedaan signifikan antara kinerja model pada data yang dilatih dan data yang belum pernah dilihat sebelumnya. Dengan kata lain, model memiliki performa klasifikasi yang konsisten dan mampu melakukan generalisasi dengan baik terhadap data baru. Tren akurasi yang tinggi dan stabil ini menunjukkan bahwa arsitektur dan parameter model

yang digunakan sudah sesuai dan efektif dalam menyelesaikan tugas klasifikasi.



Gambar 10. Confusion Matrix

Hasil confusion matrix pada Gambar 10 menunjukkan performa model dalam mengklasifikasikan dua jenis beras, yaitu anorganik dan organik. Dari total 150 data uji yang digunakan, model mampu mengklasifikasikan 73 sampel beras anorganik dengan benar, dan hanya 2 sampel yang salah diprediksi sebagai beras organik. Sementara itu, dari kategori organik, sebanyak 72 sampel berhasil diklasifikasikan dengan tepat, dan hanya 3 sampel yang salah dikenali sebagai beras anorganik.

Hasil ini menunjukkan bahwa model memiliki tingkat presisi dan sensitivitas yang sangat tinggi terhadap kedua kelas beras. Sebagian besar prediksi sesuai dengan label sebenarnya, yang mengindikasikan performa klasifikasi yang sangat baik. Nilai *True Positive* dan *True Negative* yang dominan dalam *confusion matrix* ini mendukung kesimpulan bahwa model mampu mengenali karakteristik visual dari beras organik dan anorganik dengan akurasi tinggi. Evaluasi ini juga konsisten dengan grafik akurasi dan loss sebelumnya yang menunjukkan proses pelatihan yang stabil dan efektif.

Table 1. Classification Report

| Class/ Metric | Precision | Recall | F1-Score |
|---------------|-----------|--------|----------|
| Anorganik     | 96.05     | 97.33  | 96.69    |
| Organik       | 97.30     | 96.00  | 96.64    |
| Accuracy      | 96.67     |        |          |

Tabel 1 menyajikan hasil *classification report* yang digunakan untuk mengevaluasi performa model dalam mengklasifikasikan beras menjadi dua kategori: anorganik dan organik. Hasil evaluasi memperlihatkan bahwa model memiliki *precision* sebesar 96,05% untuk beras anorganik dan 97,30% untuk beras organik. Ini berarti ketika model memprediksi sebuah sampel sebagai anorganik atau organik, tingkat kebenarannya sangat tinggi.

Dari segi *recall*, model juga menunjukkan performa yang sangat baik, yaitu 97,33% untuk beras anorganik dan 96,00% untuk beras organik. Nilai *recall* yang

tinggi menunjukkan bahwa sebagian besar sampel dari masing-masing kelas berhasil dikenali dengan benar oleh model.

Nilai *F1-score* yang mendekati 1 pada kedua kelas (96,69% untuk anorganik dan 96,64% untuk organik) menunjukkan keseimbangan yang sangat baik antara *precision* dan *recall*. Secara keseluruhan, model mencapai akurasi 96,67%, dan baik rata-rata makro maupun rata-rata berbobot menghasilkan skor yang sama, yaitu 96,67%. Hal ini mencerminkan bahwa model tidak hanya akurat secara umum, tetapi juga menunjukkan kinerja yang seimbang antara kedua kelas beras tersebut.



Gambar 11. Contoh Citra Beras yang Mengalami Kesalahan Klasifikasi

Gambar 11 memperlihatkan lima contoh citra beras yang mengalami kesalahan klasifikasi oleh model CNN berbasis arsitektur *ResNet-50*. Berdasarkan anotasi pada masing-masing gambar, diketahui bahwa kesalahan meliputi prediksi yang tidak sesuai dengan label sebenarnya, baik dari kelas beras organik maupun anorganik.

Tiga dari lima sampel merupakan citra beras organik yang secara keliru diprediksi sebagai beras anorganik, dengan tingkat keyakinan (*confidence*) bervariasi antara 0,626 hingga 0,786. Sementara dua gambar lainnya adalah beras anorganik yang salah diklasifikasikan sebagai organik dengan *confidence* sebesar 0,618 dan 0,814. Nilai *confidence* yang relatif sedang hingga tinggi menunjukkan bahwa model memiliki tingkat kepercayaan yang cukup kuat terhadap prediksi yang salah tersebut.

Secara visual, butiran beras yang salah diklasifikasikan memiliki kemiripan dalam hal bentuk, tekstur permukaan, dan kecerahan warna, yang kemungkinan besar menyebabkan ambiguitas pada model dalam mengekstraksi ciri khas dari masing-masing kelas. Hal ini mengindikasikan bahwa terdapat tumpang tindih fitur visual antar kelas, terutama pada area yang tidak terlalu kontras dalam hal warna atau tekstur. Selain itu, kemungkinan variasi kecil dalam pencahayaan, refleksi permukaan, atau ketidaksempurnaan dalam proses *cropping* juga turut memengaruhi kesalahan prediksi.

Meskipun jumlah kesalahan klasifikasi relatif kecil dan nilai *confidence*-nya tidak ekstrem (di bawah

0,9), visualisasi ini penting untuk mengevaluasi kelemahan model dalam mendeteksi batas-batas antar kelas yang sempit. Oleh karena itu, perlu dipertimbangkan penguatan data melalui teknik augmentasi yang lebih variatif atau *fine-tuning* tambahan pada model untuk meningkatkan sensitivitas terhadap fitur-fitur minor yang membedakan beras organik dan anorganik.

#### 4. Kesimpulan

Penelitian ini berhasil menerapkan arsitektur *Convolutional Neural Network* berbasis *ResNet-50* untuk klasifikasi citra beras organik dan anorganik. Dengan memanfaatkan dataset citra mikroskopik yang telah melalui proses *pre-processing*, augmentasi, dan pembagian data, model menghasilkan performa tinggi dengan akurasi mencapai 96,67%. Evaluasi menggunakan *confusion matrix* dan *classification report* menunjukkan bahwa model memiliki nilai *precision*, *recall*, dan *F1-score* yang tinggi serta seimbang pada kedua kelas. Hasil ini membuktikan bahwa pendekatan *deep learning* dengan *ResNet-50* mampu mengenali perbedaan visual antara beras organik dan anorganik secara otomatis dan akurat, serta berpotensi untuk dikembangkan sebagai sistem identifikasi beras berbasis citra digital.

#### Daftar Rujukan

- [1] E. Suprpto, M. W. Ardhi, and D. Apriandi, "Peningkatan Ekonomi Melalui Penerapan Sistem Padi Organik Di Desa Pojok, Kwadungan, Ngawi," *Stud. Kasus Inov. Ekon.*, vol. 6, no. 01, pp. 37–42, 2022, doi: 10.22219/skie.v6i01.20301.
- [2] Y. Zamrodah, "FAKTOR-FAKTOR YANG MEMPENGARUHI KONSUMEN TERHADAP PEMBELIAN BERAS ORGANIK (Studi kasus di Kecamatan Selopuro Kabupaten Blitar)," *VIABEL J. Ilm. Ilmu-Ilmu Pertan.*, vol. 15, no. 2, pp. 49–57, 2021, doi: 10.35457/viabel.v15i2.1771.
- [3] A. Aulia Martina, D. Dulbari, J. Kartahadimaja, and S. Subarjo, "Kualitas Beras dan Kandungan Gizi Tiga Genotipe Padi yang Dibudidayakan secara Organik dan Non Organik," *J-Plantasimbiosa*, vol. 6, no. 1, pp. 38–52, 2024, doi: 10.25181/jplantasimbiosa.v6i1.3512.
- [4] E. Sari *et al.*, "SOSIALISASI LITERASI PRODUCT QUALITY BERAS ORGANIK DI RPTRA KELURAHAN PAPANGGO KECAMATAN TANJUNG PRIOK," vol. 6, no. 1, pp. 2023–2026, 2025.
- [5] A. Kamil, E. Dasipah, K. KS, D. Sukmawati, and A. Dahtiar, "FAKTOR YANG MEMPENGARUHI KEPUTUSAN PETANI DALAM MENERAPKAN TEKNOLOGI USAHATANI PADI ORGANIK DAN DAMPAKNYA TERHADAP PRODUKTIVITAS DAN PENDAPATAN (Kasus Pada Petani di Kecamatan Cibeber, Kabupaten Cianjur)," *Mimb. Agribisnis J. Pemikir. Masy. Ilm. Berwawasan Agribisnis*, vol. 9, no. 1, p. 1382, 2023, doi: 10.25157/ma.v9i1.9562.
- [6] I. A. Made, D. Susanti, N. P. Sukanteri, I. Made Budiasa, and K. Jaiman, "Persepsi Konsumen terhadap Beras Organik Mentik Susu," *J. Agribisnis*, vol. 25, no. 1, pp. 62–73, 2023, [Online]. Available: <https://doi.org/10.31849/agr.v25i1.13119>
- [7] A. Prasetyo, T. Supriyadi, and A. T. Suryaningsih,

- “Kepuasan Konsumen Muda Terhadap Desain Kemasan Beras Organik Di Indonesia,” *Agrisaintifika J. Ilmu-Ilmu Pertan.*, vol. 7, no. 2, pp. 205–211, 2023, doi: 10.32585/ags.v7i2.4298.
- [8] S. Tegar Prabowo and W. Hadikumiawati, “Deteksi Dan Pengenalan Jenis Beras Menggunakan Metode Convolutional Neural Network,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 1, pp. 163–167, 2023, doi: 10.36040/jati.v7i1.6150.
- [9] R. Ardiansyah and E. Itje Sela, “Implementasi Convolutional Neural Network Untuk Klasifikasi Jenis Beras Berdasarkan Citra Digital,” *Indones. J. Comput. Sci.*, vol. 12, no. 6, pp. 4172–4182, 2023, doi: 10.33022/ijcs.v12i6.3520.
- [10] R. Nurfalah, Dwiza Riana, and Anton, “Identifikasi Citra Beras Menggunakan Algoritma Multi-SVM Dan Neural Network Pada Segmentasi K-Means,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 55–62, 2021, doi: 10.29207/resti.v5i1.2721.
- [11] MUH ZAINAL ALTIM, FAISAL, SALMIAH, KASMAN, ANDI YUDHISTIRA, and RITA AMALIA SYAMSU, “Pengklasifikasi Beras Menggunakan Metode Cnn (Convolutional Neural Network),” *J. INSTEK (Informatika Sains dan Teknol.)*, vol. 7, no. 1, pp. 151–155, 2022, doi: 10.24252/instek.v7i1.28922.
- [12] U. Kulsum and A. Cherid, “Penerapan Convolutional Neural Network Pada Klasifikasi Tanaman Menggunakan ResNet50,” *Simkom*, vol. 8, no. 2, pp. 221–228, 2023, doi: 10.51717/simkom.v8i2.191.
- [13] E. Oktafanda, “Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN),” *J. Inform. Ekon. Bisnis*, vol. 4, no. 3, pp. 72–77, 2022, doi: 10.37034/infkeb.v4i3.143.
- [14] J. P. Wiastopo and I. Imelda, “Deteksi Kesegaran Ikan Kembung dengan Metode KNN Berdasarkan Fitur GLCM dan RGB-HSV,” vol. 13, no. September, pp. 10–16, 2024.
- [15] N. L. Utami, A. Nazir, E. Budianita, and F. Insani, “Jurnal Computer Science and Information Technology ( CoSciTech ) algoritma apriori,” vol. 5, no. 1, pp. 75–83, 2024.
- [16] J. A. Figo, N. Yudistira, and A. W. Widodo, “Deteksi Covid-19 dari Citra X-ray menggunakan Vision Transformer,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1116–1125, 2023, [Online]. Available: <https://j-ptiik.ub.ac.id>
- [17] C. Nisa and F. Candra, “Klasifikasi Jenis Rempah-Rempah Menggunakan Algoritma Convolutional Neural Network,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 78–84, 2023, doi: 10.57152/malcom.v4i1.1018.
- [18] T. Berliani, E. Rahardja, and L. Septiana, “Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16,” *J. Med. Heal.*, vol. 5, no. 2, pp. 123–135, 2023, doi: 10.28932/jmh.v5i2.6116.
- [19] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 697–711, 2021.
- [20] G. Rininda, I. Hartami Santi, and S. Kirom, “Penerapan Svm Dalam Analisis Sentimen Pada Edlink Menggunakan Pengujian Confusion Matrix,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 5, pp. 3335–3342, 2024, doi: 10.36040/jati.v7i5.7420.