

KLASIFIKASI 3 MEREK BERAS DI KOTA SAMARINDA MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)

Putri Pita Mutia

Program Studi Matematika, FMIPA, Universitas Mulawarman, Samarinda, Indonesia

e-mail: putripitamutia@gmail.com*

Fidia Deny Tisna Amijaya

Program Studi Matematika, FMIPA, Universitas Mulawarman, Samarinda, Indonesia

e-mail: fidiadta@fmipa.unmul.ac.id

Wasono

Program Studi Matematika, FMIPA, Universitas Mulawarman, Samarinda, Indonesia

e-mail: wasono@fmipa.unmul.ac.id

Abstrak

Beras merupakan objek citra digital yang memiliki karakteristik visual berupa bentuk, ukuran, dan tekstur yang dapat direpresentasikan sebagai fitur untuk proses klasifikasi. Perbedaan karakteristik antar merek beras memungkinkan penerapan metode *deep learning* untuk mengenali pola citra secara otomatis. Salah satu algoritma *deep learning* yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN), yaitu metode yang mampu mengekstraksi fitur citra secara otomatis melalui proses konvolusi. Penelitian ini bertujuan menerapkan algoritma *Convolutional Neural Network* (CNN) dalam mengklasifikasikan tiga merek beras di Kota Samarinda serta menganalisis performa model yang dihasilkan. *Dataset* yang digunakan merupakan data primer sebanyak 1.050 citra digital beras yang diperoleh melalui pengambilan gambar secara langsung. Data dibagi ke dalam dua skenario pelatihan dan pengujian, yaitu 70:30 dan 80:20. Tahap pra-pemrosesan meliputi normalisasi nilai piksel ke interval $[0,1]$ dan transformasi ukuran citra menjadi 64×64 , 128×128 , dan 224×224 piksel. Untuk meningkatkan kemampuan generalisasi model, diterapkan augmentasi data pada data latih. Model CNN disusun menggunakan operasi konvolusi, fungsi aktivasi ReLU, *pooling layer*, *dropout layer*, dan *fully connected layer*, dengan fungsi aktivasi *Softmax* pada lapisan keluaran. Hasil penelitian menunjukkan bahwa model terbaik diperoleh pada skenario pembagian data 80:20 dengan ukuran input 128×128 piksel. Model menghasilkan *validation accuracy* sebesar 98,10% dan nilai *loss* sebesar 0,0733. Pada tahap pengujian diperoleh rata-rata *precision* 87,74%, *recall* 87,62%, dan *F1-score* 87,32%. Hasil tersebut menunjukkan bahwa metode CNN efektif digunakan dalam klasifikasi citra beras.

Kata Kunci: beras, citra digital, CNN, klasifikasi citra.

Abstract

Rice is a digital image object that possesses visual characteristics such as shape, size, and texture, which can be represented as features for classification tasks. Differences in characteristics among rice brands enable the application of deep learning methods to automatically recognize image patterns. One of the deep learning algorithms widely used in image classification is the *Convolutional Neural Network* (CNN), a method capable of automatically extracting image features through convolution operations. This study aims to apply the *Convolutional Neural Network* (CNN) algorithm to classify three rice brands in Samarinda City and analyze the performance of the resulting model. The dataset used consists of 1,050 primary digital rice images obtained through direct image acquisition. The data were divided into two training and testing scenarios, namely 70:30 and 80:20. The preprocessing stage included pixel value normalization into the interval $[0,1]$ and image resizing into 64×64 , 128×128 , and 224×224 pixels. To improve the model's generalization capability, data augmentation was applied to the training data. The CNN model was constructed using convolution operations, ReLU activation functions, pooling layers, dropout layers, and fully connected layers, with the *Softmax* activation function applied in the output layer. The results showed that the best model was obtained using the 80:20 data split scenario with an input size of 128×128 pixels. The model achieved a validation accuracy of 98.10% with a loss value of 0.0733. In the testing stage, the model obtained average precision, recall, and F1-score values of 87.74%, 87.62%, and 87.32%, respectively. These results indicate that the CNN method is effective for rice image classification.

Keywords: CNN, digital image, image classification, rice.

PENDAHULUAN

Beras menjadi salah satu bahan pangan pokok yang paling banyak dikonsumsi masyarakat Indonesia dengan tingkat konsumsi yang tinggi setiap tahunnya. Tingginya kebutuhan masyarakat terhadap beras menyebabkan banyaknya jenis dan merek beras yang beredar di pasaran (Yulnita dan Yeniwati, 2019). Berdasarkan Kementerian Pusat Data dan Sistem Informasi Pertanian Sekretariat Pertanian, 2025, adapun tren konsumsi beras di Provinsi Kalimantan Timur selama lima tahun terakhir menunjukkan fluktuasi. Pada tahun 2020 tercatat sebesar 82, 10 kg/kapita/tahun, kemudian pada tahun 2021 tercatat sebesar 82, 08 kg/kapita/tahun. Selanjutnya, pada tahun 2022 konsumsi beras menurun menjadi 79, 93 kg/kapita/tahun, kembali meningkat pada 2023 menjadi 82, 87 kg/kapita/tahun, dan kembali menurun pada 2024 sebesar 82, 55 kg/kapita/tahun. Berdasarkan tren tersebut, walaupun terdapat fluktuasi, tingkat konsumsi beras di rumah tangga cenderung stabil dengan kisaran di atas 79 kg/kapita/tahun. Hal ini menunjukkan bahwa beras merupakan bahan pokok utama bagi masyarakat di Provinsi Kalimantan Timur sehingga diperlukan upaya untuk menjaga kualitas dan keaslian beras.

Salah satu permasalahan yang banyak ditemukan adalah praktik pengoplosan beras, yang sempat diberitakan oleh detikcom (2025) dari hasil investigasi Kementerian Pertanian terdapat 212 merek beras yang terbukti melanggar beberapa standar yang telah ditentukan. Praktik tersebut dapat merugikan konsumen karena kualitas beras yang diterima tidak sesuai dengan standar maupun harga yang ditawarkan. Maraknya kasus pengoplosan beras menunjukkan bahwa proses identifikasi kualitas dan karakteristik beras menjadi hal yang penting untuk dilakukan. Setiap merek beras memiliki karakteristik visual yang berbeda, seperti bentuk, ukuran, warna, dan tekstur butiran. Perbedaan karakteristik tersebut dapat dimanfaatkan sebagai dasar dalam proses identifikasi maupun klasifikasi beras.

Pada umumnya, proses identifikasi beras masih dilakukan secara manual melalui pengamatan visual oleh manusia. Cara tersebut memiliki beberapa keterbatasan karena membutuhkan waktu yang

relatif lama, melelahkan, serta sangat bergantung pada subjektivitas pengamat. Selain itu, tingkat konsistensi hasil pengamatan manual juga cenderung rendah ketika jumlah data yang diamati semakin banyak. Oleh karena itu, diperlukan suatu metode otomatis yang mampu mengenali karakteristik visual beras secara lebih cepat, konsisten, dan akurat (Phukon et al., 2024).

Phukon et al., 2024 menyatakan bahwa perkembangan teknologi digital mendorong berkembangnya metode pengolahan citra digital (*image processing*) dan *computer vision* dalam berbagai bidang, termasuk pada sektor pangan. Melalui teknologi tersebut, komputer dapat mengenali pola dan karakteristik visual suatu objek berdasarkan citra digital yang diberikan. Salah satu pendekatan yang banyak digunakan dalam klasifikasi citra adalah metode *deep learning*. Metode ini mampu mempelajari pola data secara otomatis tanpa memerlukan proses ekstraksi fitur manual yang kompleks. Dalam bidang klasifikasi citra, salah satu algoritma *deep learning* yang memiliki performa baik adalah *Convolutional Neural Network* (CNN).

CNN merupakan pengembangan jaringan saraf tiruan yang dirancang untuk mengolah data berbentuk citra. Arsitektur CNN terdiri atas beberapa lapisan utama, seperti *convolutional layer*, *pooling layer*, dan *fully connected layer*. Melalui proses konvolusi, CNN mampu mengekstraksi fitur penting dari citra secara otomatis, seperti pola bentuk, tekstur, dan tepi objek. Kemampuan tersebut membuat CNN banyak digunakan dalam berbagai penelitian klasifikasi citra karena dinilai efektif dalam mengenali pola visual dengan tingkat akurasi yang tinggi. Selain itu, CNN juga memiliki kemampuan generalisasi yang baik terhadap data baru sehingga sesuai digunakan dalam permasalahan klasifikasi citra beras (Marnelius et al., 2023).

Berbagai penelitian sebelumnya telah menunjukkan keberhasilan penerapan CNN dalam klasifikasi citra. Penelitian yang dilakukan oleh Marnelius et al., 2023 dalam mengklasifikasikan lima jenis beras dengan menggunakan metode CNN dengan arsitektur *Residual Network* (ResNet-50). dengan akurasi 98% . Rabbani (2024) melakukan klasifikasi lima kelas beras dengan memanfaatkan CNN dan meningkatkan akurasi prediksi dari 86% menjadi 100% melalui penerapan *hyperparameter*

tuning. Kemudian Jauhari (2022) melakukan klasifikasi lima jenis beras dengan menerapkan CNN dengan arsitektur tambahan yakni dengan akurasi 93% pada *dataset* yang bagus sedangkan pada *dataset* yang buruk tingkat akurasinya senilai 68%. Selain penelitian pada beras, beberapa studi menggunakan CNN untuk klasifikasi citra pada komoditas lain. Wulandari et al. (2020) membahas klasifikasi tiga jenis bumbu dan rempah menggunakan CNN sederhana dan memperoleh akurasi sebesar 88%. Sementara itu, Mulyanto et al. (2021) menerapkan CNN pada pengenalan aksara Lampung berbasis *Optical Character Recognition* (OCR) dengan hasil akurasi sebesar 58%. Hasil penelitian tersebut menunjukkan bahwa performa CNN sangat dipengaruhi oleh kualitas *dataset*, variasi data, serta arsitektur model yang digunakan. Semakin baik kualitas data dan rancangan model, maka performa klasifikasi yang dihasilkan juga cenderung meningkat.

Namun, pada umumnya studi yang diperoleh menggunakan *dataset* yang bersifat umum atau dan tidak secara spesifik merepresentasikan kondisi beras yang beredar di suatu wilayah tertentu. Penelitian ini berbeda karena menggunakan *dataset* citra beras yang bersumber dari pasaran di kota Samarinda. Sehingga diharapkan hasil penelitian ini dapat memberikan model klasifikasi yang lebih akurat terhadap karakteristik visual beras yang umum ditemui oleh masyarakat di wilayah tersebut.

Berdasarkan permasalahan tersebut, penelitian ini mengimplementasikan algoritma *Convolutional Neural Network* (CNN) untuk mengklasifikasikan tiga merek beras yang beredar di Kota Samarinda berdasarkan citra digital. *Dataset* yang digunakan merupakan data primer hasil pengambilan gambar secara langsung terhadap tiga merek beras yang mewakili kelompok 1, 2 dan 3. Melalui penelitian ini diharapkan diperoleh model klasifikasi citra beras yang mampu mengenali karakteristik visual beras secara akurat sehingga dapat menjadi alternatif dalam membantu proses identifikasi kualitas beras secara otomatis.

KAJIAN TEORI

CITRA DIGITAL

Citra digital merupakan representasi data dua dimensi yang dapat dipandang sebagai sebuah *array* yang berisi nilai-nilai numerik yang direpresentasikan dalam bentuk deretan bit tertentu. Nilai-nilai tersebut merepresentasikan informasi visual dari suatu objek. Suatu citra dapat didefinisikan sebagai fungsi dua variabel $f(x, y)$ yang memiliki ukuran M baris dan N kolom dengan x dan y menyatakan posisi piksel pada citra dalam arah horizontal dan vertikal. Citra digital dapat dinyatakan dalam bentuk matriks dua dimensi sebagai berikut:

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N-1) \\ f(1,0) & f(1,1) & \dots & f(1, N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1, 0) & f(M-1, 1) & \dots & f(M-1, N-1) \end{bmatrix}$$

Nilai yang terletak pada perpotongan antara baris dan kolom, yaitu pada koordinat (x, y) disebut sebagai piksel dalam pengolahan citra digital (Putra, 2010).

NORMALISASI DATA


Mengacu pada pernyataan yang dituliskan Nasution et al. (2019) normalisasi data merupakan proses transformasi data yang bertujuan untuk menskalakan nilai atribut ke dalam rentang tertentu. Salah satu metode normalisasi yang umum digunakan adalah *Min-Max Normalization*. Metode *Min-Max Normalization* melakukan transformasi linier terhadap data asli sehingga nilai data berada pada rentang yang telah ditentukan. Secara matematis, transformasi tersebut dinyatakan sebagai berikut:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

CONVOLUTIONAL NEURAL NETWORK (CNN)

Menurut Latif et al. (2024) CNN atau jaringan saraf konvolusional adalah salah satu dari banyak contoh teknik *deep learning* yang dapat mencapai akurasi tinggi dalam masalah klasifikasi dan pengenalan gambar. Model berbasis CNN perlu diberikan *dataset* besar yang terdiri dari citra berlabel. *Dataset* ini biasanya dibagi menjadi dua bagian, bagian pertama digunakan untuk pelatihan dan bagian kedua digunakan untuk pengujian. Salah satu keunggulan model CNN adalah kecepatannya dalam

memproses data besar dan meningkatkan akurasi serta efisiensi dalam proses pengambilan keputusan.



Gambar 1. Arsitektur Sederhana CNN

Sumber: (Purwono et al., 2022)

Gambar 1 menunjukkan arsitektur CNN dasar. Arsitektur ini terdiri dari sejumlah lapisan, termasuk lapisan konvolusi, *pooling*, *dropout*, dan *dense*. Pada tahap awal, citra masukan diproses melalui *convolution layer* dan fungsi aktivasi ReLU untuk mengekstraksi karakteristik penting dari citra, seperti bentuk, tepi, dan tekstur objek. Selanjutnya, *pooling layer* digunakan untuk mengurangi ukuran fitur sehingga proses komputasi menjadi lebih efisien. Proses ekstraksi fitur dilakukan secara bertahap hingga diperoleh representasi fitur yang lebih kompleks.

Setelah itu, fitur hasil ekstraksi diubah menjadi vektor satu dimensi melalui *flatten layer* dan diteruskan ke *fully connected layer* untuk proses klasifikasi. Pada tahap akhir, fungsi aktivasi *Softmax* digunakan untuk menentukan probabilitas kelas sehingga model dapat memprediksi kategori objek berdasarkan citra yang diberikan (Zhang et al., 2023).

AUGMENTASI DATA

Berdasarkan pernyataan yang diungkapkan oleh (Shorten & Khoshgoftaar, 2019) salah satu teknik untuk membantu model menghindari *overfitting* yakni dengan memaksa jaringan saraf untuk belajar pada variasi yang lebih besar dari data yang disebut dengan data augmentasi. Data augmentasi merupakan teknik untuk meningkatkan jumlah data pelatihan tanpa mengumpulkan data baru namun dengan cara melakukan manipulasi gambar dari data pelatihan. Penerapan augmentasi perlu mempertimbangkan agar transformasi tidak mengubah makna label, sehingga jenis augmentasi harus disesuaikan dengan konteks data.

PEMBAGIAN DATASET

Menurut (Saptadi et al., 2025) pada proses pembelajaran mesin, pembagian data merupakan tahap penting yang bertujuan untuk menghindari

terjadinya *overfitting*. *Overfitting* adalah kondisi ketika model belajar terlalu detail dari data pelatihan hingga menangkap noise atau pola yang tidak relevan. Hal ini menyebabkan model memiliki performa yang sangat baik pada data pelatihan tetapi buruk pada data baru atau data pengujian. Sejalan dengan pernyataan yang dinyatakan oleh (Gholamy, Kreinovich, & Kosheleva, 2018) bahwa pembagian *dataset* dilakukan agar model tidak hanya menyesuaikan diri terhadap data latih, tetapi juga dapat diuji menggunakan data uji yang tidak pernah dilihat sebelumnya. Dengan cara ini, kemampuan generalisasi model dapat diukur secara objektif. Misalkan terdapat N data pengamatan yang dibagi ke dalam dua subset yaitu data uji dan data latih, sehingga dapat dituliskan sebagai berikut:

$$N_{train} = pN, N_{test} = (1 - p)N, 0 < p < 1 \quad (1)$$

EVALUASI MODEL

Menurut Chandra et al. (2022) pada algoritma klasifikasi perlu dilakukan evaluasi untuk mengetahui kinerja dan seberapa baik prediksi yang diperoleh, seberapa baik di sini berarti membandingkan hasil prediksi dengan label sebenarnya. Secara umum, perbandingan hasil klasifikasi dengan label sebenarnya dilakukan dengan menggunakan *confusion matrix* dan dibagi menjadi empat kategori yaitu:

1. *True Positive* (TP)
Model memprediksi kelas positif dan label sebenarnya juga benar-benar positif. Artinya, prediksi yang diberikan model sesuai dengan label sebenarnya.
2. *False Positive* (FP)
Model memprediksi kelas positif, label sebenarnya pada label sebenarnya data tersebut adalah negatif. Kesalahan ini dikenal sebagai *error* tipe 1.
3. *False Negative* (FN)
Model memprediksi kelas negatif, seharusnya pada label sebenarnya data tersebut adalah positif. Kesalahan ini disebut sebagai *error* tipe 2.
4. *True Negative* (TN)
Model memprediksi kelas negatif dan *ground truth* juga benar-benar negatif. Artinya, model berhasil mengenali sampel negatif dengan benar.

Selain itu terdapat beberapa metode evaluasi klasifikasi seperti menghitung *accuracy*, *precision*, *recall*, dan *F1-Score* sebagai berikut:

1. *Accuracy*

Menurut Fahmy (2015), pada klasifikasi multikelas, *confusion matrix* digunakan untuk mengevaluasi hasil prediksi model terhadap kelas sebenarnya. Nilai *accuracy* diperoleh dari perbandingan jumlah prediksi yang benar terhadap keseluruhan data pengujian dan dirumuskan sebagai berikut:

$$Accuracy = \frac{TP_A + TP_B + \dots + TP_n}{N} \quad (2)$$

2. *Precision*

Setelah memperoleh nilai akurasi, selanjutnya dihitung nilai presisi yang merupakan rasio antara prediksi benar positif terhadap keseluruhan hasil yang diprediksi positif. Dengan kata lain, presisi menggambarkan tingkat ketepatan hasil yang diberikan oleh sistem terhadap informasi yang diharapkan pengguna. Rumus presisi dapat dituliskan sebagai berikut:

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

3. *Recall*

Recall merupakan rasio antara prediksi benar positif terhadap keseluruhan data yang benar positif. *Recall* menunjukkan tingkat keberhasilan sistem dalam menemukan kembali informasi yang relevan. Rumus *recall* dapat dituliskan sebagai berikut:

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

4. *F1-Score*

F1-Score digunakan untuk mengetahui hubungan timbal balik antara *precision* dan *recall*. Rumus *F1-Score* dapat dituliskan sebagai berikut:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Pendekatan kuantitatif digunakan karena penelitian ini melibatkan proses pengumpulan dan pengolahan data numerik yang kemudian dianalisis secara statistik untuk menguji performa model. Metode eksperimen digunakan karena peneliti secara

langsung melakukan pengujian terhadap model CNN dalam melakukan klasifikasi merek beras berdasarkan citra digital.

Populasi dalam penelitian ini adalah seluruh merek beras yang beredar di pasaran Samarinda. Sampel yang digunakan meliputi tiga merek beras yang dikategorikan berdasarkan kelompok, yaitu kelompok 1, 2, dan 3. Masing-masing merek beras diambil sebanyak 350, sehingga total sampel keseluruhan berjumlah 1050 citra digital beras.

Dalam penelitian ini, data yang digunakan merupakan citra digital dari butir beras yang kemudian dikonversi menjadi representasi numerik dalam bentuk matriks piksel untuk digunakan sebagai *input* pada model CNN. Data citra digital tersebut digunakan secara langsung sebagai *input* model CNN tanpa melalui proses ekstraksi fitur manual, karena CNN mampu melakukan proses ekstraksi fitur secara otomatis melalui lapisan konvolusinya. Penjelasan mengenai variabel penelitian dapat dilihat pada Tabel

Tabel 1. Variabel Penelitian

Variabel	Keterangan	Satuan
Bebas (Independent)	Citra Digital Beras	Numerik
Terikat (Dependent)	Merek Beras (Mayas, Rahmat, 2 Ketupat Harum)	Kategori

Teknik pengumpulan data yang digunakan dalam penelitian ini termasuk dalam data primer, yakni data penelitian berupa citra digital butiran beras yang diperoleh melalui pengambilan gambar secara langsung menggunakan kamera smartphone Oppo Reno 6 dengan rasio citra 1:1. Pengambilan citra dilakukan dari sudut atas dengan latar belakang hitam polos untuk mengurangi gangguan visual (*noise*). Seluruh citra diambil pada malam hari dengan bantuan pencahayaan tambahan agar intensitas cahaya relatif seragam. Citra digital kemudian direpresentasikan ke dalam matriks piksel dan digunakan sebagai *input* model CNN.

Teknik analisis data merupakan metode yang digunakan untuk mengolah data citra sehingga dapat diperoleh informasi. Berikut adalah tahapan untuk menyusun model CNN yang mampu melakukan klasifikasi merek beras secara akurat.

1. Pembagian *Dataset*

Dataset citra yang digunakan dalam penelitian ini dibagi ke dalam data latih dan data uji

dengan dua skenario pembagian, yaitu 70:30 dan 80:20.

2. Pra-pemrosesan Citra Digital

Pra-pemrosesan untuk menyiapkan data sebelum masuk ke model CNN yang meliputi *resizing* dan normalisasi data.

3. Augmentasi Data

Augmentasi diimplementasikan dengan parameter *rotation range* sebesar 25° , *zoom range* sebesar 0,2, serta *width shift range*, *height shift range* masing-masing sebesar 0,15.

4. Perancangan Model CNN

Model CNN disusun dari *input layer*, *convolutional layer*, fungsi aktivasi yang digunakan pada setiap lapisan dalam CNN adalah *Rectified Linier Unit* (ReLU), *dropout layer*, *fully connected layer*, dan *output layer*.

5. Proses Pelatihan dan Optimasi Model

Selama proses ini, terjadi backward propagation untuk memperbarui bobot jaringan dengan menghitung fungsi loss, gradien dan optimasi parameter model menggunakan algoritma Adam.


6. Evaluasi Model

Menghitung *confusion matrix*, *accuracy*, *precision*, *recall* dan *F1-Score*.

HASIL DAN PEMBAHASAN

DATASET DAN PRA-PEMROSESAN


Data yang digunakan dalam penelitian ini berupa citra digital butir beras yang berasal dari tiga merek beras dengan kelompok yang berbeda, yakni kelompok 1 diwakilkan merek beras Mayas, kelompok 2 diwakilkan merek beras Rahmat, dan kelompok 3 diwakilkan merek beras 2 Ketupat Harum. Seluruh data citra diperoleh dari pasaran di Kota Samarinda. Setiap merek beras diambil sebanyak 350 citra, sehingga total keseluruhan data yang digunakan dalam penelitian ini berjumlah 1050 citra digital beras. Adapun contoh citra digital beras dari masing-masing merek ditampilkan pada Gambar 2.



Gambar 2. (a) Merek Mayas, (b) Merek Rahmat, dan (c) Merek Beras 2 Ketupat

Selanjutnya *dataset* dibagi dengan dua proporsi pembagian *dataset*, yakni 70%: 15%: 15% dan 80%: 10%: 10%. Pada proporsi data 70%: 15%: 15%, diperoleh bahwa sebanyak 735 data hasil pengacakan digunakan sebagai data latih, 158 data sebagai data validasi, dan 157 data sebagai data uji. Pada proporsi data 80%: 10%: 10%, diperoleh bahwa sebanyak 840 data hasil pengacakan digunakan sebagai data latih, sedangkan masing-masing 105 data digunakan sebagai data validasi dan data uji.

Tahap pra-pemrosesan dilakukan sebelum citra digunakan sebagai *input* citra digital pada model CNN. Proses pertama adalah *resizing* ukuran *input* citra ke dalam tiga variasi ukuran yang berbeda yakni 64×64 piksel, 128×128 piksel, dan 224×224 piksel. Variasi ukuran citra ini digunakan untuk melihat pengaruh resolusi citra terhadap performa klasifikasi model. Perbandingan citra beras sebelum dan sesudah dilakukan proses *resizing* ke dalam tiga variasi ukuran sebagai berikut.



Gambar 3. (a) Citra Asli, (b) Citra Ukuran 64×64 Piksel, (c) Citra Ukuran 128×128 Piksel dan (d) Citra Ukuran 224×224 Piksel

Proses kedua adalah normalisasi data untuk menyesuaikan skala nilai piksel agar dapat digunakan pada tahap selanjutnya sehingga diperlukan proses normalisasi. Normalisasi dilakukan menggunakan metode Min-Max Normalization dengan menskalakan nilai piksel ke dalam rentang 0 hingga 1 pada seluruh data citra digital.

Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*, diterapkan augmentasi data pada data latih menggunakan parameter *rotation range* sebesar 25° , *zoom range*

sebesar 0,2, serta *width shift range* dan *height shift range* masing-masing sebesar 0,15.

ARSITEKTUR CNN DAN PELATIHAN MODEL

CNN diawali dengan lapisan masukan yang berfungsi untuk menerima data citra digital hasil pra-pemrosesan ukuran 64×64 , 128×128 , dan 224×224 piksel yang direpresentasikan ke dalam bentuk matriks piksel menjadi representasi fitur melalui operasi konvolusi.

Proses selanjutnya dilakukan pada lapisan konvolusi yang berfungsi untuk mengekstraksi fitur-fitur dasar dari citra masukan. Pada lapisan ini dilakukan operasi konvolusi antara citra *input* dan filter, yakni dengan menghitung hasil perkalian elemen-sejajar antara nilai piksel citra *input* dan bobot filter. Hasil konvolusi kemudian dilewatkan ke fungsi aktivasi *Rectified Linier Unit* (ReLU) yang menghasilkan nilai aktivasi nonlinier.

Setelah proses konvolusi, dimensi fitur diperkecil menggunakan lapisan *pooling* untuk mengurangi kompleksitas komputasi dan mempertahankan fitur penting citra. Hasil ekstraksi fitur kemudian diubah menjadi vektor satu dimensi melalui lapisan penipisan dan dipetakan ke dalam proses klasifikasi menggunakan lapisan *fully connected*. Setelah proses tersebut, diterapkan lapisan *dropout* untuk mengurangi *overfitting*. Pada penelitian ini digunakan *dropout rate* sebesar 0,3 maka probabilitas *neuron* untuk dipertahankan selama proses pelatihan adalah 0,7. Diperoleh nilai 0 menunjukkan *neuron* yang dinonaktifkan, sedangkan nilai positif menunjukkan *neuron* yang tetap berperan dalam proses klasifikasi.

Pada tahap akhir, fungsi aktivasi *Softmax* digunakan untuk menghasilkan probabilitas keanggotaan setiap kelas sehingga model dapat menentukan hasil klasifikasi citra.

Selama proses pelatihan model CNN melakukan pembaruan bobot dan bias melalui mekanisme *backward propagation*. Proses ini dilakukan dengan menghitung gradien fungsi *loss* terhadap parameter model menggunakan aturan rantai (*chain rule*). Nilai gradien kemudian digunakan untuk memperbarui parameter model agar nilai *loss* semakin minimum pada setiap iterasi pelatihan. Dalam penelitian ini, proses optimasi parameter dilakukan menggunakan algoritma *Adaptive Moment Estimation* (Adam) karena mampu mempercepat konvergensi dan

menghasilkan pembaruan parameter yang lebih stabil.

Proses pelatihan model dilakukan menggunakan optimizer Adam dengan fungsi *loss categorical cross-entropy*. Pemilihan model terbaik dilakukan berdasarkan nilai *validation accuracy* tertinggi dan *validation loss* terendah.

PERBANDINGAN SKENARIO MODEL

Perbandingan hasil evaluasi kinerja model CNN pada seluruh kombinasi ukuran input citra dan proporsi pembagian data. Hasil perhitungan tingkat akurasi pada *dataset* dengan proporsi pembagian data 70%:30% pada ukuran input 64×64 , 128×128 , dan 224×224 , serta pada *dataset* dengan proporsi pembagian data 80%:20% pada ukuran *input* 64×64 , 128×128 , dan 224×224 , disajikan pada tabel berikut

Tabel 2. Hasil Pelatihan dan Validasi Model CNN Pada Berbagai Proporsi Pembagian dan *Input Size*


Prop orsi Data	Input Size	Train Accuracy	Train Loss	Validation Accuracy	Validation Loss	Epoch Optimal
70: 30	64 × 64	91,30%	0,2606	91,72%	0,1719	40
	128 × 128	89,13%	0,2585	95,54%	0,1372	31
	224 × 224	89,03%	0,2414	94,27%	0,1412	28
80: 20	64 × 64	86,84%	0,3384	89,52%	0,2457	22
	128 × 128	89,57%	0,2931	98,10%	0,0733	24
	224 × 224	87,17%	0,3296	96,19%	0,0925	14

Berdasarkan Tabel 2 terdapat keseluruhan nilai dari *validation accuracy* dan *validation loss* serta *epoch optimal* dari seluruh kombinasi proporsi pembagian data dan ukuran *input* citra. Diperoleh bahwa skenario dengan proporsi pembagian data 80%: 20% dan ukuran input citra 128×128 merupakan konfigurasi terbaik karena menghasilkan nilai *validation loss* paling rendah yakni sebesar 0,0733 dengan nilai akurasi 98,10% paling tinggi, nilai tersebut menunjukkan bahwa model memiliki kestabilan dan kemampuan generalisasi yang lebih baik pada proporsi data dan ukuran input citra tersebut.

CONFUSION MATRIX

Untuk memperoleh gambaran performa model secara menyeluruh, hasil prediksi model pada *dataset* dengan selanjutnya ditampilkan dalam bentuk *confusion matrix* pada model terbaik yang diperoleh

yakni proporsi pembagian data 80%:20% dengan ukuran *input* citra 128×128 sebagaimana ditunjukkan pada gambar berikut.



Gambar 4. *Confusion Matrix* Model Terbaik

Diperoleh *confusion matrix* pada Gambar 4 dari skenario pembagian data 80%:20% dengan ukuran *input* citra 128×128 menunjukkan performa model CNN dalam mengklasifikasikan data ke dalam tiga kelompok. Pada kelompok 1, model berhasil mengklasifikasikan 31 data dengan benar, pada kelompok 2, model berhasil mengklasifikasikan 26 data dengan benar dan pada kelompok 3, model berhasil mengklasifikasikan 35 data dengan benar. Secara umum, nilai TP yang relatif tinggi pada setiap kelompok menunjukkan bahwa model CNN memiliki kemampuan yang cukup baik dalam mengklasifikasikan data uji pada skenario ini.

ACCURACY, PRECISION, RECALL DAN F1-SCORE

Berdasarkan *confusion matrix* pada Gambar 4 dilakukan perhitungan metrik evaluasi berupa akurasi, *precision*, *recall* dan *F1-Score* untuk menilai kinerja model CNN sebagai berikut

1. Perhitungan Akurasi

Berdasarkan hasil *confusion matrix*, jumlah prediksi benar diperoleh dari penjumlahan nilai TP pada seluruh kelompok sebagai berikut.

$TP_{total} = TP_1 + TP_2 + TP_3 = 31 + 26 + 35 = 92$
Jumlah seluruh data uji adalah sebanyak 105. Berdasarkan Persamaan (2) nilai akurasi dihitung sebagai berikut.

$$Akurasi = \frac{92}{105} = 0,8762$$

Sehingga diperoleh nilai akurasi model CNN sebesar 87,62%.

2. Perhitungan *Precision*

Nilai FP pada masing-masing kelompok diperoleh dari jumlah data kelompok lain yang salah diprediksi ke kelompok tersebut.

Berdasarkan hasil *confusion matrix*, diperoleh $FP_1 = 3$, $FP_2 = 4$, dan $FP_3 = 6$. Berdasarkan Persamaan (3), nilai *precision* pada setiap kelompok dihitung sebagai berikut.

$$Precision_1 = \frac{31}{31 + 3} = 0,9118$$

$$Precision_2 = \frac{26}{26 + 4} = 0,8667$$

$$Precision_3 = \frac{35}{35 + 6} = 0,8537$$

$$Rata^2 Precision = \frac{0,9118 + 0,8667 + 0,8537}{3} = 0,8774$$

3. Perhitungan *Recall*

Nilai FN pada masing-masing kelompok diperoleh dari jumlah data pada kelompok tersebut yang salah diklasifikasikan ke kelompok lain. Berdasarkan hasil *confusion matrix*, diperoleh $FN_1 = 4$, $FN_2 = 9$, dan $FN_3 = 0$. Berdasarkan Persamaan (4), nilai *recall* dihitung sebagai berikut.

$$Recall_1 = \frac{31}{31 + 4} = 0,8857$$

$$Recall_2 = \frac{26}{26 + 9} = 0,7429$$

$$Recall_3 = \frac{35}{35 + 0} = 1$$

$$Rata^2 Recall = \frac{0,8857 + 0,7429 + 1}{3} = 0,8762$$

4. Perhitungan *F1-Score*

Nilai *F1-Score* diperoleh dari rata-rata harmonik antara nilai *precision* dan *recall* sebagaimana ditunjukkan pada Persamaan (5). Perhitungan *F1-Score* pada setiap kelompok adalah sebagai berikut.

$$F1_1 = \frac{2(0,9118)(0,8857)}{0,9118 + 0,8857} = 0,8986$$

$$F1_2 = \frac{2(0,8667)(0,7429)}{0,8667 + 0,7429} = 0,8000$$

$$F1_3 = \frac{2(0,8537)(1)}{0,8537 + 1} = 0,9211$$

$$Rata^2 F1 = \frac{0,8986 + 0,8000 + 0,9211}{3} = 0,8732$$

Berdasarkan hasil perhitungan tersebut, diperoleh nilai *accuracy*, *precision*, *recall*, dan *F1-Score* yang relatif tinggi pada setiap kelompok menunjukkan bahwa model CNN memiliki kemampuan yang cukup baik

dalam mengklasifikasikan data uji pada skenario pembagian data 80%:20% dengan ukuran input citra 128×128 . Hasil perhitungan metrik evaluasi tersebut disajikan pada tabel berikut.

Tabel 3. Hasil Perhitungan Metrik Evaluasi Dari Model Terbaik

Kelompok	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
Mayas	91,18%	88,57%	89,86%	87,62%
Rahmat	86,67%	74,29%	80%	
2 Ketupat Harum	85,37%	100%	92,11%	
Rata-rata	87,74%	87,62%	87,32%	

Berdasarkan tabel, dapat dilihat bahwa nilai pada kelompok 2 Ketupat Harum memiliki nilai *recall* dan *F1-Score* yang sangat tinggi menunjukkan model mampu mengklasifikasikan kelompok ini dengan sangat baik sedangkan pada kelompok Rahmat memiliki nilai *recall* dan *F1-Score* terendah yang menunjukkan bahwa performa model pada kelompok Rahmat masih lebih rendah dibandingkan kelompok lainnya.

PENUTUP

SIMPULAN

Berdasarkan hasil penelitian, algoritma CNN terbukti mampu mengklasifikasikan merek beras Mayas, Rahmat, dan 2 Ketupat Harum di Kota Samarinda ke dalam tiga kelompok berdasarkan citra digital. Performa model dipengaruhi oleh variasi proporsi pembagian data dan ukuran input citra yang digunakan. Pada skenario pembagian data 70%:30%, diperoleh nilai *validation accuracy* sebesar 91,72% untuk ukuran input 64×64 piksel, 95,54% untuk ukuran 128×128 piksel, dan 94,27% untuk ukuran 224×224 piksel. Sementara itu, pada skenario pembagian data 80%:20%, diperoleh *validation accuracy* sebesar 89,52% pada ukuran 64×64 piksel, 98,10% pada ukuran 128×128 piksel, dan 96,19% pada ukuran 224×224 piksel.

Model terbaik diperoleh pada skenario pembagian data 80%:20% dengan ukuran input 128×128 piksel yang mampu mengklasifikasikan data uji dengan baik yang ditunjukkan oleh nilai pada kelompok 1 sebesar 31 data, kelompok 2 sebesar 26 data, dan kelompok 3 sebesar 35 data, sehingga total klasifikasi benar yang diperoleh sebesar 92 data dari 105 data uji. Dengan nilai *validation accuracy* tertinggi sebesar 98,10%, serta

rata-rata nilai *precision* 87,74%, *recall* 87,62%, dan *F1-score* 87,32%.

SARAN

Berdasarkan penelitian yang telah dilakukan, terdapat saran yang dapat diberikan untuk penelitian selanjutnya adalah menambahkan variasi merek beras citra yang lebih banyak agar model dapat mempelajari karakteristik setiap kelompok secara lebih representatif serta menambahkan variasi *hyperparameter* seperti *learning rate* dapat diteliti lebih untuk memperoleh konfigurasi model yang lebih optimal.

DAFTAR PUSTAKA

- Chandra, V., Jaman, J. H., & Garino. (2022). Identifikasi Varietas Jagung Mutiara Berdasarkan Data Citra Digital Menggunakan Algoritma K-Nearest Neighbor. *Jurnal Nuansa Informatika*, 16(2). <https://doi.org/10.25134/nuansa.v16i2.5491>
- Detikcom. (2025). Dugaan Beras Oplosan: Diusut polisi, Dipelototi Senayan. Retrieved from detikcom website: <https://news.detik.com/berita/d-8013475/dugaan-beras-oplosandiusut-polisi-dipelototi-senayan>
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70 / 30 or 80 / 20 Relation Between Training and Testing Sets : A Pedagogical Explanation. In *Pooling Methods in Deep Neural Networks, a Review*.
- Jauhari, A. F. (2022). Klasifikasi Jenis Beras Menggunakan Metode Convolutional Neural Network Pada Arsitektur Mobilenet. Universitas Islam Negeri Maulana Malik Ibrahim Malang.
- Kementerian Pusat Data dan Sistem Informasi Pertanian Sekretariat Pertanian. (2025). *Buletin Konsumsi Pangan Volume 16 No 1 Tahun 2025*.
- Latif, G., Alghazo, J., Khan, M. A., Brahim, G. Ben, Fawagreh, K., & Mohammad, N. (2024). Deep Convolutional Neural Network (CNN) Model Optimization Techniques — Review For Medical Imaging. *AIMS Mathematics*, 9(8), 20539–20571. <https://doi.org/10.3934/math.2024998>
- Marnelius, C. D., Usman, K., Kumalasari, N., & Pratiwi, C. (2023). Klasifikasi Jenis Beras Berbasis Citra Dengan Menggunakan Deep Learning. *E-Proceeding of Engineering*, 10(5), 4211–4216.
- Mulyanto, A., Susanti, E., Rosi, F., & Borman, R. I. (2021). Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR). *JEPIN*, 7(1), 52–57.
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, 4(1), 78. <https://doi.org/10.24114/cess.v4i1.11458>

- Phukon, N., Singh, K. R., Singh, T. S., Datta, S., Deb, S., Singh, U. R., & Thingbaijam, G. (2024). *Quality Assessment of Rice using Convolution Neural Networks and other Machine Learning Techniques- A Comparative Study*. 12(2).
- Purwono, Ma'arif, A., Rahmaniar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. ul. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748.
- Rabbani, D. (2023). *Klasifikasi Beras Oplosan Berbasis Data Spektroskopi Menggunakan Deep Learning*. Universitas Pembangunan Nasional Veteran Jakarta.
- Saptadi, N. T. S., Kristiawan, H., Nugroho, A. Y., Suwarmiyati, N. R., Khairunnas, B. W. I. I., Saputra, M. P. Y., ... Aliyah. (2025). *Deep Learning Teori, Algoritma, dan Aplikasi*. Banten: PT Sada Kurnia Pustaka.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A Survey on Image Data Augmentation for Deep Learning. In *Journal of Big Data*. Springer International Publishing. <https://doi.org/10.1186/s40537-019-0197-0>
- Wulandari, I., Yasin, H., & Widiharih, T. (2020). Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (CNN). *Gaussian*, 9(3), 273–282.
- Yulnita, R., & Yewiwati. (2019). Analisis Produksi, Impor Dan Konsumsi Komoditi Beras Di Indonesia. *Jurnal Kajian Ekonomi Dan Pembangunan*, 1(2), 623–634.
- Zhang, A., Lipton, Z. C., Li, M., Alexander, J., & Smola. (2023). *Dive into Deep Learning*. Cambridge University Press.