

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI CITRA TIGA JENIS BERAS

Febie Elfaladonna¹, Meivi Kusnandar², Fitrianto Puja K³, Andre Mariza P⁴

^{1,2,3,4} D4 Manajemen Informatika, Politeknik Negeri Sriwijaya, Palembang

email: ¹febie_elfaladonna_mi@polsri.ac.id, ²meivi_kusnandar_mi@polsri.ac.id,

³fitrianto_puja_mi@polsri.ac.id, ⁴andre_mariza_mi@polsri.ac.id,

Abstract: *This study aims to develop an image classification model based on Convolutional Neural Network (CNN) to identify five rice varieties: Basmati, Ipsala, Arborio, Jasmine, and Karacadag. The dataset used consists of 75,000 images, with 15,000 images per class. Training was carried out using Python and TensorFlow, employing image augmentation and validation methods. The dataset was split into training, validation, and testing sets in a 70:15:15 ratio. The training results show a validation accuracy of 97.47% and a test accuracy of 97.78%, with a test loss of 0.0688. These results indicate that CNN is highly effective for rice image classification, offering high accuracy and good generalization. The conclusion of this study is that the CNN model can be applied as an assistive system in automated rice processing or sorting.*

Keywords: *image classification; CNN; rice; deep learning; TensorFlow.*

Abstrak: Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra berbasis Convolutional Neural Network (CNN) guna mengidentifikasi lima jenis beras: Basmati, Ipsala, Arborio, Jasmine, dan Karacadag. Dataset yang digunakan terdiri dari 75.000 gambar, masing-masing kelas berjumlah 15.000 gambar. Proses pelatihan dilakukan menggunakan Python dan TensorFlow dengan teknik augmentasi citra dan metode validasi. Dataset dibagi menjadi data pelatihan, validasi, dan pengujian dengan proporsi 70:15:15. Hasil pelatihan menunjukkan akurasi validasi mencapai 97,47% dan akurasi pengujian sebesar 97,78%, dengan nilai loss sebesar 0,0688. Temuan ini menunjukkan bahwa CNN sangat efektif dalam klasifikasi citra beras dengan akurasi tinggi dan generalisasi yang baik. Simpulan dari penelitian ini adalah model CNN dapat digunakan sebagai sistem bantu dalam proses pengolahan atau penyortiran beras secara otomatis.

Kata kunci: klasifikasi citra; CNN; beras; deep learning; TensorFlow.

PENDAHULUAN

Beras adalah makanan utama bagi masyarakat Indonesia serta banyak negara lain di dunia. Di Indonesia sendiri, terdapat beberapa jenis beras, seperti beras putih (*Oryza sativa* L.), beras merah (*Oryza nivara*), dan beras hitam (*Oryza sativa* L.). Setiap varietas padi memiliki karakteristik fisikokimia yang unik, bahkan varietas yang sama dapat menunjukkan perbedaan sifat jika berasal dari daerah yang berbeda (Hernawan & Meylani, 2016). Varietas seperti Basmati, Ipsala, Arborio, Jasmine, dan Karacadag

sering kali sulit dikenali hanya dengan pengamatan langsung, apalagi dalam jumlah besar. Metode klasifikasi manual yang dilakukan oleh manusia sangat bergantung pada keahlian individu, bersifat tidak konsisten, dan membutuhkan waktu yang lama. Oleh karena itu, diperlukan pendekatan otomatis yang mampu mengidentifikasi jenis beras secara cepat dan akurat.

Dalam konteks pengolahan citra digital, pendekatan deep learning seperti Convolutional Neural Network (CNN) telah terbukti efektif dalam mengenali objek dan pola visual yang kompleks.

CNN memiliki keunggulan dalam mengekstraksi fitur penting dari gambar secara otomatis, tanpa memerlukan proses ekstraksi manual, sehingga sangat cocok untuk tugas klasifikasi berbasis gambar. Bahasa pemrograman Python dipilih dalam pengembangan model CNN karena mendukung berbagai pustaka pemrosesan citra dan machine learning seperti TensorFlow, Keras, dan OpenCV.

Penelitian sebelumnya yang dilakukan oleh (Dandi Darajat, Arum Sari, & Wihandika, 2021) menunjukkan bahwa CNN memberikan performa yang baik dalam tugas klasifikasi gambar makanan. Salah satu penelitian mengembangkan sistem klasifikasi citra untuk makanan khas Indonesia menggunakan CNN, yang dipadukan dengan beberapa metode dan algoritma tambahan. Eksperimen dilakukan sebanyak delapan kali pada 27 model berbeda, dan diperoleh model terbaik dengan akurasi uji sebesar 0,6 dan akurasi evaluasi sebesar 0,91. Temuan ini menunjukkan bahwa CNN memiliki kemampuan generalisasi yang tinggi terhadap data citra makanan yang kompleks secara visual, sehingga berpotensi besar untuk diterapkan dalam klasifikasi jenis beras.

Penelitian ini bertujuan untuk membangun model CNN dengan menggunakan Python guna mengklasifikasikan lima jenis beras berdasarkan citra visual. Dataset yang digunakan mencakup 75.000 gambar, dengan masing-masing kelas berisi 15.000 gambar. Model ini diharapkan dapat mengenali karakteristik visual dari tiap varietas dan mencapai tingkat akurasi klasifikasi yang tinggi. Hasil dari penelitian ini diharapkan dapat dimanfaatkan dalam sistem otomasi industri pangan, khususnya untuk proses penyortiran dan pengendalian mutu beras.

METODE

Penelitian ini bertujuan mengklasifikasikan lima jenis beras—

Basmati, Ipsala, Arborio, Jasmine, dan Karacadag—menggunakan pendekatan deep learning berbasis Convolutional Neural Network (CNN). Seluruh proses implementasi dilakukan menggunakan bahasa Python dengan bantuan pustaka TensorFlow, Keras, Matplotlib, dan Scikit-learn.

Instalasi dan Import Library

Library yang digunakan diinstal terlebih dahulu menggunakan pip:

```
pip install tensorflow matplotlib scikit-learn
pip install tensorflowjs
```

Kemudian dilakukan proses import pustaka:

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout
from tensorflow.keras.preprocessing.image import ImageDataGenerator
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
import os
from tensorflow.keras.callbacks import EarlyStopping
import shutil
import random
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout, Input
import numpy as np
from tensorflow.keras.preprocessing import image
from google.colab import files
import json
import subprocess
```

Gambar 1 Import Library

Unduh dan Pemisahan Dataset

Dataset beras diunduh dari Kaggle menggunakan:

```
!kaggle datasets download -d muratkokludataset/rice-image-dataset
```

Gambar 2. Unduh Dataset

Dataset terdiri dari 75.000 citra yang tersebar merata ke dalam lima kelas. Dataset kemudian dipisahkan menjadi data latih (70%), validasi (15%), dan pengujian (15%) secara acak. Struktur direktori dibuat menggunakan `os.makedirs()` dan data disalin menggunakan `shutil.copyfile()`.

Preprocessing dan Augmentasi Data

Citra diubah ukurannya menjadi 64x64 piksel dan dinormalisasi ke skala [0,1]. Untuk memperkaya variasi data, digunakan teknik augmentasi seperti rotasi acak, pergeseran posisi, zoom, dan flip horizontal:

```
train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
    horizontal_flip=True)
```

Generator data validasi dan pengujian hanya menggunakan `rescale`.

Tabel 1 menunjukkan pembagian dataset per kelas:

Tabel 1 Sebaran Dataset Per Kelas

Jenis Beras	Latih	Validasi	Uji
Basmati	10.500	2.250	2.250
Ipsala	10.500	2.250	2.250
Arborio	10.500	2.250	2.250
Jasmine	10.500	2.250	2.250
Karacadag	10.500	2.250	2.250

Arsitektur Model CNN

Model CNN dibangun menggunakan `Sequential()` dengan arsitektur sebagai berikut:

1. Input Layer: 64x64x3 piksel.
2. 3 Blok Konvolusi: Kernel 3x3 dengan filter 32, 64, dan 128.
3. MaxPooling: Ukuran 2x2 pada tiap blok.
4. Flatten + Dense Layer: 128 neuron, diikuti Dropout 0.5.
5. Output Layer: Softmax dengan 5 kelas.

Model diformulasikan secara umum sebagai berikut:

$$Z = \text{softmax}(W2 \cdot \text{ReLU}(W1 \cdot X + b1) + b2) \quad (1)$$

Dengan:

X : Input citra

W1, W2 : Matriks bobot

b1, b2 : Bias

ReLU : Fungsi aktivasi non-linear

Softmax: Aktivasi output untuk multi-kelas

Kompilasi dan Pelatihan

Model dikompilasi menggunakan *optimizer Adam*, *loss function categorical_crossentropy*, dan metrik akurasi. Fungsi *EarlyStopping* digunakan untuk menghentikan pelatihan dini jika validasi tidak membaik selama 3 epoch.

```
model.compile(optimizer='adam', loss='categorical_crossentropy',
    metrics=['accuracy'])
early_stopping = EarlyStopping(monitor='val_loss',
    patience=3,
    restore_best_weights=True)
```

Model dilatih selama maksimum 20 epoch dengan `batch_size = 32`:

```
history = model.fit(
    train_generator,
    steps_per_epoch=max(1,
        train_generator.samples //
        train_generator.batch_size),
    epochs=20,
    validation_data=validation_generator,
    validation_steps=max(1,
        validation_generator.samples //
        validation_generator.batch_size),
    callbacks=[early_stopping])
```

Evaluasi dan Visualisasi

Setelah pelatihan, kinerja model divisualisasikan dalam grafik akurasi dan loss sebagai berikut:

```
plt.figure(figsize=(12, 5))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'],
    label='Training Accuracy')
plt.plot(history.history['val_accuracy'],
    label='Validation Accuracy')
plt.title('Akurasi Training dan Validasi')
plt.xlabel('Epoch')
```

```
plt.ylabel('Accuracy')
plt.legend()

plt.subplot(1, 2, 2)
plt.plot(history.history['loss'],
label='Training Loss')
plt.plot(history.history['val_loss'],
label='Validation Loss')
plt.title('Loss Training dan Validasi')
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.legend()
plt.tight_layout()
plt.show()
```

Sumber Pustaka/Rujukan

Deep learning adalah algoritma pemodelan yang disusun secara mendalam dan berlapis, dengan menggunakan serangkaian fungsi transformasi non-linear. Teknik ini memanfaatkan berbagai tahapan pemrosesan informasi non-linear untuk melakukan ekstraksi fitur, mengenali pola, serta menjalankan tugas klasifikasi (Lambacing & Ferdiansyah, 2020).

Salah satu jenis deep learning adalah klasifikasi citra merupakan yang bertujuan untuk mengelompokkan gambar ke dalam kategori tertentu berdasarkan fitur-fitur yang terkandung di dalamnya. Gambar-gambar tersebut dapat diklasifikasikan ke dalam kelas yang telah ditetapkan sebelumnya, seperti hewan, tumbuhan, atau berbagai jenis objek lainnya (Anhar & Adi Putra, 2023).

Klasifikasi gambar juga termasuk pada proses untuk mengidentifikasi dan menentukan kategori informasi dari citra raster multiband. Hasil dari proses klasifikasi ini berupa raster yang dapat dimanfaatkan dalam pembuatan peta tematik.

Berdasarkan tingkat keterlibatan antara analis dan sistem komputer dalam proses klasifikasinya, klasifikasi citra dibedakan menjadi dua jenis, yaitu klasifikasi terawasi (supervised) dan tak terawasi (unsupervised) (Diantoro & Adriasyah, 2019).


Salah satu pendekatan yang umum digunakan dalam klasifikasi citra adalah

Convolutional Neural Network (CNN) (Arifin & Nurfaizah, 2024).

Convolutional Neural Network (CNN) merupakan salah satu metode yang sangat populer dalam bidang deep learning. CNN memiliki kemampuan untuk mengekstraksi fitur dari data input berupa citra, kemudian mereduksi dimensi citra tersebut tanpa mengubah karakteristik penting di dalamnya (Omori & Shima, 2020). Arsitektur CNN terdiri atas neuron-neuron yang masing-masing memiliki bobot dan bias. Setiap neuron menerima input dan melakukan proses perhitungan melalui operasi perkalian titik (dot product) untuk menghasilkan output (Azmi, Defit, & Sumijan, 2023).

Convolutional Neural Network (CNN) dirancang khusus untuk menangani data yang memiliki struktur dan keterkaitan spasial yang kuat dalam area lokal. Gambar dua dimensi (2D) adalah contoh paling umum dari jenis data ini. Dalam sebuah gambar, piksel-piksel yang berdekatan sering kali memiliki warna serupa, menciptakan ketergantungan spasial.


Selain itu, gambar juga memiliki saluran warna yang berbeda (seperti RGB), yang membentuk representasi tiga dimensi. Gambar 3 menyajikan ilustrasi dari berbagai lapisan yang menyusun arsitektur CNN (Gunawan & Al-Rivan, 2023).




Gambar 3. Arsitektur CNN

Convolutional layer merupakan bagian dari arsitektur CNN yang berfungsi melakukan operasi konvolusi, yaitu menggabungkan filter linier dengan area lokal pada gambar. Lapisan ini merupakan lapisan pertama yang menerima input citra dalam arsitektur CNN.

Bentuk convolutional layer berupa filter yang memiliki panjang dan lebar dalam satuan piksel, serta kedalaman (depth) yang disesuaikan dengan jumlah channel pada data citra yang dimasukkan. Filter ini akan bergerak (melakukan sliding) ke seluruh bagian citra, dan pada setiap pergeseran, dilakukan operasi perkalian titik (dot product) antara nilai piksel pada input dan nilai pada filter. Hasil dari operasi ini akan membentuk output yang dikenal sebagai activation map atau feature map (Shukla & Fricklas, 2018).



Gambar 4. Proses Convolutional Layer



Gambar 5 Perhitungan Convolutional Layer


Pooling layer merupakan lapisan yang menerima output dari convolutional layer dan berfungsi untuk mereduksi ukuran data citra. Proses ini dilakukan dengan menggunakan filter berukuran tertentu yang digeser (stride) ke seluruh area feature map. Dalam sebagian besar arsitektur CNN, metode pooling yang paling umum digunakan adalah max pooling. Teknik ini membagi hasil keluaran dari convolution layer ke dalam beberapa grid, kemudian pada setiap pergeseran filter, nilai maksimum dari setiap grid akan dipilih. Ukuran langkah (stride) akan menentukan seberapa banyak data yang dipertahankan, sehingga hasil akhirnya adalah representasi gambar dengan ukuran yang lebih kecil dari aslinya. Reduksi dimensi ini bertujuan untuk menyederhanakan data dan mengurangi jumlah parameter yang harus diproses pada tahapan berikutnya (Nurfita & Gunawan, 2023).

Untuk membantu pengenalan gambar di dalam deep learning dapat

memanfaatkan berbagai library, seperti TensorFlow, Caffe, Theano, Torch, dan Keras. TensorFlow merupakan library open source yang sangat fleksibel, karena fungsionalitasnya melampaui sekadar sebuah framework pengembangan—ia juga menyediakan infrastruktur lengkap untuk membangun dan menjalankan model machine learning secara efisien (Wiranda, Purba, & Sukmawati, 2020).

HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengklasifikasikan lima jenis beras yaitu Basmati, Ipsala, Arborio, Jasmine, dan Karacadag menggunakan algoritma Convolutional Neural Network (CNN). Setelah proses training dilakukan selama beberapa epoch, diperoleh hasil performa model yang menunjukkan bahwa CNN mampu mengenali dan membedakan masing-masing jenis beras dengan akurasi yang tinggi. Gambar berikut merupakan hasil evaluasi akurasi dan loss training dan validasi.



Gambar 6 Akurasi dan Loss Validasi dan Training

Proses pelatihan menunjukkan hasil sebagai berikut:

1. Akurasi tertinggi pada data pelatihan (training) mencapai 96,18%
2. Akurasi validasi terbaik tercatat sebesar 97,47%
3. Akurasi pada data pengujian (testing) mencapai 97,78%
4. Nilai *loss* pada data pengujian adalah 0,0688.

Berdasarkan hasil tersebut, dapat disimpulkan bahwa model CNN mampu melakukan klasifikasi dengan sangat baik dan tidak mengalami overfitting secara signifikan, karena perbedaan antara akurasi pelatihan dan validasi tergolong

kecil. Model juga menunjukkan generalisasi yang kuat terhadap data yang belum pernah dilihat sebelumnya (test set), yang terlihat dari akurasi pengujian yang tinggi.

Model menggunakan arsitektur CNN berlapis, dengan beberapa layer konvolusi dan max pooling, serta diakhiri oleh fully connected layer dan softmax output layer. Jumlah kelas output adalah 5. Selama proses pelatihan, digunakan beberapa strategi untuk meningkatkan akurasi dan mencegah overfitting, seperti: Augmentasi data, melalui rotasi, flipping, dan shifting citra.

Early Stopping, yang secara otomatis menghentikan pelatihan jika performa pada data validasi tidak mengalami peningkatan. Normalisasi data, dengan melakukan rescaling piksel ke skala 0–1. Secara visual, kurva akurasi dan loss menunjukkan bahwa model mengalami peningkatan performa yang konsisten selama beberapa epoch pertama, sebelum akhirnya stabil. Hal ini mendukung bahwa arsitektur CNN yang digunakan cukup optimal untuk permasalahan klasifikasi beras.

Dengan akurasi pengujian mencapai 97,78%, model CNN ini terbukti mampu mengklasifikasikan citra beras secara akurat. Hasil ini juga mengungguli beberapa penelitian terdahulu yang menerapkan CNN untuk klasifikasi makanan atau hasil pertanian lainnya. Oleh karena itu, pendekatan ini dapat dijadikan sebagai alternatif yang efektif untuk diterapkan dalam sistem klasifikasi otomatis beras dalam bidang pertanian cerdas (smart agriculture) atau sistem kontrol mutu produk pangan.



Gambar 7 Hasil Prediksi Jenis Beras

SIMPULAN

Penelitian ini berhasil merancang dan mengevaluasi model Convolutional Neural Network (CNN) berbasis Python untuk mengklasifikasikan lima varietas beras: Basmati, Ipsala, Arborio, Jasmine, dan Karacadag dengan memanfaatkan dataset berjumlah 75.000 gambar, masing-masing kelas terdiri dari 15.000 citra. Berdasarkan proses pelatihan dan pengujian model, diperoleh beberapa kesimpulan utama sebagai berikut:

Model CNN mampu mencapai tingkat akurasi pengujian sebesar 97,78% serta akurasi validasi rata-rata di atas 95%, yang mencerminkan kinerja klasifikasi yang tinggi dan konsisten. Nilai loss yang rendah pada tahap pengujian (0,0688) menunjukkan kemampuan generalisasi model yang baik tanpa indikasi overfitting yang signifikan.

Penerapan teknik seperti augmentasi data, early stopping, dan normalisasi piksel terbukti berperan penting dalam meningkatkan performa dan kestabilan model selama pelatihan. Akurasi pengujian yang tinggi ini menunjukkan adanya peningkatan signifikan dibandingkan studi-studi sebelumnya dalam klasifikasi citra makanan, yang memperkuat potensi CNN sebagai metode efektif untuk klasifikasi citra beras.

Secara keseluruhan, model CNN yang dikembangkan dalam studi ini terbukti handal dan akurat, serta berpotensi besar untuk diimplementasikan dalam sistem otomatisasi industri beras, seperti pada proses penyortiran otomatis maupun pengawasan kualitas. Untuk pengembangan lebih lanjut, disarankan untuk menambahkan metrik evaluasi lain (misalnya confusion matrix, precision, recall, dan F1-score), mempertimbangkan penggunaan arsitektur yang lebih kompleks seperti ResNet atau MobileNet, serta mengintegrasikan model ke dalam aplikasi nyata seperti perangkat IoT atau sistem berbasis cloud guna pengujian di lingkungan industri secara langsung.

DAFTAR PUSTAKA

- Anhar, & Adi Putra, R. (2023). Perancangan Dan Implementasi Self-Checkout System Pada Toko Ritel Menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 2459-9638.
- Arifin, S., & Nurfaizah. (2024). Klasifikasi Motif Batik Menggunakan Metode Convolutional Neural Network (CNN) Dengan Multi Class Clasification. *Jurnal Ilmiah IT CIDA : Diseminasi Teknologi Informasi*, 10(1), 30-38.
- Azmi, K., Defit, S., & Sumijan. (2023). Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat. *Jurnal Unitek*, 16(1), 28-40.
- Dandi Darajat, M., Arum Sari, Y., & Wihandika, R. C. (2021). Convolutional Neural Network Untuk Klasifikasi Citra Makanan Khas Indonesia. *JTIK*, 5(11), 4764-4769.
- Diantoro, K., & Adriasyah, B. (2019). Sistem Identifikasi Jenis Burung Dengan Image Classification Menggunakan Opencv. *TEKINFO*, 20(1), 96-105.
- Gunawan, B., & Al-Rivan, M. (2023). Klasifikasi Jenis Beras Putih Menggunakan Cnn Residual Network Optimizer Sgd. *2nd MDP Student Conference 2023* (Pp. 128-132). Palembang: Universitas Multi Data Palembang .
- Hernawan, E., & Meylani, V. (2016). Analisis Karakteristik Fisikokimia Beras Putih, Beras Merah, Dan Beras Hitam (Oryza Sativa L., Oryza Nivara Dan Oryza Sativa L. Indica). *Jurnal Kesehatan Bakti Tunas Husada: Jurnal Ilmu-Ilmu Keperawatan, Analis Kesehatan Dan Farmasi*, 15(1), 79-85.
- Lambacing, M., & Ferdiansyah. (2020). Rancang Bangun New Normal COVID-19 Masker Detector Dengan Notifikasi Telegram Berbais Internet Of Things. *Jurnal Dinamik*, 25(1), 77-84.
- Nurfita, R., & Gunawan , A. (2023). Implementasi Deep Learning Berbasis Tensorflow Untuk Pengenalan Sidik Jari. *Emitor: Jurnal Teknik Elektro*, 18(1), 22-27.
- Omori, Y., & Shima, Y. (2020). Image Augmentation For Eye Contact Detection Based. *Journal Of Computers*, 15(3), 85–97.
- Shukla, N., & Fricklas, K. (2018). *Machine Learning With Tensorflow*. Manning Publications.
- Wiranda, N., Purba, H., & Sukmawati, R. (2020). Survei Penggunaan Tensorflow Pada Machine Learning Untuk Identifikasi Ikan Kawasan Lahan Basah. *Indonesian Journal Of Electronics And Instrumentation Systems (IJEIS)*, 10(2), 179-188