

# Klasifikasi Tradisional Berbasis Deep Learning Studi Kasus Gado-Gado Dan Makanan Lainnya

## *Traditional Classification Based On Deep Learning Case Studies Of Hodgepodge And Other Foods*

**Azsa Azzahra Zainuddin<sup>1</sup>; Firman Aziz<sup>2\*</sup>; Syahrul Usman<sup>3</sup>; Muhammad Nur Arafah<sup>4</sup>**

<sup>1,2,3</sup>Universitas Pancasakti, Makassar, 90121, Indonesia

<sup>4</sup>Irmex Digital Akademika, Makassar, 90551, Indonesia

<sup>1</sup>[azsaazzahrazainuddin@gmail.com](mailto:azsaazzahrazainuddin@gmail.com); <sup>2</sup>[firmazaniz@unpacti.ac.id](mailto:firmazaniz@unpacti.ac.id); <sup>3</sup>[syahrul.usman@unpacti.ac.id](mailto:syahrul.usman@unpacti.ac.id); <sup>4</sup>[mnurarafah18@gmail.com](mailto:mnurarafah18@gmail.com)

\* Corresponding author

### Abstrak

Penelitian ini bertujuan untuk melakukan klasifikasi citra makanan tradisional Indonesia dengan tingkat kemiripan visual tinggi menggunakan metode Deep Learning berbasis arsitektur Residual Network (ResNet). Dataset terdiri atas tujuh kelas makanan, yaitu gado-gado, gudeg, nasi padang, rawon, rendang padang, sate, dan soto ayam. Tahapan preprocessing dilakukan melalui normalisasi ukuran citra, konversi format, serta data augmentation berupa rotasi, flipping, dan penyesuaian pencahayaan guna meningkatkan keragaman data serta mengurangi risiko overfitting. Eksperimen dilakukan menggunakan dua varian arsitektur ResNet, yaitu ResNet-18 dan ResNet-34, dengan ukuran citra 224×224 piksel dan batch size 32. Hasil pelatihan menunjukkan bahwa ResNet-18 mencapai akurasi pelatihan sebesar 97,59% dan validasi 83,00% pada epoch ke-30, sedangkan ResNet-34 memperoleh akurasi pelatihan 95,08% dan validasi 89,29% pada epoch ke-50. Berdasarkan hasil evaluasi melalui confusion matrix, model mampu mengenali sebagian besar kelas dengan baik, meskipun masih terdapat kesalahan pada kelas yang memiliki kemiripan warna dan tekstur seperti rendang padang dan rawon. Model dengan lapisan lebih dalam terbukti memiliki kemampuan generalisasi yang lebih baik terhadap variasi citra kompleks. Penelitian ini membuktikan bahwa arsitektur ResNet efektif digunakan dalam klasifikasi citra makanan tradisional Indonesia serta berpotensi diterapkan pada sistem pengenalan otomatis berbasis kecerdasan buatan (AI) di bidang kuliner, pariwisata, dan edukasi digital. Pengembangan lebih lanjut dapat mencakup penerapan transfer learning lanjutan, integrasi model ke dalam aplikasi mobile atau web, serta pemanfaatan metode Explainable AI (XAI) seperti Grad-CAM atau SHAP untuk meningkatkan interpretabilitas hasil klasifikasi.

**Kata Kunci:** Deep Learning; ResNet; Klasifikasi Citra; Makanan Tradisional; CNN.

### Abstract

This study aims to classify the image of traditional Indonesian food with a high level of visual similarity using the Deep Learning method based on the Residual Network (ResNet) architecture. The dataset consists of seven food classes, namely gado-gado, gudeg, nasi padang, rawon, rendang padang, satay, and chicken soup. The preprocessing stage is carried out through image size normalization, format conversion, and data augmentation in the form of rotation, flipping, and lighting adjustment to increase data diversity and reduce the risk of overfitting. The experiment was conducted using two variants of the ResNet architecture, namely ResNet-18 and ResNet-34, with an image size of 224×224 pixels and a batch size of 32. The training results showed that ResNet-18 achieved a training accuracy of 97.59% and a validation of 83.00% in the 30th epoch, while ResNet-34 obtained a training accuracy of 95.08% and a validation of 89.29% in the 50th epoch. Based on the results of the evaluation through the confusion matrix, the model was able to recognize most classes well, although there were still errors in classes that had similar colors and textures such as rendang padang and rawon. Models with deeper layers have been shown to have better generalization capabilities to complex image variations. This research proves that the ResNet architecture is effectively used in the classification of traditional Indonesian food images and has the potential to be applied to artificial intelligence (AI)-based automatic recognition systems in the fields of culinary, tourism, and digital education. Further development may include the application of advanced transfer learning, the integration of models into mobile or web applications, as well as the use of Explainable AI (XAI) methods such as Grad-CAM or SHAP to improve the interpretability of classification results.

**Keywords:** Deep Learning; ResNet; Klasifikasi Citra; Makanan Tradisional; CNN

### Pendahuluan

Perkembangan teknologi kecerdasan buatan (AI) telah memberikan dampak signifikan dalam berbagai bidang, salah satunya pada pengenalan citra (image recognition). Salah satu pendekatan yang paling banyak digunakan untuk melakukan klasifikasi citra adalah Deep Learning, khususnya dengan pemanfaatan Convolutional Neural Network (CNN). CNN mampu mengekstraksi fitur-fitur penting dari citra secara otomatis tanpa memerlukan proses ekstraksi manual yang kompleks, sehingga menjadi landasan utama dalam berbagai penelitian berbasis computer vision. [1], [2], [3]. Dalam konteks kuliner Indonesia, terdapat berbagai jenis makanan tradisional yang memiliki bentuk, warna, dan tekstur yang beragam. Keberagaman tersebut menimbulkan tantangan tersendiri dalam proses klasifikasi citra makanan

karena adanya kemiripan visual antarjenis makanan tradisional, yang berpotensi menurunkan akurasi dalam sistem identifikasi otomatis [4], [5], [6]. Oleh karena itu, diperlukan model deep learning yang mampu mengenali pola visual dengan akurasi tinggi dan generalisasi yang baik terhadap variasi citra yang kompleks.

Salah satu arsitektur CNN yang terbukti memiliki performa unggul adalah Residual Network (ResNet) yang diperkenalkan oleh He, Kaiming et.al [7]. ResNet menggunakan konsep residual learning dan skip connection untuk mengatasi permasalahan vanishing gradient pada jaringan dalam (deep network), sehingga memungkinkan pelatihan model dengan lapisan lebih banyak tanpa kehilangan akurasi [8], [9]. Dalam penelitian ini, digunakan varian ResNet untuk melakukan klasifikasi citra makanan tradisional Indonesia, dengan ResNet-18 dan ResNet-34 sebagai model pembandingan dalam tahap pengujian untuk menilai performa dan efisiensi arsitektur. Penggunaan varian ResNet diharapkan dapat meningkatkan akurasi klasifikasi serta mempercepat proses pelatihan model dengan memanfaatkan kemampuan residual block yang efisien dalam ekstraksi fitur [10], [11]. Dengan adanya penelitian ini, diharapkan dapat memberikan kontribusi terhadap pengembangan sistem identifikasi makanan tradisional berbasis deep learning, yang tidak hanya bermanfaat dalam pelestarian budaya kuliner Indonesia, tetapi juga berpotensi diterapkan dalam bidang pangan, pariwisata, dan edukasi digital [12], [13], [14].

## Metode

### A. Jenis Penelitian

Penelitian ini merupakan penelitian kuantitatif eksperimental dengan pendekatan komputasional. Pendekatan ini digunakan untuk menguji efektivitas metode dengan arsitektur Residual Network (ResNet) dalam melakukan klasifikasi citra makanan tradisional Indonesia yang memiliki tingkat kemiripan visual tinggi, seperti gado gado, gudeg, nasi padang, rawon, rendang padang, sate, dan soto ayam. Melalui pendekatan ini, dilakukan analisis performa dua varian arsitektur ResNet, yaitu ResNet-18 dan ResNet-34, guna memperoleh model yang optimal dalam mengenali perbedaan visual antarjenis makanan tradisional.

### B. Instrumen Penelitian

Instrumen penelitian merupakan perangkat yang digunakan untuk mendukung proses eksperimen dan analisis dalam penelitian klasifikasi citra makanan tradisional berbasis *Deep Learning*. Instrumen ini mencakup perangkat keras (*hardware*), perangkat lunak (*software*), serta pustaka (*library*) pendukung yang digunakan dalam pelatihan dan pengujian model *Transfer Learning* dengan arsitektur *ResNet*. Adapun rincian instrumen penelitian ditunjukkan pada tabel berikut:

**Tabel 1.** Arsitektur dan Alat Penelitian

| <i>Komponen</i>           | <i>Spesifikasi</i>                         |
|---------------------------|--------------------------------------------|
| <b>CPU</b>                | Intel Core i5 Gen 12th                     |
| <b>GPU</b>                | NVIDIA GeForce MX 550                      |
| <b>RAM</b>                | ≥ 16 GB                                    |
| <b>Bahasa Pemrograman</b> | Python 3.10.5                              |
| <b>Library</b>            | TensorFlow/Keras, Scikit-learn, Matplotlib |
| <b>Platform</b>           | Jupyter Notebook / Google Colab            |

Penggunaan GPU *NVIDIA GeForce MX550* bertujuan untuk mempercepat proses komputasi pada saat pelatihan model, khususnya dalam proses propagasi balik (*backpropagation*) pada arsitektur *ResNet*. Sementara itu, *Google Colab* dan *Jupyter Notebook* dipilih karena mendukung integrasi langsung dengan pustaka *Deep Learning* seperti TensorFlow dan Keras, sehingga memudahkan dalam eksperimen, visualisasi, serta evaluasi performa model.


### C. Pengumpulan Data

Data penelitian berupa citra makanan tradisional Indonesia yang mencakup tujuh kelas utama: *gado-gado*, *gudeg*, *nasi padang*, *rawon*, *rendang padang*, *sate*, dan *soto ayam*. Sumber data diperoleh dari dokumentasi pribadi, situs kuliner daring, serta dataset terbuka seperti *Kaggle* dan *Google Images*. Teknik purposive sampling digunakan untuk memastikan bahwa setiap citra memiliki kualitas visual yang baik, objek yang jelas, serta relevansi terhadap kelas makanan yang ditentukan (Ciocca et al., 2017; Nugroho et al., 2021)

### D. Augmentasi Data

Setiap citra diubah ke format seragam dengan ukuran piksel yang sama (misalnya 224×224 piksel) dan dinormalisasi untuk memastikan kestabilan pelatihan model. Selain itu, dilakukan augmentasi data melalui teknik rotasi, flipping,

zooming, dan perubahan pencahayaan guna meningkatkan keragaman data serta mencegah overfitting. Proses ini membantu model mengenali citra dari berbagai sudut dan kondisi pencahayaan.



**Gambar 1.** Augmentasi Data

#### **E. Klasifikasi Menggunakan ResNet**

Dataset dibagi menjadi dua bagian: 80% untuk data latih dan 20% untuk data uji. Selama pelatihan, dilakukan pemantauan terhadap nilai *loss* dan *accuracy* untuk memastikan proses konvergensi model berjalan stabil. Pengujian dilakukan dengan data yang belum pernah dilibatkan dalam pelatihan agar dapat mengukur kemampuan generalisasi model. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score, serta visualisasi *confusion matrix* untuk menilai kesalahan klasifikasi pada setiap kelas.

#### **F. Evaluasi Model ResNet**

Arsitektur model yang digunakan dalam penelitian ini adalah Residual Network (ResNet), yaitu salah satu varian Convolutional Neural Network (CNN) yang dikembangkan oleh He et al. (2016). Arsitektur ini mampu mengatasi permasalahan degradation problem pada jaringan yang sangat dalam dengan memperkenalkan konsep shortcut connection atau residual learning.


Dalam penelitian ini digunakan dua varian arsitektur ResNet, yaitu ResNet-18 dan ResNet-36, yang berfungsi sebagai model pembandingan. Keduanya merupakan model yang telah dilatih sebelumnya (pretrained) menggunakan dataset ImageNet, sehingga bobot awal model sudah memiliki representasi fitur visual yang kuat. Lapisan akhir (fully connected layer) dimodifikasi agar sesuai dengan jumlah kelas citra makanan tradisional Indonesia, yaitu 7 kelas: gado-gado, gudeg, nasi padang, rawon, rendang padang, sate, dan soto ayam. Setiap citra masukan akan melalui beberapa tahapan utama dalam arsitektur ResNet:

**Tabel 2.** Tahap Feature Extraction Citra

| <i>Arsitektur Model CNN ResNet</i> | <i>Keterangan</i>                                                                 |
|------------------------------------|-----------------------------------------------------------------------------------|
| Convolutional Layer                | mengekstraksi fitur visual dasar seperti tepi, tekstur, dan pola warna.           |
| Residual Block                     | menerapkan koneksi identitas untuk mencegah hilangnya informasi selama pelatihan. |
| Batch Normalization dan ReLU       | menormalkan nilai aktivasi dan mempercepat konvergensi.                           |
| Global Average Pooling             | mereduksi dimensi fitur sebelum klasifikasi.                                      |
| Fully Connected Layer + Softmax    | menghasilkan probabilitas terhadap masing-masing kelas makanan tradisional.       |

#### **G. Tahapan Penelitian dan Rancangan Sistem**

Pada pembahasan ini menggambar alur flowchart tahapan penelitian dan rancangan sistem aplikasi untuk mengklasifikasi citra gambar makanan tradisional.



**Gambar 2.** Kerangka Konseptual dan Rancangan Aplikasi Menggunakan CNN ResNet

#### **H. Analisis Hasil dan Kesimpulan**

Tahap analisis hasil dilakukan untuk mengevaluasi kinerja model Deep Learning menggunakan varian arsitektur ResNet18 dan ResNet34 dalam mengklasifikasikan citra makanan tradisional Indonesia. Analisis ini mencakup pengukuran performa model melalui metrik evaluasi seperti akurasi, presisi, recall, dan F1-score yang diperoleh dari hasil pengujian data validasi.

#### **Hasil dan Diskusi**

##### **A. Preprocessing Data**

Tahapan preprocessing terhadap data citra dilakukan dengan melakukan pengumpulan data melalui internet dan foto manual, pelabelan citra, pengubahan ukuran pixel pada citra (resize), dan melakukan augmentasi pada citra dari keseluruhan citra training.

1. Pengumpulan Data : Pengumpulan data didapatkan dari Dataset Makanan Tradisional Indonesia yang bersumber dari Kaggle dan manual atau memfoto makanan tradisional yang dimana terdiri dari 7 jenis makanan tradisional
2. Pelabelan Data : Proses pemberian label pada data berfungsi untuk memberikan nama terhadap data untuk dapat dikenali. Peneliti membuat dua folder utama yaitu folder train dan folder test / validation. Folder train berfungsi untuk menaruh data untuk diproses pada proses pembelajaran, sedangkan folder test / validation berfungsi untuk memvalidasi data pada proses training. Pada setiap subfolder diberi nama kelas makanan tradisional disisi dengan data sesuai namanya
3. Augmentasi Data : Proses agumentasi terhadap data citra jenis makanan tradisional untuk proses training dilakukan untuk mencegah terjadinya overfitting (memiliki kinerja baik selama pelatihan, tetapi buruk pada data baru).


##### **B. Perancangan Model**

Dalam tahap perancangan model, proses pemodelan dilakukan secara sistematis untuk menghasilkan model klasifikasi citra makanan tradisional Indonesia yang akurat dan efisien. Penelitian ini menggunakan pendekatan *Deep Learning* berbasis arsitektur *Convolutional Neural Network* (CNN) menggunakan varian *ResNet*.

1. **Persiapan Data :** Data yang digunakan berupa citra makanan tradisional seperti gado-gado, gudeg, nasi padang, rawon, rendang padang, sate, dan soto ayam. Dataset ini dibagi menjadi dua bagian utama, yaitu: Citra training, yang digunakan untuk proses pelatihan model. Citra validasi, yang digunakan untuk mengevaluasi performa model selama pelatihan.
2. **Arsitektur Model :** Penelitian ini menggunakan dua varian arsitektur Residual Network (ResNet), yaitu ResNet18 dan ResNet34 sebagai model pembandingan. Kedua model ini memiliki perbedaan pada jumlah lapisan residual block, di mana ResNet18 terdiri dari 18 lapisan konvolusi, sedangkan ResNet34 memiliki 34 lapisan yang lebih dalam.

Model yang dibangun menggunakan pendekatan Sequential yang terdiri atas beberapa tahapan utama, yaitu augmentasi data, normalisasi, ekstraksi fitur melalui lapisan konvolusi dan pooling, serta klasifikasi akhir melalui lapisan fully connected. Model terdiri dari tiga buah blok konvolusi yang masing-masing diikuti oleh operasi max pooling, yang berfungsi untuk mengekstraksi dan mereduksi fitur dari gambar masukan:

1. **Layer Konvolusi 1 :** (Conv2D) dengan 16 filter ukuran  $3 \times 3$  dan aktivasi ReLU, bertugas mengenali fitur-fitur dasar seperti tepi dan tekstur.
2. **Layer Konvolusi 2 :** dengan 32 filter, mengenali pola visual yang lebih kompleks seperti bentuk objek.
3. **Layer Konvolusi 3 :** dengan 64 filter, mempelajari fitur mendalam dan spesifik dari masing-masing jenis makanan.
4. **Menggunakan 128 filter berukuran  $3 \times 3$  dengan fungsi aktivasi ReLU.** Lapisan ini berfungsi untuk menangkap fitur mendalam (deep feature representation) dari citra makanan, seperti variasi pola penyajian, kombinasi warna kompleks, dan karakteristik unik dari setiap makanan tradisional.



**Gambar 3.** Pemodelan CNN ResNet

### C. Evaluasi Hasil Probility Softmax

#### 1. Perhitungan probabilitas SoftMax

**Tabel 3.** Nilai Neuron dan Probabilitas


Prediksi Klasifikasi Makanan Tradisional

Gado -Gado kelas utama: 1

Tabel nilai neuron dan probabilitas softmax

| Neuron  | (logits) | Probabilitas |
|---------|----------|--------------|
| Kelas 1 | -0.223   | 0.316        |
| Kelas 2 | -1.632   | 0.077        |
| Kelas 3 | -0.455   | 0.251        |
| Kelas 4 | -1.209   | 0.118        |
| Kelas 5 | -2.581   | 0.030        |
| Kelas 6 | -3.619   | 0.011        |
| Kelas 7 | -0.689   | 0.198        |
| Kelas 7 | 3.074    | 0.774        |

**(a) Perhitungan Mendapatkan Nilai Probabilitas Kelas**



**(b) Grafik Visualisasi Probabilitas Kelas**

## 2. Loss Function

Loss function digunakan untuk mengukur kinerja model dengan menghitung seberapa besar perbedaan antara nilai prediksi dan nilai aktual. Semakin kecil nilai loss, semakin baik model dalam memprediksi kelas yang benar. Dalam kasus ini, hasil keluaran model (output layer) diperoleh melalui fungsi Softmax, yang mengubah skor keluaran menjadi probabilitas untuk setiap kelas. Nilai aktual (label sebenarnya) direpresentasikan dalam bentuk one-hot encoding, di mana kelas yang benar diberi nilai 1 dan kelas lainnya 0. Sebagai contoh, citra yang diinput merupakan gambar Soto, yang berada pada indeks ke-7. Maka representasi aktualnya adalah:


Sebagai contoh, citra yang diinput merupakan gambar Soto, yang berada pada indeks ke-7. Maka representasi aktualnya adalah: Aktual = [0., 0., 0., 0., 0., 0., 1]. Hasil prediksi model setelah melalui Softmax adalah Prediksi Softmax = [0.01345823, 0.01345614, 0.01345496, 0.01345551, 0.01354749, 0.01346881, 0.15346000, 0.17669986]. Dari hasil tersebut, kelas dengan probabilitas tertinggi adalah indeks ke-7 dengan nilai 0.1767, sehingga model memprediksi gambar tersebut sebagai Soto. Untuk menghitung seberapa tepat prediksi model, digunakan Cross-Entropy Loss, yang mengukur jarak antara distribusi probabilitas prediksi dan label aktual. Hasil perhitungan loss untuk satu citra ini adalah: **Cross-Entropy Loss = 1.73330269**. Nilai ini menunjukkan tingkat kesalahan model terhadap citra tersebut semakin kecil nilainya, semakin baik model mengenali kelas yang benar.

## D. Evaluasi Hasil Model


Tahap akhir pelatihan CNN adalah backpropagation, yang berfungsi memperbarui bobot agar nilai *loss* menurun. Penelitian ini menggunakan ResNet18 dan ResNet34 tanpa *transfer learning*, dengan algoritma optimasi Nadam. Selama pelatihan, *loss* menurun dan akurasi meningkat secara stabil, menunjukkan proses pembelajaran yang baik tanpa *overfitting*. Hasil evaluasi menunjukkan ResNet18 mencapai akurasi pelatihan 0.9846 dan validasi 0.8300, sedangkan ResNet34 memiliki kinerja validasi sedikit lebih tinggi karena arsitekturnya yang lebih dalam mampu mengekstraksi fitur lebih kompleks. Secara keseluruhan, kedua model mampu mengklasifikasikan citra makanan tradisional dengan akurasi tinggi meskipun dilatih *from scratch*, membuktikan efektivitas model ResNet dengan data dan parameter pelatihan yang tepat.

|            |                                                                                          |
|------------|------------------------------------------------------------------------------------------|
| Epoch 1/50 |                                                                                          |
| 43/43      | 226s 5s/step - accuracy: 0.6958 - loss: 0.8854 - val_accuracy: 0.8496 - val_loss: 0.5910 |
| Epoch 2/50 |                                                                                          |
| 43/43      | 236s 5s/step - accuracy: 0.7740 - loss: 0.6943 - val_accuracy: 0.8687 - val_loss: 0.4944 |
| Epoch 3/50 |                                                                                          |
| 43/43      | 223s 5s/step - accuracy: 0.8153 - loss: 0.5664 - val_accuracy: 0.8805 - val_loss: 0.4319 |
| Epoch 4/50 |                                                                                          |
| 43/43      | 217s 5s/step - accuracy: 0.8473 - loss: 0.4919 - val_accuracy: 0.8879 - val_loss: 0.3977 |
| Epoch 5/50 |                                                                                          |
| 43/43      | 217s 5s/step - accuracy: 0.8636 - loss: 0.4323 - val_accuracy: 0.8982 - val_loss: 0.3616 |
| Epoch 6/50 |                                                                                          |
| 43/43      | 285s 6s/step - accuracy: 0.8706 - loss: 0.4067 - val_accuracy: 0.8982 - val_loss: 0.3440 |
| Epoch 7/50 |                                                                                          |
| 43/43      | 236s 5s/step - accuracy: 0.8982 - loss: 0.3351 - val_accuracy: 0.9041 - val_loss: 0.3271 |

Gambar 4. Loss dan Validation







(c) Confusion Matrix ResNet-18

(d) Confusion Matrix ResNet-34

**Gambar 5.** Hasil Evaluasi Model ResNet 18 dan 34

| Model ResNet.   | Batch Size<br>Img Size | Epoch     | Accuracy      | Validasi<br>Accuracy |
|-----------------|------------------------|-----------|---------------|----------------------|
| ResNet 18       | 224, 224 (32)          | 10        | 0.8345        | 0.7032               |
| ResNet 18       | 224, 224 (32)          | 30        | 0.9709        | 0.8300               |
| ResNet 18       | 224, 224 (32)          | 50        | 0.9759        | 0.7925               |
| ReNet 34        | 224, 224 (32)          | 10        | 0.7716        | 0.6200               |
| ReNet 34        | 224, 224 (32)          | 30        | 0.9483        | 0.7771               |
| <b>ReNet 34</b> | <b>224, 224 (32)</b>   | <b>50</b> | <b>0.9508</b> | <b>0.8929</b>        |

**Tabel 4.** Hasil Training Model Varian ResNet

## Kesimpulan

Penelitian ini berfokus pada klasifikasi citra makanan tradisional Indonesia dengan kemiripan visual tinggi menggunakan arsitektur Deep Learning berbasis ResNet. Dataset terdiri atas tujuh kelas makanan, yaitu gado-gado, gudeg, nasi padang, rawon, rendang padang, sate, dan soto ayam. Tahapan preprocessing mencakup normalisasi ukuran citra, konversi format, serta data augmentation melalui rotasi, flipping, dan penyesuaian pencahayaan untuk meningkatkan keragaman dan mengurangi overfitting. Eksperimen dilakukan menggunakan ResNet-18 dan ResNet-34 dengan ukuran citra 224×224 piksel dan batch size 32. Hasil menunjukkan ResNet-18 memperoleh akurasi pelatihan 97,59% dan validasi 83,00% pada epoch ke-30, sedangkan ResNet-34 mencapai akurasi pelatihan 95,08% dan validasi 89,29% pada epoch ke-50. Model dengan lapisan lebih dalam terbukti memiliki generalisasi lebih baik terhadap variasi citra kompleks. Evaluasi melalui confusion matrix menunjukkan model mampu mengenali sebagian besar kelas dengan baik, meski masih terdapat kesalahan pada kelas yang mirip warna dan teksturnya seperti rawon dan rendang padang. Penelitian ini membuktikan efektivitas ResNet dalam klasifikasi citra makanan tradisional dan berpotensi diterapkan pada sistem pengenalan otomatis berbasis AI di bidang kuliner dan pariwisata. Pengembangan selanjutnya dapat mencakup perluasan dataset, penerapan transfer learning lanjutan, integrasi model ke aplikasi mobile/web, penggunaan Explainable AI (Grad-CAM/SHAP), serta perbandingan dengan arsitektur lain seperti Inception, MobileNet, dan Vision Transformer.

## Daftar Pustaka

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [2] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of Convolutional Neural Network (CNN)," *2017 Int. Conf. Eng. Technol.*, pp. 1–6, 2017, doi: 10.1109/ICEngTechnol.2017.8308186.
- [3] Y. Zhang, J. Zhao, and P. Wang, "Advances in Deep Learning for Food Recognition: A Review," *IEEE Access*, vol. 9, pp. 156392–156406, 2021.
- [4] D. N. Sari, F. Yuliani, and B. Santoso, "Klasifikasi Citra Makanan Tradisional Indonesia Menggunakan CNN Berbasis Transfer Learning," *J. Teknol. Inf.*, vol. 17, no. 2, pp. 78–86, 2021.
- [5] I. Rachmawati and A. Setiawan, "Analisis Kinerja Model CNN pada Klasifikasi Makanan Tradisional Indonesia," *J. Sist. Cerdas*, vol. 8, no. 1, pp. 44–53, 2022.

- [6] A. Hidayat, S. Rahmawati, and R. Pratama, "Implementasi Deep Learning untuk Klasifikasi Citra Makanan Tradisional Indonesia," *J. Teknol. Inf. dan Komput.*, vol. 9, no. 2, pp. 55–63, 2023.
- [7] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [8] M. Tan and Q. V Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proceedings of the 36th International Conference on Machine Learning (ICML)*, 2019, pp. 6105–6114.
- [9] Y. Li, H. Chen, and Y. Zhang, "Improved Residual Networks for Image Classification," *IEEE Access*, vol. 8, pp. 223445–223456, 2020.
- [10] L. Zhao, X. Wu, and T. Zhang, "ResNet-based Image Classification with Improved Generalization," *J. Vis. Commun. Image Represent.*, vol. 78, p. 103197, 2021.
- [11] X. Wang, J. Liu, and F. Li, "Hybrid Residual Network for Food Image Classification," *IEEE Access*, vol. 10, pp. 35124–35134, 2022.
- [12] A. D. Putra, D. Nuraini, and M. Ramadhan, "Deep Learning-Based Recognition of Indonesian Food Images Using CNN," *J. Inf. Syst. Res.*, vol. 10, no. 3, pp. 134–142, 2021.
- [13] R. P. Nugroho, E. Fitriani, and A. Suryanto, "Pemanfaatan CNN untuk Identifikasi Objek Citra Makanan Lokal Berbasis Android," *J. Inform.*, vol. 13, no. 4, pp. 217–226, 2022.
- [14] D. Prasetyo and R. Arifianto, "Implementasi Model ResNet untuk Klasifikasi Citra Makanan Tradisional Nusantara," *J. Ilmu Komput. dan Apl.*, vol. 15, no. 1, pp. 12–23, 2024.