

# Analisis Pengaruh Augmentasi Data Terhadap Performa Transfer Learning MobileNetV2 dalam Klasifikasi Citra Makanan Indonesia

Salsabila Aulia Ramadhan<sup>1</sup>, Atang Susila<sup>1\*</sup>

<sup>1</sup>Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Jl. Raya Puspipetek No. 46, Kel. Buaran, Kec. Serpong, Kota Tangerang Selatan, Banten 15310, Indonesia

Email: [salsabilaauliar1@gmail.com](mailto:salsabilaauliar1@gmail.com), [\\*atang.g66@gmail.com](mailto:atang.g66@gmail.com)

(\* : coresponding author)

**Abstrak**– Keterbatasan jumlah data latih dan tingginya variasi visual pada citra makanan Indonesia sering menyebabkan model klasifikasi berbasis *deep learning* mengalami *overfitting* serta kesulitan dalam mengenali citra baru secara akurat. Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan delapan skenario augmentasi data pada model *MobileNetV2* berbasis *transfer learning* untuk mengklasifikasikan 10 kelas makanan Indonesia, yaitu Ayam Pop, Bakso, Gado-Gado, Mie Goreng, Nasi Goreng, Rawon, Rendang, Sate, Soto, dan Telur Balado. Dataset yang digunakan terdiri dari 500 citra untuk pelatihan yang dibagi menjadi 70% data latih dan 30% data validasi, serta 100 citra tambahan sebagai data uji independen. Teknik augmentasi yang diterapkan meliputi rotation, zoom, brightness, contrast, photometric (brightness + contrast), geometric (rotation + zoom), dan combined yang merupakan gabungan seluruh teknik tersebut, serta skenario baseline tanpa augmentasi. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Hasil penelitian menunjukkan bahwa seluruh teknik augmentasi mampu meningkatkan performa model dibandingkan dengan skenario baseline yang hanya mencapai akurasi validasi sebesar 80,00% dan menunjukkan indikasi *overfitting*. Skenario rotation menghasilkan performa terbaik dengan akurasi validasi sebesar 91,87% dan akurasi uji independen sebesar 87,00%. Hasil ini menunjukkan bahwa penerapan augmentasi data yang tepat dapat meningkatkan akurasi serta kemampuan generalisasi model *MobileNetV2* dalam klasifikasi citra makanan Indonesia pada kondisi data yang terbatas.

**Kata Kunci:** Augmentasi Data, Transfer Learning, MobileNetV2, Klasifikasi Citra, Makanan Indonesia

**Abstract**– Limited training data and high visual variability in Indonesian food images often cause deep learning-based classification models to experience overfitting and difficulties in accurately recognizing new images. To address this issue, this study applies eight data augmentation scenarios to a transfer learning-based MobileNetV2 model for classifying 10 Indonesian food categories, namely Ayam Pop, Bakso, Gado-Gado, Mie Goreng, Nasi Goreng, Rawon, Rendang, Sate, Soto, and Telur Balado. The dataset consists of 500 images used for training, which are divided into 70% training data and 30% validation data, along with 100 additional images used as an independent test set. The applied augmentation techniques include rotation, zoom, brightness adjustment, contrast adjustment, photometric (brightness + contrast), geometric (rotation + zoom), and a combined scenario integrating all augmentation techniques, as well as a baseline scenario without augmentation. Model performance was evaluated using accuracy, precision, recall, F1-score, and confusion matrix. The results indicate that all augmentation techniques improve the model performance compared to the baseline scenario, which only achieved 80.00% validation accuracy and showed signs of overfitting. The rotation scenario achieved the best performance with a validation accuracy of 91.87% and an independent test accuracy of 87.00%. These findings demonstrate that appropriate data augmentation can improve both the accuracy and generalization capability of the MobileNetV2 model in Indonesian food image classification under limited data conditions.

**Keywords:** Data Augmentation, Transfer Learning, MobileNetV2, Image Classification, Indonesian Food

## 1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan membuat komputer kini mampu mengenali dan mengolah gambar dengan cara yang semakin menyerupai manusia. Salah satu bidang yang banyak berkembang adalah klasifikasi citra, yang dimanfaatkan dalam berbagai kebutuhan seperti pendeteksian objek, analisis medis, hingga pengenalan makanan (Wijayanto et al., 2024). Model berbasis *deep learning*, terutama *Convolutional Neural Network (CNN)*, banyak digunakan karena mampu mempelajari pola visual secara otomatis dan mendalam (Hartono et al., 2022). Namun, pelatihan CNN dari awal membutuhkan data yang sangat banyak dan waktu komputasi yang tidak

sedikit, sehingga cukup sulit diterapkan pada domain dengan data terbatas, seperti citra makanan Indonesia (Sasongko et al., 2023).

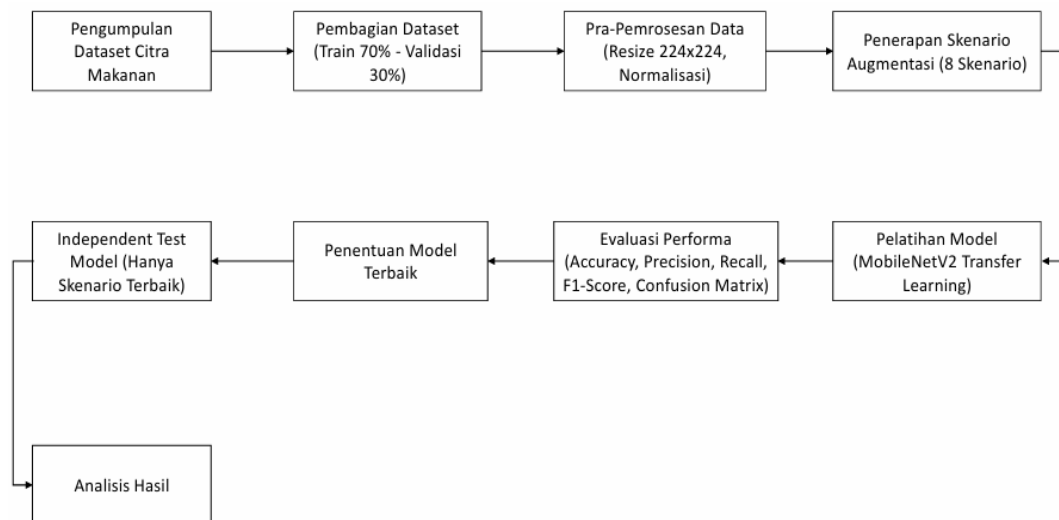
*Transfer learning* kemudian muncul sebagai pendekatan yang lebih efisien. Dengan memanfaatkan model pralatih seperti *MobileNetV2* yang sudah dilatih menggunakan dataset besar seperti *ImageNet*, model dapat disesuaikan kembali untuk tugas klasifikasi yang berbeda dengan jumlah data yang lebih sedikit (Bansal et al., 2023; Yadav & Chand, 2021). *MobileNetV2* juga dikenal ringan dan cocok diimplementasikan pada berbagai perangkat, termasuk untuk pengenalan makanan. Meski demikian, klasifikasi makanan Indonesia masih menghadapi tantangan karena banyak hidangan memiliki tampilan yang serupa dari sisi warna, tekstur, dan bentuk, sehingga model membutuhkan data dengan variasi yang cukup untuk membedakan tiap kelas secara akurat (Rasyidi et al., 2024).

Augmentasi data menjadi salah satu cara yang lebih praktis untuk menambah variasi citra pelatihan tanpa harus menambah jumlah data secara manual. Melalui transformasi seperti rotasi, pergeseran sudut pandang, atau penyesuaian tingkat pencahayaan, model memperoleh lebih banyak contoh visual sehingga dapat belajar lebih baik dan mengurangi risiko *overfitting* (Chun et al., 2022). Beberapa penelitian sebelumnya menunjukkan bahwa kombinasi augmentasi data dan *transfer learning* mampu meningkatkan performa klasifikasi pada dataset yang ukurannya terbatas (Chun et al., 2022; Sasongko et al., 2023).

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk menganalisis pengaruh berbagai teknik augmentasi data terhadap performa *MobileNetV2* dalam klasifikasi citra makanan Indonesia. Penelitian ini memberikan kontribusi berupa analisis komparatif terhadap delapan skenario augmentasi data untuk mengidentifikasi teknik yang paling efektif dalam meningkatkan kemampuan generalisasi model pada klasifikasi makanan Indonesia.

## 2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen kuantitatif untuk menganalisis pengaruh delapan teknik augmentasi data terhadap performa model *MobileNetV2* dalam klasifikasi citra makanan Indonesia. Tahapan metodologi meliputi pengumpulan dataset, pra-pemrosesan, penerapan augmentasi, pelatihan model, serta evaluasi performa hasil pelatihan. Secara ringkas, alur penelitian yang dilaksanakan dalam studi ini ditunjukkan pada Gambar 1.



**Gambar 1.** Alur Penelitian

### 2.1 Dataset

Dataset yang digunakan terdiri dari 10 kelas makanan Indonesia yaitu ayam pop, bakso, gado-gado, mie goreng, nasi goreng, rawon, rendang, sate, soto, dan telur balado. Setiap kelas memiliki 50 citra sehingga total dataset berjumlah 500 citra.

**Tabel 1.** Jumlah Citra Dataset Penelitian

No	Kelas Makanan	Jumlah Citra
1	Ayam Pop	50
2	Bakso	50
3	Gado-Gado	50
4	Mie Goreng	50
5	Nasi Goreng	50
6	Rawon	50
7	Rendang	50
8	Sate	50
9	Soto	50
10	Telur Balado	50
Total		500

Dataset kemudian dibagi menjadi dua bagian yaitu 70% sebagai data latih dan 30 % sebagai data validasi. Selain itu digunakan 100 citra tambahan sebagai independent test untuk menguji kemampuan generalisasi model.

**Tabel 2.** Pembagian Dataset Penelitian

Jenis Dataset	Persentase	Jumlah Citra
Data Latih	70%	350
Data Validasi	30%	150
Data Uji Independen	-	100
Total	-	600

## 2.2 Pra-Pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan seluruh citra memiliki format yang seragam sebelum diproses oleh model. Dalam tahap ini, setiap citra diubah ukurannya menjadi 224 × 224 piksel, yaitu ukuran standar untuk input pada arsitektur *MobileNetV2*. Penyesuaian ukuran ini bertujuan agar seluruh citra dapat diproses tanpa distorsi bentuk dan tetap merepresentasikan karakter visual makanan secara optimal.

Selain itu, nilai piksel pada masing-masing citra dinormalisasikan ke rentang 0 hingga 1. Normalisasi dilakukan untuk menstabilkan proses pembelajaran serta membantu model mencapai konvergensi yang lebih baik saat pelatihan. Setelah itu, data dikelompokkan sesuai kelas masing-masing gambar, kemudian dibagi menjadi data latih, dan validasi berdasarkan pembagian yang telah ditentukan pada Tabel 2.

## 2.3 Augmentasi Data

Augmentasi data dilakukan untuk menambah keberagaman citra pada dataset sehingga model dapat mempelajari lebih banyak variasi visual dari setiap kelas makanan. Teknik ini sangat penting diterapkan pada kondisi jumlah data yang terbatas, karena tanpa augmentasi model cenderung menghafal data latih dan mengalami *overfitting* saat berhadapan dengan data baru.

Pada penelitian ini diterapkan delapan skenario augmentasi yang berbeda. Satu skenario bertindak sebagai *baseline*, yaitu pelatihan tanpa augmentasi, sementara tujuh skenario lainnya menerapkan transformasi citra yang bervariasi. Daftar skenario augmentasi yang digunakan yaitu terdapat pada Tabel 3.

**Tabel 3.** Jenis Augmentasi

Skenario	Jenis Augmentasi	Teknik Variasi yang Digunakan	Keterangan	Total Citra
Skenario 1	Baseline	-	Tanpa augmentasi	50
Skenario 2	Rotation	-20°, -10°, 0°, 10°, 20°	Dataset dengan efek rotasi.	2500

Skenario 3	Zoom	-0.2x, -0.1x, 0x, 0.1x, 0.2x	Dataset dengan efek zoom in/out.	2500
Skenario 4	Brightness	-20%, -10%, 0%, +10%, +20%	Dataset dengan efek pencerahan terang/gelap.	2500
Skenario 5	Contrast	-20%, -10%, 0%, +10%, +20%	Dataset dengan efek kontras.	2500
Skenario 6	Geometric	Rotation + Zoom	Semua transformasi bentuk dan posisi gambar (rotasi + zoom).	2500
Skenario 7	Photometric	Brightness + Contrast	Mengubah aspek Cahaya dan warna (Brightness + Contrast)	2500
Skenario 8	Combined	Semua jenis augmentasi	Kombinasi rotation + zoom + brightness + contrast.	2500

Augmentasi data diterapkan pada data latih dan data validasi, sehingga setiap citra pada kedua subset tersebut memperoleh variasi visual tambahan. Sementara itu, data independent test tidak diberikan augmentasi agar proses pengujian mencerminkan performa model pada data baru.

#### 2.4 Model dan Pelatihan

Model yang digunakan pada penelitian ini adalah *MobileNetV2*, yaitu salah satu arsitektur *Convolutional Neural Network* (CNN) yang dirancang agar efisien dalam penggunaan komputasi dan memori. *MobileNetV2* dipilih karena memiliki kemampuan ekstraksi fitur yang baik pada citra berukuran kecil sehingga cocok untuk diterapkan pada penelitian dengan sumber daya terbatas (Kencana et al., 2024).

Dalam penelitian ini, *MobileNetV2* diterapkan menggunakan pendekatan *transfer learning*, di mana bobot pralatih dari *ImageNet* digunakan sebagai *feature extractor*. Seluruh lapisan ekstraksi fitur dikunci (*freeze*) agar kemampuan representasi visual yang telah dipelajari sebelumnya tetap dipertahankan. Selanjutnya, bagian *classifier* dimodifikasi dengan menambahkan lapisan *Global Average Pooling*, *Dropout*, dan *Dense* berjumlah sepuluh neuron dengan *softmax* sebagai fungsi aktivasi untuk mendukung klasifikasi sepuluh kelas makanan Indonesia.

Proses pelatihan dilakukan secara konsisten pada delapan skenario augmentasi data. Setiap skenario menggunakan konfigurasi pelatihan yang sama untuk menjaga keadilan dalam perbandingan performa antar model. Pengaturan pelatihan yang diterapkan ditunjukkan pada Tabel 4 berikut ini.

**Tabel 4.** Pelatihan *MobileNetV2*

No	Parameter	Nilai
1.	Arsitektur Model	<i>MobileNetV2 (Transfer Learning)</i>
2.	Input Image Size	224 × 224 piksel
3.	Optimizer	<i>Adam</i>
4.	Learning Rate	0.001
5.	Batch Size	8
6.	Jumlah Epoch Maksimal	50
7.	EarlyStopping	<i>Patience = 5</i>
8.	Jumlah Output	10 Kelas Makanan Indonesia
9.	Lapisan Tambahan	<i>Global Average Pooling, Dropout (0.3), Dense Softmax</i>

Untuk mencegah *overfitting*, digunakan teknik *EarlyStopping*, di mana pelatihan otomatis dihentikan apabila performa pada data validasi tidak mengalami peningkatan selama beberapa

iterasi. Dengan penerapan konfigurasi tersebut, model diharapkan dapat belajar secara optimal dan menghasilkan performa yang stabil saat diuji menggunakan data baru.

## 2.5 Evaluasi Performa

Evaluasi performa dilakukan untuk menilai kemampuan model dalam melakukan klasifikasi pada gambar makanan Indonesia. Pengujian dilakukan menggunakan data validasi untuk setiap skenario augmentasi guna membandingkan peningkatan performa yang diberikan oleh masing-masing teknik. Pengukuran performa dilakukan menggunakan empat metrik utama, yaitu:

### 1. Accuracy

*Accuracy* digunakan untuk melihat proporsi prediksi yang benar dari seluruh data yang diuji. Metrik ini bekerja dengan baik ketika data memiliki distribusi kelas yang seimbang, namun dapat menjadi kurang representatif jika terjadi ketidakseimbangan kelas (Nugroho et al., 2023; Prityanto & Zein, 2023).

### 2. Precision

*Precision* digunakan untuk menilai sejauh mana prediksi positif model sesuai dengan label positif sebenarnya. Metrik ini menjadi penting ketika kesalahan prediksi positif perlu diminimalkan, misalnya pada kasus medis (Zhang et al., 2020).

### 3. Recall

*Recall* mengukur kemampuan model dalam mengenali seluruh sampel kelas positif yang sebenarnya (Ahmed et al., 2022). Nilai *recall* yang tinggi menunjukkan bahwa model tidak melewatkan banyak data positif pada proses prediksi.

### 4. F1-Score

*F1-score* merupakan rata-rata harmonis antara *precision* dan *recall*, sehingga dapat memberikan penilaian yang lebih seimbang pada kondisi data yang memiliki tingkat variabilitas tinggi (Chicco & Jurman, 2020).

Selain itu, digunakan juga *confusion matrix* untuk menganalisis bagaimana distribusi kesalahan prediksi antar kelas makanan, sehingga dapat diketahui kelas mana yang masih sulit dibedakan oleh model.

Melalui evaluasi ini, setiap skenario augmentasi dapat dibandingkan secara objektif untuk menentukan teknik yang paling efektif dalam meningkatkan akurasi dan kemampuan generalisasi model *MobileNetV2* pada dataset citra makanan Indonesia.

## 3. ANALISA DAN PEMBAHASAN

Evaluasi dilakukan pada delapan skenario pelatihan untuk mengukur pengaruh augmentasi data terhadap performa model *MobileNetV2* dalam mengenali citra makanan Indonesia. Hasil pengujian pada data validasi ditampilkan pada Tabel 5.


Tabel 5. Perbandingan Performa Validasi pada Seluruh Skenario Augmentasi

No	Skenario	Accuracy	Precision	Recall	F1-Score
1.	Rotation	91.87%	92.32%	91.87%	91.93%
2.	Contrast	91.47%	92.09%	91.47%	91.54%
3.	Photometric	91.07%	91.31%	91.07%	90.93%
4.	Brightness	89.60%	90.48%	89.60%	89.78%
5.	Zoom	88.67%	89.26%	88.67%	88.52%
6.	Combined	86.53%	87.04%	86.53%	86.48%
7.	Geometric	86.00%	87.13%	86.00%	86.14%
8.	Baseline	80.00%	85.75%	80.00%	79.29%

Berdasarkan hasil pada Tabel 5, seluruh skenario augmentasi mampu meningkatkan performa model dibandingkan baseline yang memperoleh akurasi validasi 80,00%. Hal ini

menunjukkan bahwa penambahan variasi visual pada data pelatihan berhasil membantu model mempelajari fitur makanan secara lebih beragam dan mengurangi *overfitting*.

Untuk memperlihatkan permasalahan *overfitting* yang terjadi pada skenario *baseline*, Gambar 2 menyajikan grafik perbandingan akurasi pelatihan dan validasi selama proses pelatihan.




**Gambar 2.** Training vs Validation Accuracy Baseline

Gambar 2 memperlihatkan bahwa akurasi pada data latih meningkat dengan sangat cepat dan mendekati 100% sejak awal pelatihan. Namun, akurasi pada data validasi justru berada di kisaran 70–80% dan tidak menunjukkan peningkatan yang sebanding. Jarak yang cukup besar antara kedua kurva ini mengindikasikan bahwa model *baseline* mengalami *overfitting*, karena model terlalu terpaku pada pola dari data latih dan kurang mampu melakukan generalisasi terhadap data baru. Temuan ini menunjukkan bahwa penggunaan teknik augmentasi diperlukan untuk meningkatkan kemampuan model dalam mengenali variasi visual pada citra makanan.


Skenario *rotation* memberikan hasil terbaik pada semua metrik penilaian, termasuk akurasi sebesar 91,87% dan F1-score 91,93%. Rotasi citra efektif untuk memperluas pemahaman model terhadap bentuk dan orientasi objek makanan yang sering tertangkap kamera dari sudut yang berbeda di dunia nyata. Skenario *contrast* dan *photometric* juga menunjukkan performa kuat, menandakan bahwa penyesuaian pencahayaan dan detail visual cukup penting dalam klasifikasi makanan dengan karakter visual yang beragam. Sebaliknya, skenario *combined* dan *geometric* memberikan peningkatan yang lebih rendah karena transformasi yang terlalu kompleks dapat mengubah karakteristik citra secara berlebihan sehingga model kesulitan menangkap pola asli dari objek makanan. Dengan demikian, pemilihan teknik augmentasi yang tepat sangat menentukan kualitas model yang dihasilkan.

Untuk memperjelas tren peningkatan performa dari seluruh skenario pelatihan, Gambar 3 menampilkan grafik perkembangan akurasi validasi pada setiap model.



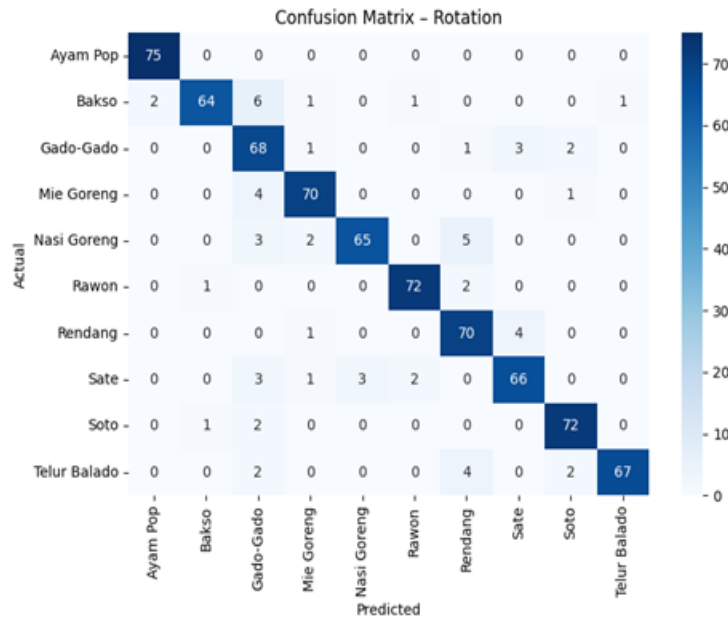
**Gambar 3.** Accuracy Seluruh Skenario

Gambar 3 menunjukkan perbandingan akurasi validasi pada delapan skenario augmentasi data. Hasil ini memperlihatkan bahwa skenario rotation memberikan peningkatan performa paling signifikan dibandingkan skenario lainnya.



**Gambar 4.** *Training vs Validation Accuracy – Rotation*

Selain menghasilkan akurasi yang lebih tinggi, model dengan penerapan augmentasi rotasi juga menunjukkan kemampuan generalisasi yang lebih baik. Distribusi prediksi pada setiap kelas makanan ditampilkan melalui *confusion matrix* pada Gambar 5. Visualisasi ini memberikan gambaran mengenai pola prediksi model serta sebaran kesalahan klasifikasi pada data uji.



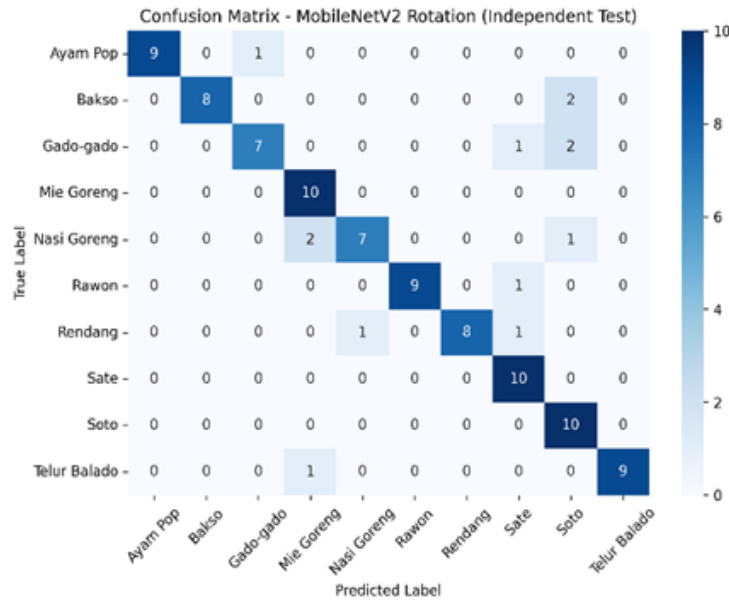
**Gambar 5.** *Confusion Matrix – Rotation*

#### 4. IMPLEMENTASI

Model dengan performa terbaik yaitu skenario *rotation* kemudian diuji menggunakan *independent test* dataset yang terdiri dari 100 citra baru yang tidak pernah digunakan dalam proses pelatihan.

**Tabel 6.** Hasil Evaluasi *Independent Test* pada Skenario Rotation

Metrik	Nilai
Accuracy	87.00%
Precision	89.55%
Recall	87.00%
F1-Score	87.15%



**Gambar 6.** Confusion Matrix Rotation pada Independent Test

Berdasarkan *confusion matrix* pada Gambar 6, sebagian besar kelas makanan berhasil diklasifikasikan dengan baik oleh model. Beberapa kelas seperti mie goreng, sate, dan soto memiliki tingkat prediksi yang sangat tinggi, menunjukkan bahwa ciri visual pada makanan tersebut cukup mudah dikenali oleh model. Namun demikian, masih terdapat beberapa kesalahan klasifikasi pada kelas yang memiliki kemiripan visual, seperti gado-gado yang terkadang diprediksi sebagai sate atau soto. Hal ini menunjukkan bahwa kemiripan warna dan komposisi bahan makanan dapat mempengaruhi proses klasifikasi model.

Berdasarkan hasil tersebut, model masih dapat mempertahankan performa klasifikasinya dengan cukup baik pada data baru. Perbedaan nilai antara validasi dan independent test masih tergolong wajar, yang menandakan bahwa model tidak mengalami *overfitting* secara berlebihan. Nilai *precision* yang lebih tinggi daripada *recall* mengindikasikan bahwa model lebih baik dalam menghindari kesalahan prediksi pada kelas yang tidak sesuai, meskipun masih terdapat sebagian makanan yang tidak terdeteksi dengan benar.

Secara keseluruhan, hasil ini menunjukkan bahwa teknik augmentasi *rotation* mampu membantu model mengenali variasi orientasi makanan yang umum ditemukan pada citra dunia nyata. Dengan demikian, model dinilai cukup andal dalam melakukan klasifikasi citra makanan Indonesia meskipun jumlah data pelatihan terbatas.

## 5. KESIMPULAN

Penelitian ini bertujuan meningkatkan performa model *MobileNetV2* dalam klasifikasi citra makanan Indonesia melalui penerapan delapan skenario augmentasi data. Berdasarkan eksperimen yang dilakukan, seluruh teknik augmentasi terbukti mampu mengurangi gejala *overfitting* dan meningkatkan generalisasi model dibandingkan *baseline* yang hanya mencapai akurasi 80,00% dan *F1-score* 79,29%.

Skenario *rotation* menghasilkan performa terbaik dengan akurasi 91,87%. Hasil pengujian pada data independent test juga konsisten dengan akurasi 87,00%, menunjukkan kemampuan model untuk mengenali citra baru yang tidak pernah dilihat sebelumnya. Sementara itu, skenario *contrast* dan *photometric* turut memberikan peningkatan performa yang kuat, diikuti *brightness* dan *zoom*. Sebaliknya, skenario *geometric* dan *combined* memberikan peningkatan yang lebih rendah karena transformasi yang terlalu kompleks dapat mengubah karakteristik citra asli secara berlebihan.

Secara keseluruhan, penelitian ini membuktikan bahwa pemilihan augmentasi yang tepat berperan penting dalam meningkatkan efektivitas *transfer learning* pada dataset dengan variasi visual terbatas. Temuan ini dapat menjadi acuan dalam pengembangan lebih lanjut sistem klasifikasi makanan berbasis visi komputer pada skala penerapan nyata.

## REFERENCES

- Ahmed, S., Hasan, B., Ahmed, T., Sony, R. K., & Kabir, H. (2022). Less Is More : Lighter and Faster Deep Neural Architecture for Tomato Leaf Disease Classification. *IEEE Access*, 10(June), 68868–68884. <https://doi.org/10.1109/ACCESS.2022.3187203>
- Bansal, M., Kumar, M., Sachdeva, M., & Mittal, A. (2023). Transfer learning for image classification using VGG19: Caltech-101 image data set. *Journal of Ambient Intelligence and Humanized Computing*, 14(4), 3609–3620. <https://doi.org/10.1007/s12652-021-03488-z>
- Chicco, D., & Jurman, G. (2020). *The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation*. 1–13.
- Chun, T. H., Hashim, U. R., Ahmad, S., Salahuddin, L., Choon, N. H., & Kanchymalay, K. (2022). Efficacy of the Image Augmentation Method using CNN Transfer Learning in Identification of Timber Defect. *International Journal of Advanced Computer Science and Applications*, 13(5), 107–114. <https://doi.org/10.14569/IJACSA.2022.0130514>
- Hartono, I., Noertjahyana, A., & Santoso, L. W. (2022). Deteksi Masker Wajah dengan Metode Convolutional Neural Network. *Jurnal Infra*, 10. <https://publication.petra.ac.id/index.php/teknik-informatika/article/view/12042>
- Kencana, N. W., Rusydi, U., & Murinto. (2024). Implementasi Transfer Learning Untuk Klasifikasi Jenis Ras Ayam. *JIP (Jurnal Informatika Polinema)*, 147–154. <https://jurnal.polinema.ac.id/index.php/jip/article/view/6469/4405>
- Nugroho, A., Soelean, M. A., Premunendar, R. A., Nurhindarto, A., Nuswantoro, U. D., & Korespondensi, P. (2023). *PENINGKATAN PERFORMA ENSEMBLE LEARNING PADA SEGMENTASI SEMANTIK GAMBAR DENGAN TEKNIK OVERSAMPLING UNTUK CLASS IMPROVED PERFORMANCE OF ENSEMBLE LEARNING ON SEMANTIC SEGMENTATION OF IMAGES WITH OVERSAMPLING TECHNIQUES FOR CLASS*. 10(4). <https://doi.org/10.25126/jtiik.2023106831>
- Pristyanto, Y., & Zein, A. A. (2023). *Model Balanced Bagging Berbasis Decision Tree Pada Dataset Imbalanced Class*. 12, 9–15.
- Rasyidi, M. A., Mardhiyyah, Y. S., Nasution, Z., & Wijaya, C. H. (2024). Performance comparison of state-of-the-art deep learning model architectures in Indonesian food image classification. *Bulletin of Electrical Engineering and Informatics*, 13(5), 3355–3368. <https://doi.org/10.11591/eei.v13i5.7996>
- Sasongko, T. B., Haryoko, H., & Amrullah, A. (2023). Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(4), 763–768. <https://doi.org/10.25126/jtiik.20241046583>
- Wijayanto, M. F., Swanjaya, D., & Wulanningrum, R. (2024). Penerapan MobileNet Architecture pada Identifikasi Foto Citra Makanan Indonesia. *Digital Transformation Technology*, 4(1), 652–662. <https://doi.org/10.47709/digitech.v4i1.4449>
- Yadav, S., & Chand, S. (2021). Food image recognition based on Mobile NetV2 using support vector machine. *Proceedings of International Conference on Women Researchers in Electronics and Computing, Wrec*, 192–200. <https://doi.org/10.21467/proceedings.114.27>