

# Klasifikasi Jajanan Tradisional Indonesia berbasis *Deep Learning* dan Metode *Transfer Learning*

RAIHAN FATURRAHMAN, YULI SUN HARIYANI, SUGONDO HADIYOSO

Fakultas Ilmu Terapan, Universitas Telkom, Indonesia

Email : [yulisun@telkomuniversity.ac.id](mailto:yulisun@telkomuniversity.ac.id)

*Received* 20 Juli 2023 | *Revised* 14 Agustus 2023 | *Accepted* 26 Agustus 2023

## ABSTRAK

*Makanan jajanan tradisional Indonesia telah menjadi warisan budaya yang berharga dan penting. Namun di tengah kemajuan zaman, sebagian masyarakat menganggapnya ketinggalan dan beralih ke makanan modern. Sebagai bagian dari upaya untuk melestarikan dan membantu masyarakat terutama kaum muda untuk mengenali ragam jajanan tradisional Indonesia, maka penelitian ini bertujuan untuk mengklasifikasi jenis jajanan tradisional Indonesia secara otomatis berdasarkan citra dengan menggunakan arsitektur deep learning. Dalam penelitian ini, dilakukan penggunaan metode transfer learning untuk melatih ulang base-network, sehingga mampu mengenali citra jajanan tradisional Indonesia. Di antara tiga base network yang dilatih dan diuji, disimpulkan bahwa dengan menggunakan base-network mobilenetV2 menghasilkan akurasi uji sebesar 98%, tertinggi dibandingkan dengan menggunakan ResNet50 dan VGG16 yang menghasilkan akurasi uji 97.33% dan 93.33%.*

**Kata kunci:** *jajanan tradisional indonesia, klasifikasi, deep learning, transfer learning*

## ABSTRACT

*Traditional Indonesian snacks have become valuable and important cultural heritage. However, amidst the progress of time, some people consider them outdated and switch to modern foods. As part of an effort to preserve and help the community, especially the younger generation, to recognize various traditional Indonesian snacks, this research aims to automatically classify types of traditional Indonesian snacks based on images using deep learning architecture. In this study, transfer learning method was employed to retrain the base-network, enabling it to recognize images of traditional Indonesian snacks. Among the three base networks trained and tested, it was concluded that using the MobileNetV2 base-network resulted in a test accuracy of 98%, the highest compared to using ResNet50 and VGG16, which achieved test accuracies of 97.33% and 93.33% respectively.*

**Keywords:** *Indonesian traditional snack, classification, deep learning, transfer learning*

## 1. PENDAHULUAN

Makanan atau jajanan tradisional adalah jajanan lokal yang dimiliki daerah tertentu yang dapat menjadi khas tersendiri. Jajanan tradisional hingga sekarang masih ada dan biasanya digunakan atau dapat dinikmati pada acara tradisi adat, perkawinan, dan lainnya **(Nahak, 2019) (Putri, dkk, 2021)**. Pada jaman modern, ada masyarakat yang beranggapan jika jajanan tradisional sudah ketinggalan dan kemudian bergeser ke makanan atau jajanan modern. Saat ini banyak makanan modern yang diimpor dan mudah didapatkan **(Waluyo, dkk, 2021)**. Namun demikian, jajanan tradisional merupakan salah satu bentuk warisan dari nenek moyang dan sebagai penerus bangsa kita wajib melestarikannya **(Nahak, 2019)**. Sebagai bangsa Indonesia seharusnya kita mengenal berbagai macam makanan jajanan yang tersebar di berbagai wilayah yang ada di Indonesia. Lebih jauh lagi kita dapat mengenalkan jenis makanan jajanan Indonesia ke negara lain agar jajanan tradisional Indonesia tidak diklaim oleh negara lain. Beragam jenis jajanan tradisional yang dimiliki oleh Indonesia akan menyulitkan dalam mengenalinya. Beberapa jenis bahkan sangat mirip satu dengan lainnya. Sehingga diperlukan pengetahuan untuk dapat mengenali jenis-jenis jajanan tradisional secara visual.

Teknologi pengenalan objek yang kemudian dikenal *computer vision* pada sebuah gambar telah berkembang cepat dan menghasilkan performa tinggi **(Matsuzaka & Yashiro, 2023) (Nahak, 2019)**. Teknologi *computer vision* telah membantu dalam berbagai sektor seperti medis, transportasi, hutan, pertanian, dan lainnya **(Kakani, dkk, 2020) (Zhu, dkk, 2021)**. Oleh karena itu, teknologi ini memungkinkan untuk diterapkan dalam pengenalan atau pembelajaran jajanan tradisional. Beberapa penelitian mengusulkan *platform computer vision* untuk mengenali jajanan tradisional. Teknik ekstraksi ciri pada gambar makanan tradisional kemudian dikombinasikan dengan metode pengklasifikasi otomatis telah dilaporkan pada **(Fahira, dkk, 2020)**. Penelitian serupa lainnya pada beberapa jenis makanan Indonesia menggunakan metode ekstraksi ciri tradisional meliputi analisis warna dan tekstur yang dikombinasikan dengan *k-nearest neighbor* juga telah dilaporkan pada **(Febriani, dkk, 2019) (Muslika, dkk, 2022)**. Penelitian lainnya menitikberatkan pada penggunaan metode *deep learning* dengan basis *Convolutional Neural Network* yang dianggap dapat menghasilkan akurasi tinggi pada jumlah data yang besar. Penelitian berkaitan dengan klasifikasi jajanan tradisional Indonesia menggunakan *deep learning* telah dilaporkan pada **(Hariman, dkk, 2023) (Sarwinda, dkk, 2020)**. Penelitian-penelitian tersebut telah berhasil memberikan akurasi tinggi hingga lebih besar 95%. Meskipun demikian masih terdapat *gap* penelitian dalam klasifikasi jenis jajanan yang berbeda.

Oleh karena itu pada penelitian ini diusulkan teknik klasifikasi lima jenis jajanan tradisional Indonesia menggunakan *deep learning* dengan pendekatan *convolutional network* dan *transfer learning*. Lima jenis makanan tersebut adalah cucur, klepon, kue ku, kue talam, dan onde-onde. Simulasi awal perancangan dengan mengumpulkan gambar, dilanjutkan dengan pemrosesan awal untuk menyeragamkan ukuran gambar, dilanjutkan dengan ekstraksi ciri menggunakan konvolusi dua dimensi, dan klasifikasi. Dalam penelitian ini, metode yang diusulkan dijalankan pada google colab berbasis pemrograman python. Evaluasi kinerja yang diusulkan meliputi akurasi, *precision* dan *recall*. Dengan sistem ini diharapkan dapat mempermudah pengguna dalam mengenali beragam jajanan tradisional yang ada di Indonesia.

## 2. METODOLOGI

### 2.1 Convolutional Neural Network

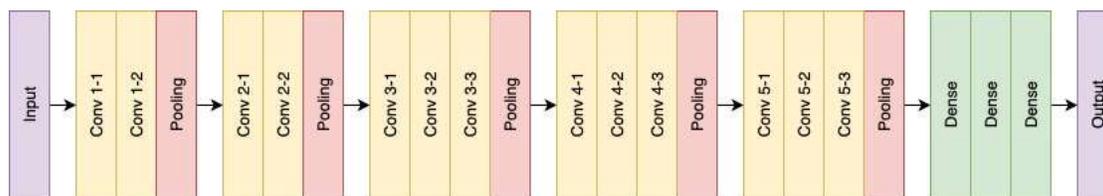
Metode *machine learning* yang populer dikembangkan saat ini terutama untuk citra adalah *Convolutional Neural Network* (CNN). CNN berhasil digunakan dalam menyelesaikan berbagai permasalahan terkait citra seperti klasifikasi (Vankdothu, dkk, 2022), deteksi (Subhi & Md. Ali, 2018), segmentasi (Hariyani, dkk, 2020), rekognisi (Kaur, dkk, 2022), dan lain sebagainya. Terdapat berbagai variasi arsitektur jaringan CNN yang telah dikembangkan seperti VGGNet (Simonyan & Zisserman, 2014), MobileNet (Sandler, dkk, 2018), Densenet (Huang, dkk, 2017), dan lain sebagainya. CNN pada dasarnya terdiri dari banyak lapisan yang terdiri dari *layer* konvolusi, *layer pooling*, dan *layer fully connected*.

### 2.2 Transfer Learning

*Transfer learning* adalah metode atau teknik yang memanfaatkan jaringan yang telah dilatih sebelumnya dan menggunakannya sebagai titik awal untuk mempelajari tugas atau masalah baru. Dengan menggunakan *transfer learning*, fitur yang telah dipelajari dapat ditransfer ke tugas baru dengan memanfaatkan dataset yang lebih sedikit selama proses pelatihan, sehingga mempercepat proses tersebut. Dikarenakan jaringan sudah melalui proses pelatihan sebelumnya dan telah mempelajari untuk mengekstraksi berbagai fitur yang berbeda, jaringan yang baru menjadi lebih akurat dalam melakukan tugasnya.

### 2.3 VGG16

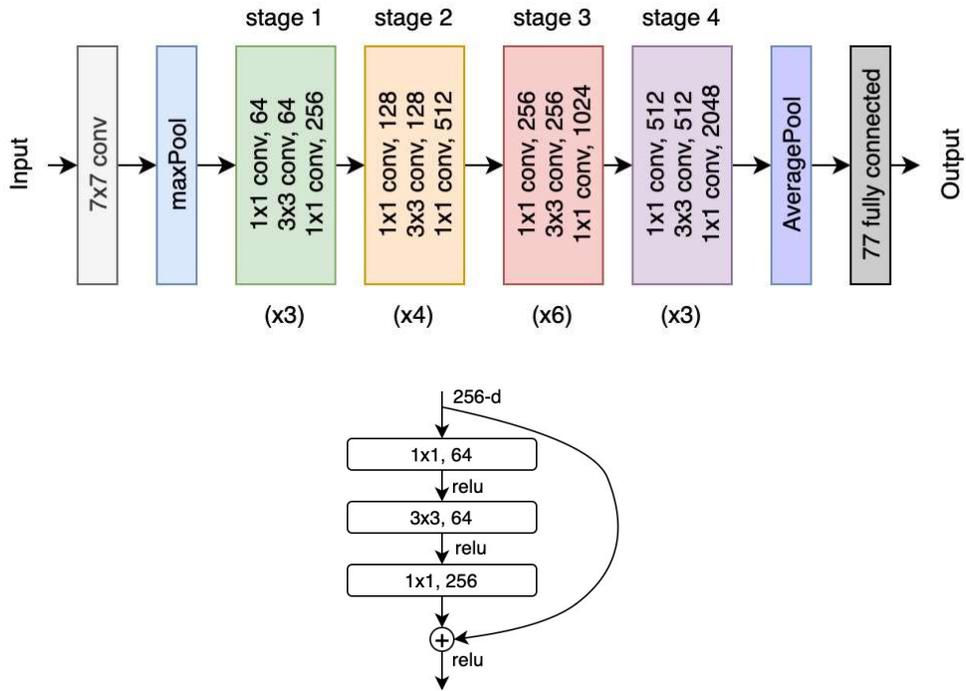
VGG16 (Simonyan & Zisserman, 2014) adalah sebuah model CNN yang menggunakan lapisan atau *layer* konvolusi dengan filter konvolusi berukuran kecil (3×3). Dengan menggunakan ukuran filter konvolusi tersebut, kedalaman jaringan saraf dapat ditingkatkan dengan menambahkan lebih banyak lapisan konvolusi. Model VGG16 mempunyai 19 lapisan yang terdiri dari 16 lapisan operasi konvolusi dan tiga lapisan *fully connected*. Gambar 1 menunjukkan arsitektur dasar dari VGG16.



Gambar 1. Arsitektur VGG16

### 2.4 ResNet50

ResNet-50 merupakan salah satu varian arsitektur dari CNN yang memiliki 50 lapisan atau layer dan memperkenalkan sebuah konsep baru yaitu *shortcut connections* (He dkk, 2016). Penggunaan *shortcut connection* bertujuan untuk mengatasi masalah *vanishing gradient problem* yang muncul pada proses *training* jaringan *deep learning*. Ketika sebuah jaringan menjadi semakin dalam, dapat timbul masalah *vanishing gradient* yang menyebabkan gradien menjadi sangat kecil. Hal ini dapat berdampak pada penurunan performa atau akurasi jaringan tersebut. Arsitektur ResNet50 yang digunakan dalam penelitian disajikan pada Gambar 2.



Gambar 2. Arsitektur ResNet50

## 2.5 MobileNetV2

Tabel 1. Arsitektur MobileNetV2

Input	Operator	<i>t</i> (faktor ekspansi)	<i>c</i> (jumlah kanal keluaran)	<i>n</i> (jumlah perulangan blok)	<i>s</i> (stride)
$224^2 \times 3$	Conv2d	-	32	1	2
$112^2 \times 32$	Bottleneck	1	16	1	1
$112^2 \times 16$	Bottleneck	6	24	2	2
$56^2 \times 24$	Bottleneck	6	32	3	2
$28^2 \times 32$	Bottleneck	6	64	4	2
$14^2 \times 64$	Bottleneck	6	96	3	1
$14^2 \times 96$	Bottleneck	6	160	3	2
$7^2 \times 160$	Bottleneck	6	320	1	1
$7^2 \times 320$	Conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	Avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	Conv2d 1x1	-	k	-	-

MobileNetV2 yang dikembangkan oleh Sandler (**Sandler dkk, 2018**), merupakan sebuah arsitektur *Convolutional Neural Network* (CNN) berbasis perangkat bergerak yang dirancang untuk mengatasi kebutuhan akan sumber daya komputasi yang terbatas. Arsitektur ini merupakan perbaikan dari arsitektur MobileNet sebelumnya. Salah satu perbedaan utama antara MobileNet dan arsitektur CNN lainnya terletak pada penggunaan lapisan konvolusi atau

*convolution layer*. Pada MobileNetV2, lapisan konvolusi menggunakan filter dengan ketebalan yang sesuai dengan ketebalan gambar *input*. MobileNetV2 menggabungkan *depthwise convolution*, *linear bottleneck*, *pointwise convolution* dan *shortcut connections* antar *bottlenecks* untuk meningkatkan efisiensi dan kinerja jaringan. Detail spesifikasi parameter MobileNetV2 ditunjukkan pada Tabel 1.

## 2.6 Pengumpulan *Dataset*

*Dataset* yang digunakan dalam penelitian ini berupa citra jajanan tradisional Indonesia yang diperoleh melalui berbagai sumber yang tersedia di internet dengan bantuan mesin perambah google. Unduhan dari berbagai sumber kemudian dikompilasi dan menghasilkan lima kelas data yaitu kue cucur, klepon, kue ku, kue talam dan onde-onde. Gambar 3 menunjukkan contoh kelas data yang digunakan dalam penelitian. Total data yang digunakan berjumlah 1400 citra yang dibagi menjadi 1250 citra digunakan untuk data latih dan validasi, serta 250 citra digunakan sebagai data uji. Pada data *training* dan validasi, data terbagi menjadi lima kelas di mana masing-masing kelas terdiri dari 250 citra. Sedangkan pada data uji, setiap kelas terdiri dari 50 citra. *Dataset* dapat diakses melalui link <https://github.com/hysun7/Dataset-Makanan-Tradisional-Indonesia>.



**Gambar 3. Contoh Kelas Data yang Digunakan**

## 2.7 Sistem yang dibangun

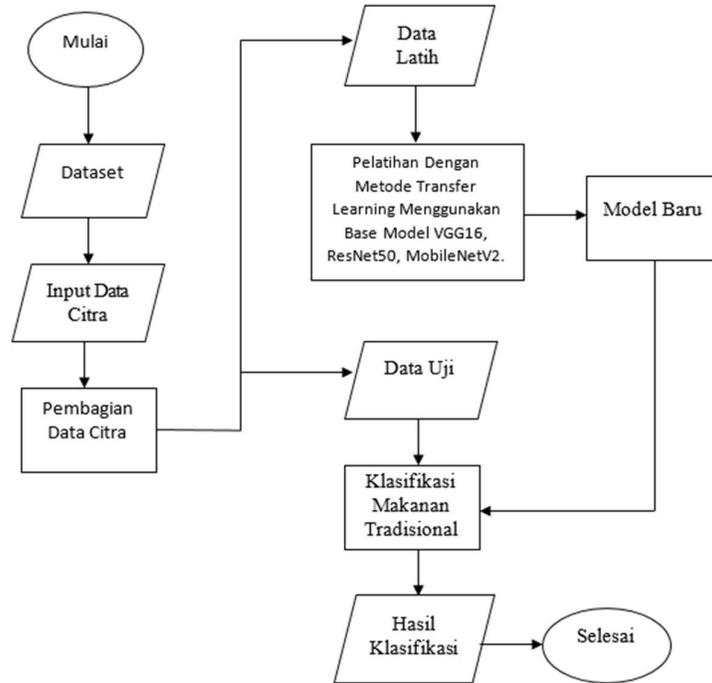
Gambar 4 menunjukkan diagram alir sistem perancangan klasifikasi jenis makanan jajanan tradisional Indonesia dengan CNN menggunakan metode *transfer learning*. Adapun penjelasan dari blok diagram alir sebagai berikut:

Pertama dilakukan pengumpulan *dataset* yaitu jenis makanan jajanan tradisional Indonesia. *Dataset* dikelompokkan menjadi lima kelas yang terdiri dari kue cucur, klepon, kue ku, kue talam dan onde-onde. *Dataset* dibagi menjadi data latih dan data uji. Data latih sebagai data untuk melakukan proses *training*, sedangkan data uji untuk mengevaluasi model yang sudah melakukan proses pelatihan atau *training*.

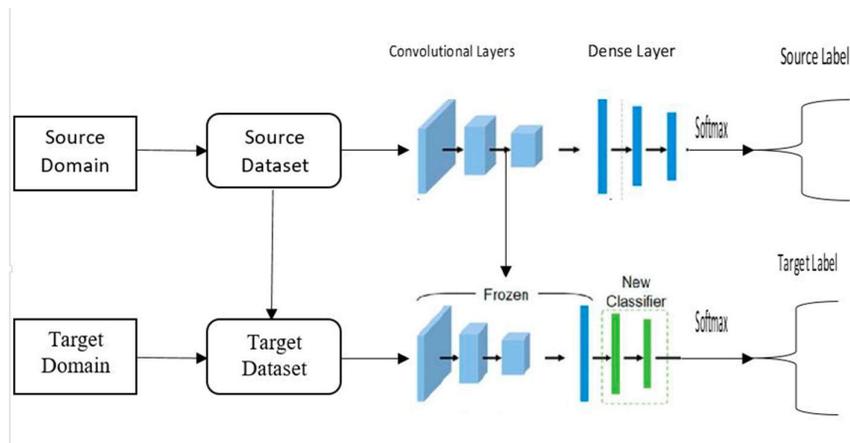
Setelah melakukan proses pembagian data citra, pada data latih akan dilakukan proses *training model* dengan CNN menggunakan metode *transfer learning* dengan menggunakan *base model* seperti yang ditunjukkan pada Gambar 5. Pada penelitian ini, penulis menggunakan tiga *base*

model yaitu MobileNetV2, ResNet50, dan VGG16. Proses *training* dilakukan dengan menggunakan *dataset* makanan yang telah dikurasi sebelumnya. Setelah melakukan proses *training*, maka akan dihasilkan model baru dengan nilai bobot hasil *training*.

Setelah menghasilkan model baru, pada data uji akan melakukan proses evaluasi performa sistem yang sudah ditraining sebelumnya. Dan akan menghasilkan proses pengelompokan atau klasifikasi jenis makanan jajanan tradisional dengan melihat akurasi yang didapatkan.



**Gambar 4. Diagram Alir Sistem**



**Gambar 5. Proses Transfer Learning**

## 2.8 Evaluasi

Pada penelitian ini, parameter akurasi, *precision*, *recall* dan *F1-score* digunakan untuk mengukur seberapa baik performansi sistem yang telah dibuat. Untuk memperoleh pemahaman yang lebih baik tentang metrik yang digunakan, perlu diawali dengan definisi dari istilah-istilah seperti *true positive* (TP), *false positive* (FP), *false negative* (FN), dan *true negative* (TN) yang tercantum dalam *confusion matrix* Tabel 2. *True positive* (TP) merujuk pada data yang benar-benar positif dan berhasil diprediksi dengan benar sebagai positif. Sebaliknya, *true negative* (TN) merujuk pada data yang benar-benar negatif dan berhasil diprediksi dengan benar sebagai negatif.

Namun, terdapat juga *false positive* (FP), yaitu data yang sebenarnya negatif tetapi salah diprediksi sebagai positif. Dalam hal ini, terjadi kesalahan dalam memprediksi data negatif. Sebaliknya, *false negative* (FN) adalah data yang sebenarnya positif tetapi salah diprediksi sebagai negatif. FN merupakan kebalikan dari TP dan menunjukkan kesalahan dalam memprediksi data positif.

**Tabel 2. Confusion Matrix**

		Kelas sebenarnya	
		<i>Positive</i>	<i>Negative</i>
Prediksi	<i>Positive</i>	<i>True Positive</i> (TP)	<i>False Positive</i> (FP)
	<i>Negative</i>	<i>False Negative</i> (FN)	<i>True Negative</i> (TN)

Akurasi didefinisikan sebagai perbandingan antara jumlah prediksi yang benar dengan jumlah total data prediksi. Akurasi dirumuskan sesuai Persamaan (1).

$$Akurasi = \frac{TP+TN}{Total\ Data} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

*Precision* merupakan rasio antara jumlah prediksi benar terhadap suatu label dengan jumlah total prediksi yang benar maupun yang salah terhadap label tersebut, atau dapat dihitung dengan membagi jumlah *True Positive* dengan jumlah *Predicted Positive*. *Precision* dirumuskan sesuai Persamaan (2).

$$Precision = \frac{TP}{FP+TP} \quad (2)$$

*Recall* bertujuan untuk mengukur seberapa baik model dalam menghindari *false negative*, didefinisikan sebagai rasio *True Positive* terhadap *Actual Positive*. Maka *recall* dirumuskan sesuai Persamaan (3).

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

*F1-score* adalah kombinasi rata-rata dari presisi dan *recall*. *F1-score* didefinisikan sesuai Persamaan (4).

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4)$$

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Performansi Sistem

Eksperimen dilakukan menggunakan bahasa pemrograman python dan *library* Keras yang dijalankan pada google colab dengan membandingkan tiga *base model* yaitu MobileNetV2, ResNet50, VGG16. Parameter latih yang digunakan diantaranya *learning rate* 0.001, menggunakan Adam *optimizer*, nilai *weight decay* 0.01 dan *epoch* 10. Hasil simulasi dari ketiga *base-model* ini akan dibandingkan dan dianalisis dengan memperhatikan nilai parameter yang digunakan yaitu *precision*, *recall*, *F-1 score* dan *accuracy*. Untuk evaluasi model menggunakan *confusion matrix*.

**Tabel 3. Hasil Performansi Dengan *Base Model/VGG16***

Kelas	Precision	Recall	F1-Score
Cucur	0.93	0.79	0.86
Klepon	1.00	1.00	1.00
Kue Ku	0.90	1.00	0.95
Kue Talam	0.91	0.97	0.94
Onde-onde	0.94	0.94	0.94

Hasil performansi berdasarkan *precision*, *recall*, dan *F1-score* dengan menggunakan *base model/VGG16* ditunjukkan pada Tabel 3. Untuk kelas cucur mendapatkan nilai *precision* 0.93 atau 93%, *Recall* 0.79 atau 79%, *F1-score* 0.86 atau 86%. Untuk kelas klepon masing-masing parameter bernilai 100%, Untuk kue ku mendapatkan *precision* 90%, *Recall* 100%, *F1-score* 95%. Untuk kue talam mendapatkan *precision* 91%, *Recall* 97% dan *F1-score* 94% dan untuk onde-onde mendapatkan 94% untuk *precision*, *recall* dan *F1-score*.

**Tabel 4. Hasil Performansi Dengan *Base Model/ResNet50***

Kelas	Precision	Recall	F1-Score
Cucur	0.94	0.97	0.96
Klepon	1.00	0.96	0.98
Kue Ku	1.00	1.00	1.00
Kue Talam	0.97	0.97	0.97
Onde-onde	0.97	0.97	0.97

Pada Tabel 4 ditampilkan hasil klasifikasi dengan menggunakan *base model/ResNet50*. Untuk cucur mendapatkan nilai *precision* 94%, *Recall* 97%, *F1-score* 96%. Untuk klepon mendapatkan *precision* 100%, *Recall* 96%, *F1-score* 98%. Untuk kue ku mendapatkan *precision*, *Recall* dan *F1-score* masing-masing mendapatkan 100%. Untuk kue talam masing-masing mendapatkan 97% dan untuk onde-onde masing-masing mendapatkan 97%.

**Tabel 5. Hasil Performansi dengan *Base Model* Mobilenetv2**

Kelas	Precision	Recall	F1-Score
Cucur	0.97	0.97	0.97
Klepon	1.00	0.96	0.98
Kue Ku	1.00	1.00	1.00
Kue Talam	0.94	1.00	0.97
Onde-onde	1.00	0.97	0.99

Sedangkan dengan menggunakan *base-model* MobileNetV2 hasil performansi berdasarkan *precision*, *recall*, dan *F1-score* ditunjukkan pada Tabel 5. Kelas cucur mendapatkan nilai *precision*, *Recall* dan *F1-score* masing-masing mendapatkan 0.97 yang artinya 97%. Untuk klepon mendapatkan *precision* 100%, *Recall* 96%, *F1-score* 98%. Untuk kue ku mendapatkan *precision*, *Recall* dan *F1-score* masing-masing mendapatkan 100%. Untuk kue talam mendapatkan *precision* 94%, *Recall* 100% dan *F1-score* 97% dan untuk onde-onde mendapatkan *precision* 100%, *Recall* 97% dan *F1-score* 99%.

**Tabel 6. Hasil Performansi untuk Semua *Base Model* Berdasarkan Rata-Rata Nilai *Precision*, *Recall* Dan *F1-Score***

Model	Precision	Recall	F1-score
VGG16	0.936	0.94	0.938
ResNet50	0.976	0.974	0.976
MobileNetV2	0.982	0.98	0.982

Nilai rata-rata nilai *precision*, *recall* dan *F1-score* untuk *base-model* VGG16, ResNet50 dan MobileNetV2 ditunjukkan pada Tabel 6. Dari tabel terlihat bahwa sistem yang menggunakan *base-model* MobileNetV2 menghasilkan nilai *precision*, *recall* dan *F1-score* dengan nilai 0.982, 0.987 dan 0.982 untuk rata-rata nilai *precision*, *recall* dan *F1-score* secara berurut, paling tinggi jika dibandingkan sistem yang menggunakan *base model* ResNet50 dan MobileNetV2.

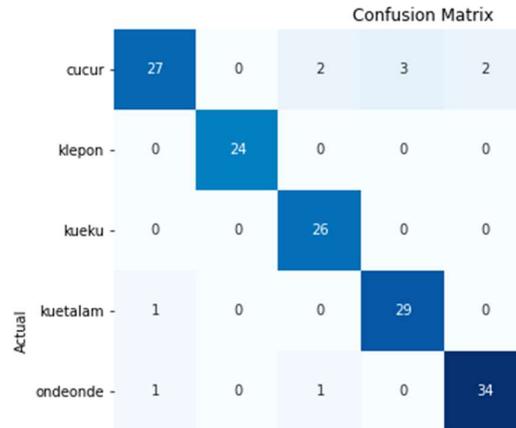
**Tabel 7. Perbandingan Akurasi Pengujian Berdasarkan *Base Model***

Model	Jumlah Parameter	Akurasi
VGG16	14,797,509	93.33%
ResNet50	23,867,141	97.33%
MobileNetV2	2,439,109	98.00%

Hasil akurasi yang didapatkan pada setiap model ditunjukkan pada Tabel 7. Sistem dengan *base model* MobileNetV2 yang memiliki jumlah parameter yang paling sedikit menghasilkan akurasi sebesar 98%. Hasil ini merupakan yang tertinggi dibandingkan VGG16 yang menghasilkan akurasi 93.33% dan ResNet50 yang menghasilkan akurasi 97.33%.

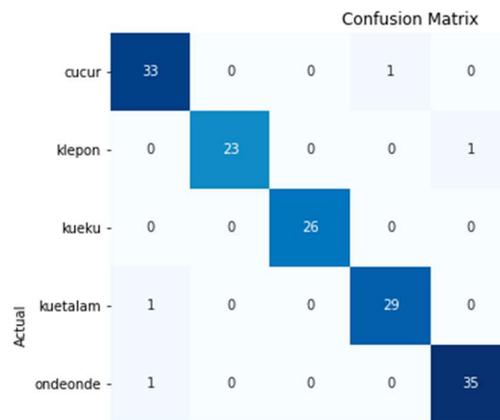
### 3.2 Confusion Matrix

Pada bagian ini akan ditampilkan hasil evaluasi model menggunakan *confusion matrix*. Terdapat tiga model yang digunakan yaitu hasil *confusion matrix* MobileNetV2, ResNet50, dan VGG16.



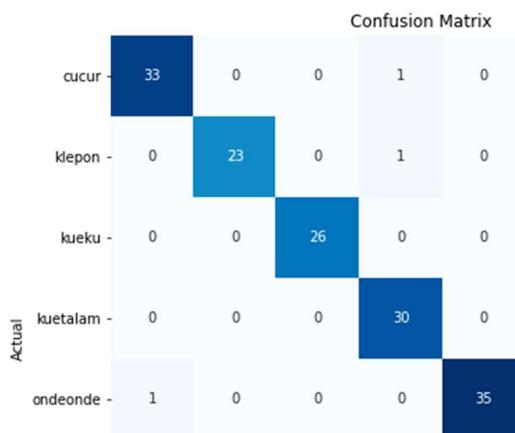
**Gambar 6. Confusion Matrix untuk Base Model VGG16**

Gambar 6 menampilkan hasil evaluasi base model VGG16 yang ditunjukkan dengan *confusion matrix*. Terdeteksi kesalahan berjumlah sepuluh data yaitu kue cucur terdeteksi sebagai kue talam sebanyak dua data, kue cucur sebagai kue talam sebanyak tiga data, kue cucur sebagai onde-onde berjumlah dua data, satu data kue talam terdeteksi sebagai cucur, dan satu onde-onde terdeteksi sebagai kue ku.



**Gambar 7. Confusion Matrix untuk Base Model Resnet50**

*Confusion matrix* untuk *base model* ResNet50 yang ditunjukkan pada Gambar 7 menampilkan kesalahan deteksi data berjumlah empat data yaitu kue cucur terdeteksi sebagai kue talam, klepon sebagai onde-onde, kue talam sebagai cucur, dan onde-onde sebagai cucur.



**Gambar 8. Confusion Matrix untuk Base Model MobileNetV2**

Pada Gambar 8, *confusion matrix* dengan *base model* MobileNetV2, terdeteksi kesalahan berjumlah tiga data yaitu cucur yang terdeteksi sebagai kue talam, klepon terdeteksi sebagai kue talam, dan onde-onde terdeteksi sebagai cucur.

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasi jenis jajanan tradisional Indonesia secara otomatis berdasarkan citra menggunakan arsitektur *deep learning*. Metode *transfer learning* digunakan dalam penelitian ini untuk melatih ulang *base-network* agar dapat mengenali citra jajanan tradisional Indonesia. Terdapat lima kelas yang diuji yaitu kue cucur, klepon, kue ku, kue talam dan onde-onde. Hasil penelitian menunjukkan bahwa walaupun memiliki jumlah parameter yang paling sedikit yaitu sekitar 2 juta parameter, penggunaan *base-model* MobileNetV2 menghasilkan akurasi uji tertinggi sebesar 98%, dibandingkan dengan menggunakan ResNet50 dan VGG16 yang masing-masing menghasilkan akurasi uji 97.33% dan 93.33%. Penelitian ini memberikan kontribusi dalam melestarikan dan membantu masyarakat, terutama kaum muda, untuk mengenali ragam jajanan tradisional Indonesia yang berharga dan penting sebagai warisan budaya.

#### DAFTAR RUJUKAN

- Fahira, P. K., Rahmadhani, Z. P., Mursanto, P., Wibisono, A., & Wisesa, H. A. (2020). Classical Machine Learning Classification for Javanese Traditional Food Image. *ICICoS 2020 - Proceeding: 4th International Conference on Informatics and Computational Sciences*, (pp.1–5). <https://doi.org/10.1109/ICICoS51170.2020.9299039>
- Febriani, F. D., Sari, Y. A., & Wihandika, R. C. (2019). Klasifikasi Citra Kue Tradisional Indonesia Berdasarkan Ekstraksi Fitur Warna RGB Color Moment Menggunakan K-Nearest Neighbor. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(10), 10199–10206.

- Hariman, A. A., Mulyana, D. I., & Yel, M. B. (2023). Klasifikasi Jajanan Tradisional Jawa Tengah dengan Metode Transfer Learning dan MobileNetV2. *Jurnal Informasi Interaktif*, 8(1), 15–23.
- Hariyani, Y. S., Eom, H., & Park, C. (2020). DA-Capnet: Dual Attention Deep Learning Based on U-Net for Nailfold Capillary Segmentation. *IEEE Access*, 8, 10543–10553. <https://doi.org/10.1109/ACCESS.2020.2965651>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 2261–2269). <https://doi.org/10.1109/CVPR.2017.243>
- Kakani, V., Nguyen, V. H., Kumar, B. P., Kim, H., & Pasupuleti, V. R. (2020). A critical review on computer vision and artificial intelligence in food industry. *Journal of Agriculture and Food Research*, 2, 1–12. <https://doi.org/10.1016/j.jafr.2020.100033>
- Kaur, G., Sinha, R., Tiwari, P. K., Yadav, S. K., Pandey, P., Raj, R., Vashisth, A., & Rakhra, M. (2022). Face mask recognition system using CNN model. *Neuroscience Informatics*, 2(3), 100035. <https://doi.org/10.1016/j.neuri.2021.100035>
- Matsuzaka, Y., & Yashiro, R. (2023). AI-Based Computer Vision Techniques and Expert Systems. *Ai*, 4(1), 289–302. <https://doi.org/10.3390/ai4010013>
- Muslika, Irianti, A., & Sulfayanti. (2022). Klasifikasi Makanan Tradisional Mandar Menggunakan Ekstraksi Fitur Warna Dan Tekstur Dengan Metode K-Nearest Neighbour. *Prosiding Seminar Nasional Energi, Kelistrikan, Teknik dan Informatika*, 3, (pp. 60).
- Nahak, H. M. I. (2019). Upaya Melestarikan Budaya Indonesia Di Era Globalisasi. *Jurnal Sosiologi Nusantara*, 5(1), 65–76. <https://doi.org/10.33369/jsn.5.1.65-76>
- Putri, R. D., Tiurma, & Himawan. (2021). Traditional Food Serves In Wedding Ceremony As Cultural Heritage In Nagari Balahaie Kabupaten Padang Pariaman. *Journal Food and Beverage, Product and Services, Accommodation Industry, Entertainment*, 4(2), 1–18.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 4510–4520).
- Sarwinda, D., Argyadiva, T., Saragih, L. B. S., Oktareza, M., Handi Bagus, P., Fauzan, F., & Erickson, B. (2020). Automatic Multi-class Classification of Indonesian Traditional Food

- using Convolutional Neural Networks. *2020 3rd International Conference on Computer and Informatics Engineering, IC2IE 2020*, (pp. 43–47). <https://doi.org/10.1109/IC2IE50715.2020.9274636>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations (ICLR 2015)*, (pp. 1-14).
- Subhi, M. A., & Md. Ali, S. (2018). A Deep Convolutional Neural Network for Food Detection and Recognition. *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, (pp. 284–287). <https://doi.org/10.1109/IECBES.2018.8626720>
- Vankdothu, R., Hameed, M. A., & Fatima, H. (2022). A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method. *Computers and Electrical Engineering*, *101*, 107960. <https://doi.org/10.1016/j.compeleceng.2022.107960>
- Waluyo, G. B., Sari, Y. A., & Rahayudi, B. (2021). Pengenalan Citra Makanan Kue Tradisional menggunakan Ekstraksi Fitur HSV Color Moment dan Local Binary Pattern dengan K-Nearest Neighbour. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, *5*(12), 5641–5649.
- Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, *4*(December 2020), 233–249. <https://doi.org/10.1016/j.crfs.2021.03.009>