

# Klasifikasi Citra Makanan Selingan Khas Indonesia dengan *Convolutional Neural Network*

## *Image Classification of Indonesian Snacks using Convolutional Neural Network*

<sup>1</sup>Kunti Eliyen\*, <sup>2</sup>Abidatul Izzah, <sup>3</sup>Fikha Rizky Aullia

<sup>1,2,3</sup>Manajemen Informatika, PSDKU Politeknik Negeri Malang di Kota Kediri, Indonesia

\*e-mail: [kunti.eliyen@polinema.ac.id](mailto:kunti.eliyen@polinema.ac.id)

(received: 28 September 2024, revised: 7 March 2025, accepted: 16 March 2025)

### Abstrak

Kuliner setiap daerah memiliki ciri khas dan keunikan masing-masing. Namun masih banyak masyarakat yang belum mengenal nama makanan selingan khas Indonesia terlebih untuk makanan yang tidak berasal dari asal daerahnya. Promosi makanan selingan khas Indonesia sejatinya sangat diperlukan sebagai langkah awal untuk edukasi keragaman Indonesia baik kepada masyarakat Indonesia maupun internasional karena kuliner merupakan salah satu factor yang juga dapat menarik minat wisatawan untuk berkunjung ke suatu daerah. Salah satu cara untuk menyelesaikan masalah tersebut dengan melakukan klasifikasi citra makanan selingan khas Indonesia dengan mengimplementasikan *Convolutional Neural Network (CNN)*. Penelitian ini menggunakan dataset citra sebanyak 30 data untuk 10 kelas dan setiap kelas terdapat 3 citra. Training model dilakukan dengan *epoch* = 40 menghasilkan akurasi 86%. Pengujian data menghasilkan *recall* sebesar 86%, *precision* sebesar 91% dan F1 Score 88%.

**Kata kunci:** klasifikasi citra, makanan selingan, *convolutional neural network*

### Abstract

*Each region in Indonesia has its own unique and distinctive culinary traditions. However, many people are still unfamiliar with the names of traditional Indonesian snacks, especially those that originate from regions other than their own. Promoting these traditional snacks is essential as an initial step in educating both domestic and international audiences about Indonesia's cultural diversity. Culinary heritage is also a key factor in attracting tourists to visit a region. One way to address this issue is through image classification of Indonesian traditional snacks using Convolutional Neural Networks (CNN). This study uses a dataset consisting of 30 images across 10 classes, with 3 images per class. The model was trained over 40 epochs and achieved an accuracy of 86%. The testing phase yielded a recall of 86%, precision of 91%, and an F1-score of 88%.*

**Keywords:** image classification, snack, convolutional neural network

## 1 Pendahuluan

Keberagaman bangsa Indonesia tidak hanya ditunjukkan dari budaya, suku, ras, agama, dan bahasa daerah saja, namun juga dikenal dengan beragam kuliner mulai dari makanan utama hingga makanan ringan. Kuliner setiap daerah memiliki ciri khas dan keunikan masing-masing. Hidangan utama Indonesia yang sangat populer seperti nasi goreng dan rendang. Sedangkan makanan selingan atau jajanan Indonesia yang populer adalah pempek, cireng, seblak, dan lain-lain. Promosi jajanan khas Indonesia hingga ke tingkat internasional tentunya kurang signifikan. Makanan merupakan faktor kunci dalam menarik minat wisatawan asing terhadap Indonesia dan hal ini dapat dicapai melalui berbagai festival bertaraf internasional serta dukungan dari pemerintah terkait. Teknologi berkembang dengan pesat, promosi pangan Indonesia melalui computer vision menggunakan

pengolahan citra digital dengan pembelajaran mendalam untuk mengidentifikasi pangan dengan sistem klasifikasi adalah salah satu solusi terbaik dalam hal ini.

Pemrosesan citra mencakup berbagai teknik yang dirancang untuk meningkatkan kualitas citra digital, mengekstrak informasi berharga, dan memberikan pemahaman lebih dalam tentang struktur citra yang mendasarinya [1]. Computer vision adalah pengembangan dalam ilmu computer yang menggabungkan teknologi kecerdasan buatan yang menjadikan computer dapat memahami dan menganalisis informasi visual dari data yang dimasukkan. Teknik pembelajaran mendalam dapat digunakan untuk secara otomatis mengekstraksi karakteristik dari data pelatihan yang tidak dibuat oleh insinyur manusia. Hal ini dicapai dengan mengintegrasikan teknik computer vision dengan pendekatan pembelajaran mendalam [2].

Penerapan *deep learning* merupakan cara yang tepat untuk melakukan pengolahan citra digital untuk klasifikasi pangan. *Deep learning* adalah metode kecerdasan buatan memberikan perintah pada komputer yang dipacu oleh bagaimana otak manusia bekerja. Model pembelajaran mendalam mampu mengenali pola kompleks dalam citra, teks, suara, dan data lainnya untuk menghasilkan wawasan dan prediksi yang akurat. Kegunaan *deep learning* adalah untuk menyelesaikan tugas secara otomatis seperti memaparkan objek atau citra, di mana kemampuan ini berdasar pada kecerdasan manusia [3]. Teknologi yang mendasari *deep learning* adalah jaringan saraf, jaringan ini terdiri dari node atau neuron yang saling berhubungan dalam struktur berlapis.

Node memproses data dalam sistem yang terkoordinasi dan adaptif. Node-node ini bertukar umpan balik mengenai output yang dihasilkan, menentukan kesalahan, dan melakukan perbaikan berkelanjutan. Dengan demikian, jaringan saraf tiruan adalah inti dari sistem pembelajaran mendalam. Di antara jaringan pembelajaran mendalam, Convolutional Neural Networks (CNN) adalah yang paling banyak digunakan dan disukai. Pembelajaran mendalam cukup terkenal akhir-akhir ini karena CNN. Keunggulan utama CNN dibandingkan pendahulunya adalah ia dapat mengidentifikasi aspek-aspek penting secara otomatis, tanpa pengawasan manusia, menjadikannya yang paling populer. Mirip dengan jaringan saraf tradisional, struktur CNN dimodelkan oleh neuron yang ditemukan di otak manusia dan hewan lainnya. Lebih tepatnya, CNN mensimulasikan rangkaian sel rumit yang membentuk korteks visual di otak kucing [4].

Tujuan penelitian ini adalah untuk penerapan metode CNN dalam melakukan klasifikasi citra makanan selingan khas Indonesia dengan bertujuan untuk memperkenalkan nama makanan selingan khas Indonesia dengan harapan makanan khas Indonesia dapat lebih dikenali oleh masyarakat luas baik di dalam dan luar negeri. Pemilihan metode CNN untuk klasifikasi pada penelitian ini dikarenakan CNN merupakan metode yang dapat melakukan ekstraksi fitur citra secara otomatis dalam komputasinya.

## 2 Tinjauan Literatur

Beberapa penelitian telah dilakukan tentang klasifikasi citra menggunakan CNN. Penelitian “Klasifikasi Citra Makanan Berdasarkan Asal Daerah Menggunakan Convolutional Neural Network” data yang digunakan adalah citra makanan, output yang diperoleh adalah klasifikasi jenis makanan untuk mengetahui asal daerah makanan tersebut [5]. Penelitian ini mempunyai nilai recall sebesar 41,46% untuk kelas Jawa dan 83,67% untuk kelas Sumatera. Hal ini menunjukkan bahwa model tersebut cenderung lebih baik dalam mengidentifikasi makanan khas Pulau Sumatera dibandingkan Pulau Jawa. Hal ini dikarenakan jumlah sampel dataset makanan Sumatera lebih banyak dibandingkan makanan Jawa. Model cenderung lebih banyak mempelajari ciri-ciri atau bentuk makanan yang berasal dari Pulau Sumatera, sehingga hasil recall pada kelas Sumatera lebih tinggi dibandingkan dengan kelas Jawa, artinya model lebih baik dalam mengenali kelas mayoritas. Penelitian “Klasifikasi Tipe Kematangan Pisang Menggunakan Metode Ensemble Convolutional Neural Network (CNN)”, data yang digunakan berupa citra buah pisang untuk menentukan tipe kematangan pisang yang terdiri dari buatan dan alami [6]. Dataset yang digunakan terdiri dari 11666 citra yang diklasifikasikan ke dalam 12 kelas yang menghasilkan akurasi sebesar 90,92%. Pada penelitian “Klasifikasi Menggunakan Convolutional Neural Network (CNN) pada Screenshot Halaman Instagram” data citra yang digunakan adalah citra screenshot pada halaman Instagram [7]. Penelitian bertujuan untuk menentukan niche akun berdasarkan foto yang diunggah ke akun Instagram pada kategori kecantikan, kebugaran, makanan, keluarga, dan fashion. Hasil penelitian ini adalah nilai akurasi sebesar 91%,

presisi sebesar 93%, recall sebesar 90% dan F1-Score sebesar 91%. Pengujian model mendapatkan hasil maksimal pada kategori makanan [7]. Penelitian “Klasifikasi Citra Ikan Menggunakan Convolutional Neural Networks” menggunakan citra ikan sebagai data pembelajaran [8]. Penelitian bertujuan untuk menentukan nama ikan berdasarkan dan diperoleh hasil sebesar 99,13% dan 99,11% untuk nilai presisi dan recall.

Penelitian yang telah dilakukan [5] mengklasifikasikan citra makanan untuk menentukan asal daerah dengan menggunakan CNN dengan mengidentifikasi makanan Jawa dan Sumatra. Penelitian Wardani [6] mengklasifikasikan citra buah pisang untuk menentukan tipe kematangan dengan CNN. Pada penelitian Kholik [7] mengklasifikasikan niche akun Instagram menggunakan CNN dengan dataset halaman akun Instagram. Dapat diketahui bahwa penelitian-penelitian yang telah dilakukan mengimplementasikan CNN untuk klasifikasi citra sehingga pada penelitian ini akan dilakukan klasifikasi dengan dataset citra makanan selingan menggunakan CNN.

### 3 Metode Penelitian

Metode penelitian yang dilakukan terdiri dari tiga langkah seperti pada Gambar 1



Gambar 1. Tahap penelitian

Tahap penelitian yang ditunjukkan pada Gambar 1 meliputi pengambilan data, Klasifikasi dan Pengujian yang akan dijabarkan berikut:

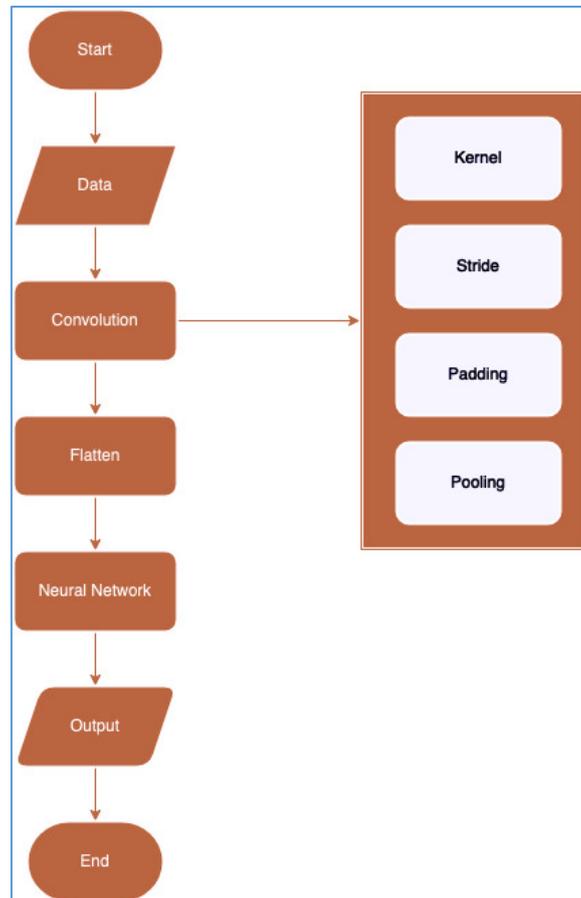
#### 1. Pengambilan Data

Dalam proses *deep learning*, dataset merupakan elemen utama untuk memperoleh hasil yang diharapkan. Semakin banyak dataset yang digunakan maka semakin baik pula hasil pembelajarannya. Kumpulan data pelatihan biasanya digunakan untuk mendukung proses machine learning dengan membaca atau mengidentifikasi jenis data tertentu dalam model AI yang didukung oleh prinsip machine learning. Singkatnya, algoritma *machine learning* bekerja dengan mempelajari data, menentukan hubungan, menghasilkan pemahaman, membuat keputusan, dan mengevaluasi dari data pelatihan yang ditugaskan kepada mereka [9].

Data citra diperlukan untuk pemrosesan computer vision untuk mengevaluasi algoritma atau model dalam komputasi pemrosesan citra [10]. Pada penelitian ini, citra jajanan khas Indonesia digunakan sebagai dataset. Citra diperoleh dari sumber gratis di internet. Jumlah kelas yang digunakan untuk menampungnya ada sepuluh dengan total 30 citra dengan masing-masing kelas terdapat 3 citra.

#### 2. Klasifikasi

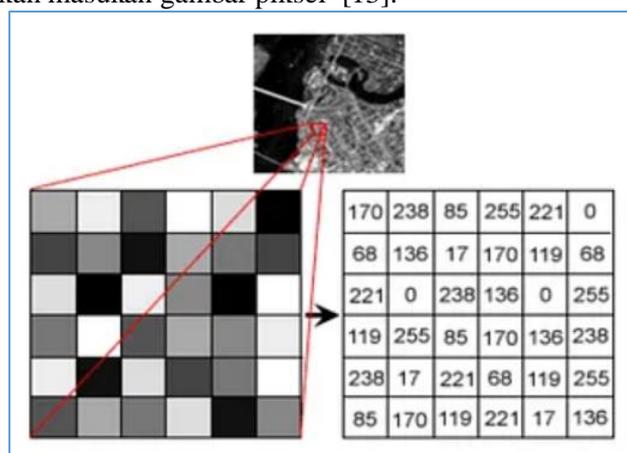
Klasifikasi merupakan sebuah proses mengelompokkan objek sesuai dengan karakteristik yang sama. Klasifikasi citra merupakan teknik untuk mengkategorikan citra berdasarkan persamaan yang dimiliki oleh citra ke dalam kelas tertentu [11]. CNN diimplementasikan untuk proses klasifikasi pada penelitian ini. Gambar 2 menggambarkan alur proses pada CNN untuk klasifikasi citra.



**Gambar 2.** Alur proses *convolutional neural network*

*a. Convolutional Layer*

Bagian mendasar dari CNN adalah lapisan konvolusional, karena lapisan ini berisi sekumpulan proses (kernel) sebelum data digunakan [12]. Suatu gambar dibaca oleh mesin sebagai matriks yang merupakan kumpulan angka seperti yang ditunjukkan pada Gambar 3. Angka-angka tersebut mewakili piksel gambar sebagai intensitas cahaya pada suatu titik tertentu. Lapisan ini diberi filter kernel untuk menentukan masukan gambar piksel [13].



**Gambar 3.** Pixel

*b. Kernel*

Kernel menentukan nilai diskrit atau bilangan bulat [12]. Kernel adalah matriks berukuran  $n \times n$  yang digunakan untuk mengekstrak fitur dari matriks piksel gambar. Kernel bekerja dengan produk titik dari setiap wilayah data masukan. Perkalian titik dalam matematika adalah operasi

aljabar yang mencakup dua barisan bilangan yang panjangnya sama (biasanya vektor koordinat) dan menghasilkan satu bilangan [].

c. *Stride*

Stride merupakan Parameter yang mengatur seberapa besar pergeseran filter. Semakin kecil ukuran langkahnya, semakin banyak informasi yang bisa diambil dari input, namun ini akan membutuhkan lebih banyak proses komputasi dibandingkan dengan ukuran langkah yang lebih besar [14]. Proses perpindahan langkahnya dilakukan dimulai dari kiri ke kanan lalu naik ke bawah sebanyak nilai langkahnya.

d. *Padding*

Padding merupakan proses penambahan lapisan ekstra pada tepi citra dapat dilakukan dengan memperbesar ukuran piksel berdasarkan nilai-nilai di sekitar data masukan, sehingga area reseptif yang dihasilkan tidak terlalu kecil dan informasi tidak banyak yang hilang. Biasanya, nilai ini adalah nol, yang dikenal sebagai zero padding. Proses konvolusi ini menghasilkan output yang akan digunakan sebagai input untuk lapisan konvolusi berikutnya [15]

e. *Pooling*

Lapisan ini digunakan untuk meminimalkan dimensi *feature map* sehingga proses komputasi dapat lebih cepas karena melibatkan lebih sedikit parameter yang perlu diperbarui dan juga membantu mengatasi overfitting. Pada proses pooling, nilai yang diambil adalah nilai tertinggi dari area filter, yang dikenal sebagai max pooling [15].

f. *Flatten*

Flatten adalah proses mengubah matriks menjadi kolom agar sesuai dengan arsitektur jaringan. Diketahui masukan dari jaringan syaraf tiruan adalah neuron yang berbentuk vektor. Oleh karena itu, jika sebelumnya feature map berbentuk matriks, maka perlu diubah menjadi vektor.

g. *Neural Network*

Arsitektur jaringan syaraf tiruan terdiri dari tiga lapisan yaitu *input layer*, *hidden layer* dan *output layer*. Data yang digunakan pada *input layer* merupakan hasil proses perataan, pada lapisan inilah *input* diolah, dianalisis dan diteruskan ke lapisan berikutnya. *Hidden layer* memproses *input* dari *input layer* atau dari *hidden layer* lainnya. Pada lapisan ini *output* dari lapisan sebelumnya diolah dan diteruskan ke lapisan berikutnya. Lapisan selanjutnya adalah *output layer* yang memberikan hasil akhir pengolahan data dari lapisan sebelumnya. Node yang dihasilkan oleh *output layer* dapat terdiri dari satu atau lebih node. Biasanya, ketika jaringan saraf memecahkan masalah multiclass, lapisan keluaran memiliki banyak node.

3. Pengujian

Tahap selanjutnya setelah implementasi metode CNN untuk klasifikasi citra adalah melakukan pengujian pada data training. Pengujian dilakukan dengan menghitung nilai *accuracy*, *precision*, *recall* dan *F1 Score* dengan menggunakan *Confusion Matrix*.

a. *Accuracy*

*Accuracy* merupakan nilai perbandingan yang menunjukkan kebenaran prediksi dari seluruh data. Akurasi dihitung dengan persamaan 1. Nilai ini menunjukkan ketepatan model klasifikasi (Serafim). Perhitungan *accuracy* diperoleh dengan menggunakan formula berikut:

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

b. *Precision*

*Precision* merupakan nilai perbandingan dari prediksi yang benar positif dengan total hasil yang diprediksi positif yang dihitung dengan persamaan 2. *Precision* mengandung nilai yang menunjukkan ketepatan data dengan hasil prediksi yang diperoleh dari model pada proses klasifikasi. Perhitungan *precision* dihitung dengan menggunakan formula berikut:

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

c. *Recall*

*Recall* merupakan perbandingan dari nilai data yang prediksi benar positif dengan total data yang benar positif yang dihitung dengan persamaan 3. Nilai *recall* dapat dihitung dengan formula berikut:

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

d. *F1 Score*

*F1 Score* merupakan nilai rata-rata dari *precision* dan *recall* yang dihitung dengan persamaan 4. Nilai ini menunjukkan kesepadanan dari nilai *precision* dan *recall*. *F1 Score* dapat dihitung dengan formula berikut:

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

#### 4 Hasil dan Pembahasan

Pada penelitian ini digunakan data primer dengan total 30 citra makanan selingan yang dibagi menjadi 10 kelas, dimulai dengan kelas berindeks 0 yaitu kelas dodol galamai, emping kerupuk melinjo, enting wijen, es krim, geblek, gethuk goreng, gethuk singkong, gurandil, jagung gerontol, kacang tanah rebus.

Keseluruhan data citra dikonversi ke DataFrame supaya arsitektur CNN dapat mempelajari label pada dataset. Gambar 4 merupakan hasil konversi dataset citra ke DataFrame. Hasil konversi ditunjukkan dengan filepaths dan labels masing-masing kelas dataset yang ditampilkan tidak berurutan.

```
filepaths labels
0 /Users/macbookair/Desktop/python/CNN/dataset_n... 7. Gurandil
1 /Users/macbookair/Desktop/python/CNN/dataset_n... 7. Gurandil
2 /Users/macbookair/Desktop/python/CNN/dataset_n... 7. Gurandil
3 /Users/macbookair/Desktop/python/CNN/dataset_n... 4. Geblek
4 /Users/macbookair/Desktop/python/CNN/dataset_n... 4. Geblek
7. Gurandil 3
4. Geblek 3
5. Gethuk Goreng 3
2. Enting wijen 3
9. Kacang Tanah Rebus 3
3. Es Krim 3
0. Dodol galamai 3
8. Jagung Gerontol 3
1. Emping kerupuk mlinjo 3
6. Gethuk Singkong 3
Name: labels, dtype: int64
```

Gambar 4. Konversi ke dataframe

Pemisahan dataset atau *split dataset* bertujuan untuk membagi data menjadi beberapa bagian yang membentuk sub himpunan data. Dataset kemudian di-*split* dengan perbandingan 8:1:1, 80% digunakan untuk data training, 10% untuk data testing dan 10% untuk data validasi. Sehingga diperoleh 24 citra untuk data training, 3 citra untuk data testing dan 3 citra untuk data validasi. Gambar 5 menunjukkan hasil pembagian dataset pada program.

```
train_df length: 24 test_df length: 3 valid_df length: 3
```

Gambar 5. Pembagian dataset

Proses training data nantinya akan bergantung dengan data input yang diolah. Oleh karena itu, agar proses *training* dapat lebih cepat dalam komputasinya maka perlu dilakukan proses *resize* ukuran gambar untuk semua data meliputi height yaitu ukuran tinggi citra, width yaitu ukuran lebar dan channels yaitu banyaknya angka yang digunakan untuk menentukan warna setiap *pixel*. Gambar 6 merupakan kode yang digunakan untuk melakukan *resize* citra pada python.

```
height=224
width=224
channels=3
batch_size=128
img_shape=(height, width, channels)
img_size=(height, width)
length=len(test_df)
test_batch_size=sorted([int(length/n) for n in range(1,length+1)
                        if length % n ==0 and length/n<=80],reverse=True)[0]
test_steps=int(length/test_batch_size)
print ( 'test batch size: ',test_batch_size, ' test steps: ', test_steps)
```

Gambar 6. Kode resize data citra

Selanjutnya dalam pembuatan arsitektur CNN pada penelitian ini memanfaatkan library Keras dengan menggunakan fungsi Conv2D, MaxPool2D, Dropout, Flatten, dan Dense. Fungsi Conv2D adalah fungsi yang dapat membuat jaringan konvolusi, dengan mengeksplorasi pola citra input dengan menjalankan serangkaian filter yang dapat dieksplorasi pada citra input. Parameter yang ditentukan pada Conv2D adalah filter, kernel aktivasi, dan strides dengan nilai 32, 3, ReLu (Rectified Linear

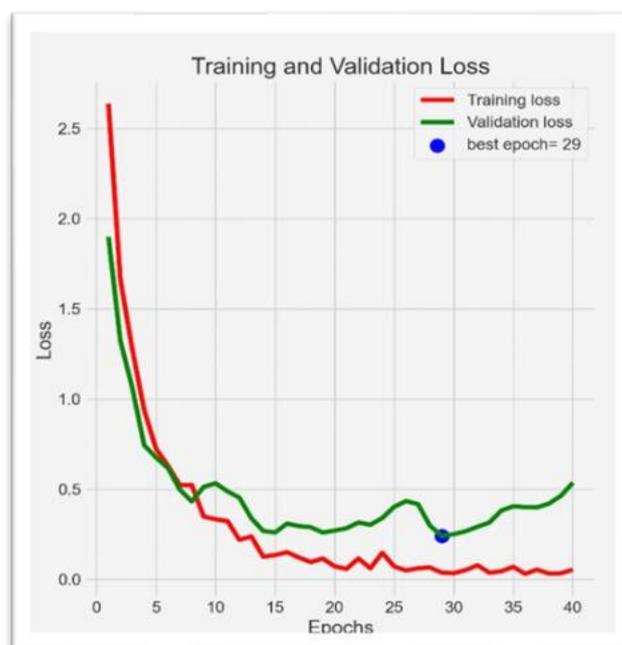
Unit) dan 1. Fungsi MaxPool2D terdapat pada pooling layer dengan parameter pool\_size dan stride yang akan bergeser pada seluruh area *feature map*. Selanjutnya fungsi Dropout pada dropout layer agar dalam pelatihan CNN tidak terjadi overfitting [16] pada data training dan memaksimalkan pembelajaran yang proporsional pada awal training. Kemudian citra input diubah menjadi array satu dimensi menggunakan fungsi Flatten. Selanjutnya, Dense layer merupakan layer pada tahap akhir dari *neural network* untuk mengklasifikasi data, seperti data gambar atau data prediksi. Pada dense layer ini nilai activation yang digunakan adalah softmax. Activation sendiri merupakan fungsi untuk mengonversi agar output pada suatu lapisan dapat diproses pada lapisan selanjutnya. Softmax sering digunakan sebagai aktivasi lapisan terakhir jaringan klasifikasi karena hasilnya dapat diinterpretasikan sebagai distribusi probabilitas.

Setelah membangun arsitektur CNN kemudian meng-*compile* model dengan parameter optimizer, loss, dan metrics. Optimizer merupakan teknik atau algoritma yang digunakan untuk mengurangi kesalahan dengan mengatur berbagai parameter dan bobot, sehingga meminimalkan kesalahan dan memberikan akurasi yang lebih tepat. Pada penelitian ini optimizer yang digunakan adalah Adam optimizer dengan nilai learning rate 0,001. Loss function merupakan fungsi untuk menghitung kesalahan prediksi. Loss function yang digunakan adalah cross entropy, karena fungsi ini yang sering digunakan dalam masalah klasifikasi multiclass dan multilabel. Metrics yang digunakan adalah accuracy untuk menghitung seberapa sering prediksi sesuai dengan label. Gambar 7 menunjukkan komponen model CNN yang diimplementasikan dalam klasifikasi citra.

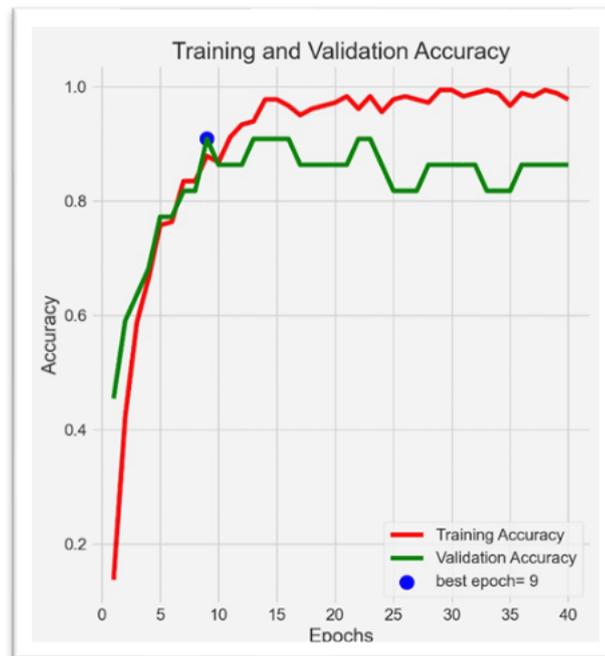
Layer (type)	Output Shape	Param #
xception (Functional)	(None, 7, 7, 2048)	20861480
conv2d_4 (Conv2D)	(None, 7, 7, 32)	589856
max_pooling2d (MaxPooling2D)	(None, 3, 3, 32)	0
dropout (Dropout)	(None, 3, 3, 32)	0
flatten (Flatten)	(None, 288)	0
dense (Dense)	(None, 10)	2890

**Gambar 7. Komponen model CNN**

Tahap selanjutnya adalah *fitting model* untuk *training* data citra dengan model. Pada fitting model ini digunakan parameter batch\_size dan epoch dengan nilai 32 dan 40. Fitting model menghasilkan nilai loss dan akurasi pada Gambar 8 dan Gambar 9.



**Gambar 8. Grafik nilai loss dengan epoch 40**



**Gambar 9. Grafik nilai akurasi dengan epoch 40**

Gambar 8 menunjukkan grafik nilai *loss* dengan epoch 40, nilai *loss* yang terbaik adalah nilai yang terendah dari seluruh epoch yaitu nilai *loss* 0,2403 pada epoch ke-29. Gambar 9 memberikan grafik untuk nilai akurasi yang dilakukan dengan epoch ke-40. Nilai akurasi stagnan pada epoch ke-37 hingga epoch ke-40 dengan nilai 86%. Tahap selanjutnya setelah proses training model dilakukan adalah melakukan pengujian pada data uji. Hasil data uji dapat dilihat pada Tabel 1.

**Tabel 1. Hasil pengujian**

No	Kelas Makanan	Jumlah Data Uji	Benar	Salah
1.	Dodol Galamai	3	3	0
2.	Emping Kerupuk Mlinjo	3	3	0
3.	Enting Wijen	3	3	0
4.	Es Krim	3	3	0
5.	Geblek	3	3	0
6.	Gethuk Goreng	3	2	1
7.	Gethuk Singkong	3	1	2
8.	Gurandil	3	3	0
9.	Jagung Gerontol	3	3	0
10.	Kacang Tanah Rebus	3	2	1

Hasil pengujian pada Tabel 1 menunjukkan bahwa terdapat klasifikasi yang salah pada beberapa kelas. Pada hasil pengujian 2 citra gethuk singkong diklasifikasikan pada kelas geblek, 1 citra gethuk goreng diklasifikasikan pada kelas emping krupuk mlinjo, 1 citra kacang tanah rebus diklasifikasikan pada kelas enting wijen. Hasil pengujian yang telah dilakukan menghasilkan *recall*, *precision* dan F1 Score masing-masing bernilai 86%, 91% dan 88%.

## 5 Kesimpulan

Klasifikasi citra makanan selingan khas Indonesia dengan CNN berhasil dilakukan dengan menggunakan dataset citra sebanyak 30 data yang terdiri dari 10 kelas dengan masing-masing kelas terdapat 3 citra. Training model CNN pada data citra dengan nilai epoch = 40 menghasilkan akurasi 86%. Pengujian data menghasilkan *recall* sebesar 86%, *precision* sebesar 91% dan F1 Score 88%.

Untuk penelitian selanjutnya diharapkan dapat menggunakan data uji lebih banyak dan menggunakan fungsi aktivasi yang berbeda sehingga didapatkan perbandingan nilai dari percobaan yang dilakukan.

## Referensi

- [1] Y. Zhao, Y. Rao, S. Dong, and Zhang, "Survey on Deep Learning Object Detecton," 2020.
- [2] W. Fang, P. E. D. Love, H. Luo, and L. Ding, "Computer Vision For Behaviour-based Safety in Construction: A Review and Future Directions," Jan. 01, 2020, Elsevier Ltd. doi: 10.1016/j.aei.2019.100980.
- [3] A. Santoso and G. Ariyanto, "Implementasi Deep Learning berbasis Keras untuk Pengenalan Wajah," *Jurnal Teknik Elektro*, vol. 18, no. 01, [Online]. Available: <https://www.mathworks.com/discovery/convol>
- [4] L. Alzubaidi et al., "Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00444-8.
- [5] W. P. Kusumo and C. S. K. Aditya, "Klasifikasi Citra Makanan berdasarkan Asal Daerah menggunakan Convolutional Neural Network Food Image Classification based on Regional Origin using Convolutional Neural Network."
- [6] P. D. Wardani, "Klasifikasi Tipe Kematangan Pisang menggunakan Metode Ensemble Convolutional Neural Network (CNN)," *JPTIJK*, vol.8, No.9, September 2024.
- [7] A. Kholik, "Klasifikasi menggunakan Convolutional Neural Network (CNN) pada Tangkapan Layar Halaman Instagram," *JDMSI*, vol. 2, no. 2, pp. 10–20, 2021.
- [8] Elvin and C. Lubis, "Klasifikasi Citra Ikan menggunakan Convolutional Neural Network." *Jurnal Ilmu Komputer dan Sistem Informasi*, 2022.
- [9] J. Lin, A. Zhang, M. Lécuyer, J. Li, A. Panda, and S. Sen, "Measuring the Effect of Training Data on Deep Learning Predictions via Randomized Experiments."
- [10] M. Taufik Ali, and B. Sugiarto, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang berbasis Mobile," *Digitech*, vol.3, No.2, 2023.
- [11] A. Ambarwari, M. Husni, and D. Mahayana, "Perkembangan Metode Klasifikasi Citra Penginderaan Jauh dalam Perspektif Revolusi Ilmiah Thomas Kuhn," *Jurnal Filsafat Indonesia*, vol. 6, 2023.
- [12] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," Mar. 01, 2023, MDPI. doi: 10.3390/computation11030052.
- [13] Purwono, A. Ma'arif, W. Rahmani, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, "Understanding of Convolutional Neural Network (CNN): A Review," *International Journal of Robotics and Control Systems*, vol. 2, no. 4, pp. 739–748, 2022, doi: 10.31763/ijrcs.v2i4.888.
- [14] K. R. Wardani and L. Leonardi, "Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network," *Jurnal Tekno Insentif*, vol. 17, no. 2, pp. 112–126, Oct. 2023, doi: 10.36787/jti.v17i2.1130.
- [15] F. Paraijun et al., "Implementasi Algoritma Convolutional Neural Network dalam mengklasifikasi Kesegaran Buah berdasarkan Citra Buah," vol. 11, no. 1, 2022, doi: 10.33322/kilat.v11i1.1458.
- [16] I. Guntoro, D. M. Midyanti, and D. R. Hidayati, "Penerapan Dropout pada Jaringan Saraf Tiruan Backpropagation dalam mengklasifikasi Tingkat Fine Fuel Moisture Code (FFMC) Untuk Kebakaran Hutan dan Lahan," 2022.