

# Pengenalan Makanan Tradisional Indonesia Beserta Bahan-bahannya dengan Memanfaatkan DCNN Transfer Learning

Citra Mahaputri<sup>1</sup>, Yosi Kristian<sup>1</sup>, Endang Setyati<sup>1</sup>

<sup>1</sup>Departemen Informatika, Fakultas Sains dan Teknologi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia

**Corresponding author:** Citra Mahaputri (e-mail: citramahaputri@gmail.com).

**ABSTRACT** Food recognition is the first step to assessing one's diet. In the introduction of food and its ingredients, it is felt that there is a lack of dissemination of photos of traditional Indonesian food, so researchers are encouraged to conduct research on the recognition of traditional Indonesian food. The researcher made a classification of food images whose input is an image of traditional Indonesian food. Feature extraction of food images is difficult to classify because food images vary in appearance, including texture, colour, shape and other visual characteristics. This research examines the use of Deep Convolutional Neural Network (DCNN) models EfficientNetB6 and EfficientNetV2M for the recognition of traditional Indonesian food and its ingredients. DCNN is a method commonly used to detect complex images. Researchers manually collected 1,202 different images of traditional Indonesian food. It consists of 20 types of traditional Indonesian food. Each type of food has 50-80 food images. The data used for food classification tests is 241 food image data outside the data used for training and get 83.82% accuracy for the EfficientNetV2M model and 80.08% for the EfficientNetB6 model. Then in the testing process in predicting the food ingredients seen in the image on average get 64% for the EfficientNetV2M model and 59% for the EfficientNetB6 model. Based on the research results, it shows that the DCNN method with the EfficientNetV2M model can achieve the best performance of the EfficientNetB6 model.

**KEYWORDS** Deep Convolution Neural Network, EfficientNetB6, EfficientNetV2M, Image Classification

**ABSTRAK** Pengenalan makanan adalah langkah awal untuk melakukan penilaian diet seseorang. Dalam pengenalan makanan beserta bahan-bahannya, dirasakan kurang diseminasi foto-foto makanan tradisional Indonesia, sehingga peneliti terdorong untuk melakukan penelitian mengenai pengenalan makanan tradisional Indonesia. Peneliti membuat klasifikasi citra makanan yang inputannya merupakan citra makanan tradisional Indonesia. Ekstraksi fitur citra makanan sulit untuk diklasifikasikan karena citra makanan beraneka ragam penampilannya, termasuk tekstur, warna, bentuk dan karakteristik visual lainnya. Penelitian ini meneliti pemanfaatan *Deep Convolutional Neural Network* (DCNN) model *EfficientNetB6* dan *EfficientNetV2M* untuk pengenalan makanan tradisional Indonesia beserta bahan-bahannya. DCNN merupakan metode yang biasa digunakan untuk mendeteksi citra yang kompleks. Peneliti mengumpulkan citra makanan tradisional Indonesia secara manual sebanyak 1.202 citra makanan yang berbeda. Terdiri dari 20 jenis makanan tradisional Indonesia. Masing-masing jenis makanan terdapat 50-80 gambar makanan. Data yang digunakan untuk uji klasifikasi makanan adalah 241 data citra makanan di luar data yang digunakan untuk *training* dan mendapatkan akurasi 83,82% untuk model *EfficientNetV2M* dan 80,08% untuk model *EfficientNetB6*. Kemudian pada proses pengujian dalam memprediksi bahan-bahan makanan yang terlihat pada gambar rata-rata mendapatkan 64% untuk model *EfficientNetV2M* dan 59% untuk model *EfficientNetB6*. Berdasarkan hasil penelitian menunjukkan bahwa metode DCNN dengan model *EfficientNetV2M* dapat mencapai performa terbaik dari model *EfficientNetB6*.

**KATA KUNCI** *Deep Convolution Neural Network*, *EfficientNetB6*, *EfficientNetV2M*, Klasifikasi Makanan

## I. PENDAHULUAN

Indonesia memiliki aneka ragam tradisi, budaya dan aneka ragam kuliner yang sangat menarik untuk di coba. Gaya hidup masyarakat mempengaruhi pemenuhan kebutuhan kalori dan sudah menjadi masalah yang umum di hadapi pada masa sekarang ini. Hal utama yang menjadi penyebab permasalahan ini adalah jenis makanan yang dimakan oleh manusia.

Pola makan yang tidak sehat berdampak besar pada nutrisi yang dibutuhkan tubuh. Makanan cepat saji dan makanan tinggi gula dapat meningkatkan risiko terhadap kesehatan [1],[2],[3]. Penerapan panduan nutrisi seimbang menggunakan metode *chaining backward* memberikan informasi tentang panduan nutrisi seimbang dan kalkulator kalori. Metode *chaining backward* digunakan untuk menghitung nilai gizi dan kalori pengguna aplikasi berdasarkan umur, makanan yang dimakan, tinggi dan berat badan [4].

Penelitian dalam pengenalan makanan merupakan perkembangan di masa sekarang. Sebagian besar peneliti mendapat tantangan tidak hanya mendeteksi nama makanan tetapi juga menghitung kalori di dalamnya [5]. Peneliti melakukan penelitian mengenai pengenalan makanan dan estimasi nutrisi dengan menggunakan *Machine Learning* dan menyiapkan dua model sistem dalam penelitiannya. Model pertama adalah model *text mining* untuk mengumpulkan informasi makanan di lebih dari 500 *website* dengan menggunakan *crawling* dan *scrapy*. Tahap selanjutnya, informasi berupa kata-kata diekstraksi dengan dipisahkan dengan menggunakan library *Python HTML Parser* untuk mendapatkan informasi penting mengenai nama masakan, bumbu – bumbu dan komposisi masakan tersebut. Peneliti membuat bank data mengenai makanan dengan resep/bumbu makanannya dengan menggunakan *word2vec*.

Keuntungan dari metode yang ada dalam penelitian [5] adalah menggabungkan gambar dengan informasi yang terkandung di dalamnya untuk menggabungkan dan memunculkan data informasi kalori dan nutrisi dari bumbu dan komposisi masakan. Penelitian ini memiliki akurasi sebesar 85%. Kelemahan dari penelitian ini adalah *dataset* dan variasi makanan yang digunakan penulis masih kurang banyak. Kemudian justifikasi kebenaran mengenai jumlah kalori dan nutrisi dalam makanan belum terverifikasi dengan baik oleh ahlinya.

Kontribusi untuk penelitian ini adalah :

1. Merancang sebuah sistem klasifikasi makanan yang dapat memprediksi makanan tradisional Indonesia yang inputnya merupakan citra dari makanan tradisional Indonesia dengan memanfaatkan metode *Transfer Learning* pada DCNN dengan model *EfficientNetB6* dan *EfficientNetV2M* untuk memprediksi ini makanan apa.
2. Merancang sebuah sistem yang dapat memprediksi bahan - bahan makanan pada makanan tradisional Indonesia dengan memanfaatkan metode *Transfer*

*Learning* pada DCNN dengan model *EfficientNetB6* dan *EfficientNetV2M*.

## II. PENELITIAN YANG RELEVAN

Pada tahun 2019, [6] melakukan penelitian yang terkait dengan pengenalan makanan Cina dengan menggunakan metode CNN. Peneliti membangun model penelitian dengan menggunakan perbandingan dan korelasi antara arsitektur CNN yang diusulkan dan model *BoF (Bag-of Feature)*. Keunggulannya terletak pada kombinasi fitur dan klasifikasi yang terdiri dari lapisan yang terhubung penuh. Tujuan menggunakan *layer* yang terhubung penuh adalah untuk menggabungkan fitur tingkat tinggi yang diekstraksi dari fase sebelumnya untuk mengklasifikasikan gambar input ke dalam kelas yang sesuai seperti yang ditentukan oleh *dataset* pelatihan. Penggabungan kombinasi fitur dengan klasifikasi menggunakan *layer* terhubung mencegah hilangnya data pada proses *training*, sehingga pada saat pengujian dilakukan, sistem mencapai akurasi yang baik. Data yang digunakan sebanyak 8734 gambar dari 25 jenis makanan yang berbeda di China. Metode CNN memiliki akurasi untuk top-1 sebesar 97,12% dan tingkat akurasi untuk top-5 sebesar 99,86%. Kesimpulan tersebut cukup kuat untuk mendukung keunggulan yang diklaim karena kombinasi kombinasi fitur dan klasifikasi menggunakan *layer* terhubung mencegah hilangnya data pada proses *training*, sehingga pada saat pengujian dilakukan sistem mencapai akurasi yang baik. Kekurangan dari penelitian ini adalah *dataset* gambar terbatas pada masakan Cina. Peneliti menyarankan untuk penelitian selanjutnya dapat ditambahkan daftar makanan dari negara lain.

Pada tahun 2020, [7] melakukan penelitian mengenai pengenalan dalam 13 kategori makanan di Vietnam [7]. Peneliti mencoba membandingkan 2 metode utama yaitu *Hand-Craft Feature* dan CNN. *Hand-Craft Feature* adalah teknik pengenalan objek yang mengekstrak informasi gambar seperti warna, tekstur, dan bentuk. Metode *Hand-Craft Feature* yang digunakan peneliti adalah *Support Vector Machines (SVMs)* dan *Extreme Gradient Boosting (XGBoost)*. Metode berbasis CNN yang dipakai pada penelitian ini antara lain *AlexNet*, *GoogleNet*, *ResNet50*, *ResNet101v2*, dan *InceptionResnet2*. Peneliti menggunakan metode optimasi adam untuk pembobotan setiap *layer* dari metode CNN. Peneliti mendapatkan akurasi tertinggi 1,3,dan 5 dengan menggunakan 8093 gambar dari 13 jenis makanan Vietnam yang berbeda. *InceptionResnet2* memiliki hasil akurasi yang tinggi dibandingkan dengan metode lain. Terutama pada *layer* 3 dan 5. *InceptionResnet2* seharusnya memiliki akurasi yang tinggi karena memiliki jumlah *layer* dan parameter paling banyak dibandingkan metode lainnya. Peneliti menyarankan untuk menambahkan jumlah kategori gambar dan menambahkan justifikasi mengenai nutrisi dan kalori makanan. Penelitian ini terbatas pada komputer dan nantinya dapat diimplementasikan pada *mobile phone*.

Pada penelitian selanjutnya, [8] bertujuan untuk mendeteksi makanan Indonesia dengan menggunakan metode CNN melakukan normalisasi (*cropping, wrapping, resizing*) data masukan. Tahap selanjutnya, peneliti mengubah ukuran citra menjadi 128 x 128 piksel dan mengubah citra menjadi *grayscale* untuk proses pelatihan. Metode CNN yang digunakan adalah *forward-propagation* dan *back-propagation*. Dalam proses *training*, peneliti menggunakan sekitar 10 ribu data dengan 10 kelas, setiap kelas makanan memiliki 1000 data. Untuk pengujian, peneliti menggunakan 500 gambar, dimana setiap kelas menggunakan 50 gambar. Hasil penelitian menunjukkan keakuratan pengenalan makanan sebesar 88% menggunakan metode CNN. Kesimpulan ini mendukung hasil penelitian, karena gambar dinormalisasi sebelum diproses. Semakin optimal penggunaan data *training* maka semakin tinggi akurasi yang dihasilkan.

Pada penelitian sebelumnya telah meneliti pemanfaatan DCNN untuk mengenali budaya Indonesia berupa Ukiran Jepara [9] sedangkan pada [10] meneliti pemanfaatan DCNN untuk mengenali nyeri dari wajah bayi. Penelitian tentang pengenalan makanan lainnya dapat ditemukan di [11], [12], [13].

Berdasarkan penelitian sebelumnya hasil yang didapatkan cukup memuaskan, namun ekstraksi fitur tidak berjalan dengan baik karena mengandalkan fitur *BoF (Bag-of-Feature)* dan *Hand-Craft Feature* yang sering menjadi kendala. Oleh karena itu, dalam penelitian ini menerapkan ekstraksi fitur dengan *feature learning*. Bagian berikut menjelaskan tentang *Convolutional Neural Network (CNN)* dan *EfficientNet* yang digunakan dalam penelitian ini.

### III. Convolutional Neural Network dan EfficientNet

Dalam penelitian ini, peneliti menggunakan metode *Convolutional Neural Network (CNN)* yang merupakan pengembangan dari *Deep Convolutional Neural Network (DCNN)*, jenis *neural network* yang biasa digunakan untuk data terkait gambar. CNN bisa digunakan untuk mendeteksi dan mengenali obyek dalam gambar. Fitur utama CNN adalah model/ arsitektur yang dapat melihat informasi prediktif suatu objek ketika diposisikan dimana saja pada *input*. CNN terdiri dari banyak *neuron* yang memiliki *weight, bias* dan *activation function*. *Convolutional Neural Network (CNN)* terdapat 2 bagian utama, yaitu *feature learning* dan *classification*. Berikut adalah penjelasan dari kedua bagian utama tersebut. *Convolutional Neural Network (CNN)* terdapat 2 bagian utama, yaitu *feature learning* dan *classification*. 2 bagian utama dijelaskan dibawah ini

#### A. Feature Learning

*Feature learning* adalah melakukan proses “*encoding*” suatu citra menjadi fitur dalam bentuk numerik untuk merepresentasikan citra tersebut. *Feature learning* terdiri dari beberapa layer yang bekerja sama untuk mendapatkan gambar. Penjelasan dari setiap *layer* adalah sebagai berikut:

##### 1) Convolution Layer

*Convolution Layer* pada CNN menghasilkan citra baru yang mewakili fitur dari gambar input. Dalam proses ini, *Convolution Layer* pada CNN menggunakan filter pada setiap gambar masukan. Proses ini menggunakan filter dengan tinggi, lebar, dan ketebalan tertentu. Filter ini diinisialisasi dengan nilai tertentu dan nilai filter ini yang menjadi parameter yang akan diperbarui dalam proses *learning* [14]. Konvolusi adalah istilah matematika yang berarti berulang kali menerapkan satu fungsi ke output fungsi lain. Dalam pemrosesan gambar, konvolusi berarti menerapkan kernel ke semua kemungkinan skema *offset*.

##### 2) Activation Layer

*Activation Layer* adalah *layer* yang fungsi aktivasinya *feature map* yang dihasilkan dari *convolution layer*. Fungsi aktivasi membantu mengubah nilai pada *feature map* dalam rentang tertentu sesuai dengan fungsi aktivasi yang digunakan. Tujuannya adalah untuk meneruskan nilai ke *layer* berikutnya yang menjelaskan fitur utama dari gambar yang masuk. Peneliti biasanya menggunakan fungsi aktivasi *ReLU* yang lebih fungsional. Fitur aktivasi *ReLU* memungkinkan nilai output neuron direpresentasikan sebagai 0 ketika input negatif. Jika masukannya dari fungsi aktivasi adalah positif, keluaran dari neuron menjadi masukan dari aktivasi itu sendiri.

##### 3) Pooling layer

*Pooling layer* biasanya muncul setelah *convolution layer* dan *activation layer*. Pada dasarnya *pooling layer* terdiri dari filter dengan ukuran tertentu yang bergerak di semua area *feature map*. *Pooling layer* yang umum digunakan adalah *Max Pooling* dan *Average Pooling*. Tujuan penggunaan *pooling layer* adalah untuk memperkecil ukuran *feature map (down sampling)*, yang meningkatkan kecepatan komputasi karena lebih sedikit parameter yang perlu diperbarui dan dapat mengatasi *overfitting* [15]. *Overfitting* terjadi ketika sampel data *training* terlalu acak dan *loss* berkurang sementara *val\_loss* tetap sama atau meningkat. Hal terpenting saat membuat model CNN adalah memilih berbagai *pooling layer* [16].

#### B. Classification

Tujuan dari proses *classification* adalah untuk mengklasifikasikan setiap *neuron* yang diekstrak dalam proses *feature learning*. Bagian ini terdiri dari beberapa layer yang saling berhubungan. Berikut adalah penjelasan dari masing-masing fungsi yang termasuk dalam *classification* tersebut.

##### 1) Flatten

*Feature learning* menghasilkan *feature map* dari masih berbentuk *multidimensional array*, sedangkan agar sesuai dengan *fully-connected layer*, data harus dalam bentuk vektor, sehingga membutuhkan fungsi yang disebut *Flatten*. Fungsi *flatten* adalah untuk membentuk kembali (*reshape*) *feature map* menjadi vektor sehingga dapat digunakan sebagai *input* dari *fully-connected layer*.

## 2) Fully Connected Layer

*Fully Connected Layer* umum digunakan dalam penerapan *multi-layer perceptron* dan dimaksudkan untuk mengubah dimensi data sehingga data dapat diklasifikasikan secara linear. *Layer* ini memiliki *hidden layer*, *activation function*, *output layer*, dan *loss function*. Setiap neuron pada *convolution layer* harus diubah menjadi data satu dimensi sebelum dapat dimasukkan ke dalam *fully-connected layer*. Karena jika data kehilangan informasi spasial dan tidak dapat dibalik, sedangkan *fully-connected layer* hanya dapat dilakukan di ujung jaringan. *Convolution layer* dengan ukuran kernel 1 x 1 melakukan fungsi yang sama dengan *fully-connected layer* tetapi tetap mempertahankan karakter spasial data.

Dalam penelitian pengenalan makanan tradisional Indonesia beserta bahan - bahannya peneliti menggunakan *framework* untuk mempermudah pembuatan program *deep learning*. Peneliti menggunakan *Keras Applications*. *Keras Applications* merupakan salah satu modul *library* yang menyediakan arsitektur untuk berbagai model *deep learning*. Model deteksi gambar *Keras Applications* juga dapat digunakan untuk mengekstrak fitur dari citra. *Keras* adalah antarmuka yang memudahkan pengguna dalam pemrograman dan semua komputasi model dilakukan oleh *library* lain yaitu *TensorFlow* atau *Theano*.

Peneliti menggunakan sebuah kerangka kerja/*framework* yang bernama *tensorflow*. Penggunaan *tensorflow* pada penelitian ini untuk mempermudah dan mempercepat proses *training* dan uji coba penelitian. *Tensorflow* sudah banyak digunakan untuk penelitian berbasis *deep learning-convolutional neural network*, [17], [18].

Pada penelitian ini, peneliti menggunakan *transfer learning* untuk pengenalan jenis makanan dan pengenalan bahan - bahan yang terlihat pada gambar makanan. *Transfer learning* adalah alat yang digunakan untuk mentransfer pengetahuan dari *domain* asal ke *domain* tujuan/target [19], [20].

*EfficientNet* adalah arsitektur dari *Convolutional neural network* (CNN) yang di dasarkan pada 3 dimensi penskalaan sederhana dan sangat efektif, yaitu *depth* (kedalaman), *width* (lebar) dan *resolution* (resolusi). Dimensi penskalaan pada *EfficientNet* merupakan penskalaan dengan koefisien yang tetap. Secara umum *EfficientNet* dapat mencapai nilai akurasi yang tinggi dan memiliki tingkat performa yang lebih baik dari arsitektur CNN yang lain dan dapat mengurangi ukuran parameter dan FLOPS yang optimal [21]. *EfficientNetB6* adalah arsitektur *Convolutional Neural Network* (CNN) yang dibuat berdasarkan ide dasar CNN menjadi arsitektur *Neural Network* dengan sumber daya tetap dan kemudian ditingkatkan untuk mendapatkan akurasi tinggi. Dalam prakteknya, membangun arsitektur CNN sesuai dengan pola penskalaan tertentu dan mengetahui bahwa menyeimbangkan kedalaman, lebar, dan resolusi jaringan dengan hati-hati dapat menghasilkan kinerja yang lebih baik. Sedangkan *EfficientNetV2M* merupakan salah satu jenis *convolutional neural network* dengan kecepatan

*training* yang lebih cepat dan efisiensi parameter yang lebih baik dari model sebelumnya.

## C. Confusion Matrix

*Confusion Matrix* adalah metode yang digunakan untuk menampilkan dan membandingkan nilai aktual dengan nilai prediksi dari model yang dapat digunakan untuk memberikan ukuran evaluasi seperti akurasi, *Precision*, *Recall*, *F1Score*. Akurasi adalah alat ukur untuk menentukan tingkat kesesuaian hasil pengukuran dengan nilai sebenarnya. Akurasi dituliskan pada (1). *F1Score* adalah ukuran level *classifier* dapat menilai sebuah kelas. *F1Score* dapat digunakan untuk mengukur kinerja *multiclass* dengan mengambil rata-rata tertimbang (*weighted average*) hasil *F1Score* untuk semua kelas seperti yang ditunjukkan pada (2). Bobot di sini adalah jumlah data untuk mendukung (*support*) setiap kelas. *Precision* adalah tingkat ketelitian antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem, seperti ditunjukkan pada (3). *Recall* adalah tingkat keberhasilan sistem dalam mengambil informasi. Dengan persamaan (4) nilai *Recall* dapat diketahui. Ada 4 nilai yang dihasilkan oleh *Confusion Matrix* diantaranya: Nilai *True Negative* (TN) adalah data yang diklasifikasikan dengan benar sebagai keluaran negatif atau salah. *True Positive* (TP) adalah data yang diklasifikasikan dengan benar sebagai output positif atau benar. *False Positive* (FP) adalah data yang diklasifikasikan apakah keluarannya positif atau benar. *False Negative* (FN) adalah data yang diklasifikasi dengan kurang tepat sehingga keluarannya negatif atau salah [22].

$$\text{Akurasi} = \frac{\text{True Positive}}{\text{Total Data}} \quad (1)$$

$$\text{F1Score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2)$$

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (3)$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (4)$$

## IV. METODE

### A. Dataset

Dalam penelitian ini, peneliti memilih makanan tradisional Indonesia yang dijadikan objek penelitian. Gambar makanan tradisional Indonesia dikumpulkan secara manual sebanyak 1.202, gambar makanan yang terdiri dari 20 jenis makanan tradisional Indonesia yang berbeda diambil dari situs *web* dan foto selama 3 bulan berturut-turut. Pada masing-masing kelas makanan terdapat 50-80 gambar



makanan yang sudah dikumpulkan menjadi *dataset* yang siap untuk dilakukan pengujian klasifikasi makanan dan memprediksi bahan-bahannya. Setelah itu peneliti melakukan pelabelan yang sesuai dengan kelas makanan. 80% dari 1.202 yaitu 961 data citra makanan digunakan untuk data *training* dan 20% yaitu 241 data citra makanan digunakan untuk data *testing*.

### B. Image Preprocessing

Dalam proses pengumpulan data gambar makanan, peneliti menggunakan gambar makanan dengan kriteria berikut ini :

1. Gambar tampak atas
2. Gambar disimpan dalam bentuk JPG
3. Gambar berukuran 224 x 224
4. Gambar harus terdiri dari makanan (minuman, alat makan, hiasan, pot bunga dan lainnya tidak di perbolehkan)
5. Gambar makanan berwarna
6. Jenis gambar makanan terdiri dari 20 kelas makanan tradisional Indonesia yaitu Ayam Lodho, Gado-gado, Gule Kambing, Krengsengan, Lodeh, Lontong Kikil, Opor Ayam, Oseng-oseng Kerang, Oseng-oseng Udang, Rawon, Rujak Cingur, Sate Madura, Sayur Asem, Sayur Bayam, Sayur Bobor, Sop Ayam, Sop Daging, Soto Lamongan, Tahu Campur, Tahu Tek.

Tahap pertama, citra makanan yang telah terkumpul diolah kemudian masuk ke dalam tahap *preprocessing*. Pada proses *wrapping*, bertujuan untuk menentukan tepi citra, selanjutnya melakukan proses *cropping* objek pada citra sehingga sistem dapat fokus untuk mengidentifikasi objek utama citra makanan. Tujuan dilakukan *cropping* adalah untuk membuat citra makanan lebih jelas dan sama untuk semua gambar. *Cropping* yaitu proses menghilangkan bagian gambar yang tidak di perlukan. Proses ini biasanya meliputi penghapusan sebagian tepi citra untuk menghilangkan sampah asing dari citra, meningkatkan frekuensi gambar dan mengubah rasio [14]. Proses ini dilakukan secara manual dengan menggunakan software. Selanjutnya adalah pelabelan dan pengelompokan gambar. Gambar-gambar yang sudah dipilah dan ukurannya sama, dikelompokkan dengan jenis kelas yang sama dalam satu *folder* dan di beri nama menurut 20 kelas makanan tradisional Indonesia untuk mempermudah proses *training*. Proses pengolahan data gambar makanan tradisional Indonesia dimulai dari mengubah ukuran citra makanan menjadi ukuran 224 x 224, kemudian mengubah menjadi *grayscale* agar mudah diproses pada tahap *training*. Kemudian citra makanan diolah dengan menggunakan *deep learning* untuk proses *training*. Pada tahap *training* dimulai dengan mengubah citra menjadi vektor.

### C. Training

Pada proses *training* bertujuan untuk menghasilkan akurasi yang tinggi dari klasifikasi citra makanan. Tahap *training* ini terdiri dari proses *feedforward* dan proses *backpropagation*. Untuk memulai proses *feedforward*,

membutuhkan jumlah dan ukuran layer yang dibuat, ukuran subsampling dan citra vektor. Kemudian proses *feedforward* pada citra vektor akan melalui konvolusi dan *Max Pooling* untuk memperkecil ukuran gambar dan memperbanyak neuron. Pada proses *training* peneliti menggunakan data sebanyak 961 data citra makanan. Peneliti melakukan *Training* dengan membandingkan model DCNN *EfficientNetB6* dan *EfficientNetV2M* dengan *epoch* 100, *batchsize* 50. Peneliti mendapatkan nilai akurasi 0,9834 dengan nilai kerugian 0,0521 untuk model *EfficientNetB6*, dan model *EfficientNetV2M* mendapatkan akurasi 0,9979 dengan nilai kerugian 0,0062.

## V. HASIL

### A. Implementasi

Penelitian ini memanfaatkan metode *Deep Convolutional Neural Network (DCNN)* yang mampu mengklasifikasikan gambar makanan tradisional Indonesia dan memprediksi bahan-bahan makanan pada makanan tersebut dengan menggunakan model *EfficientNetB6* dan *EfficientNetV2M*. Dalam penerapannya, ada beberapa langkah untuk memprediksi proses klasifikasi gambar makanan, yang pertama, gambar makanan dimasukkan dalam proses konvolusi dengan, *input* (224, (3, 3)) untuk mengurangi dimensi setiap gambar *input* makanan tetapi masih menyimpan informasi penting dari gambar. Proses “*Flattening*” dan “*Fully-connected layer*” untuk mengklasifikasikan fitur yang di peroleh dalam proses sebelumnya pada semua kelas. Gambar 1 adalah hasil klasifikasi makanan dengan metode DCNN yang menghasilkan klasifikasi Sate Madura dan Ayam Lodho.



Asli = Sate Madura (12) Pred = Sate Madura (12) Asli = Ayam Lodho (1) Pred = Ayam Lodho (1)

**GAMBAR 1.** Hasil Klasifikasi Citra Makanan

### B. Pengujian

Dalam penelitian ini telah dilakukan penerapan metode *Convolutional Neural Network (CNN)*, metode ini dapat menghasilkan klasifikasi citra makanan. Pada pelaksanaannya, sistem dalam melakukan klasifikasi citra makanan cukup baik, dengan prediksi kesalahan sistem sebesar 19,92% dalam citra makanan. Dalam menguji keakuratan sistem, peneliti melakukan pengujian pada 20 kelas makanan dan menggunakan 241 citra makanan baru

dari setiap kelas pengujian diluar gambar yang digunakan untuk *training*.

Berikut ini adalah hasil pengujian dengan model *EfficientNetB6* yang sudah di lakukan oleh peneliti:

TABEL I.  
AKURASI HASIL PENGUJIAN CITRA MAKANAN DENGAN *EFFICIENTNETB6*

Nama Makanan	BENAR		SALAH		Total Gambar Pengujian
	Jumlah Gambar	Persentase (%)	Jumlah Gambar	Persentase (%)	
Ayam Lodho	13	72,22	5	28	18
Gado - Gado	12	80,00	3	20	15
Gule Kambing	13	86,66	2	13	15
Krengsengan	17	94,44	1	6	18
Lodeh	14	87,50	2	12	16
Lontong Kikil	6	54,54	5	45	11
Opor Ayam	2	33,33	4	67	6
Oseng – Oseng Kerang	8	80,00	2	20	10
Oseng – Oseng Udang	14	93,33	1	7	15
Rawon	10	90,90	1	9	11
Rujak Cingur	8	66,66	4	33	12
Sate Madura	7	100,00	0	0	7
Sayur Asem	12	85,71	2	14	14
Sayur Bayam	6	54,54	5	14	11
Sayur Bobor	7	87,50	1	12	8
Sop Ayam	14	82,35	3	18	17
Sop Daging	7	63,63	4	36	11
Soto Lamongan	10	100,00	0	0	10
Tahu Campur	8	88,88	1	11	9
Tahu Tek	5	71,42	2	29	7
Rata-rata	193	80,08	48	19,92	241

Berdasarkan hasil pengujian klasifikasi citra makanan dengan model *EfficientNetB6* pada Tabel I mendapatkan hasil pengujian sistem dengan akurasi 80,08% dan kesalahan rata-rata 19,92%.

Dibawah ini adalah hasil pengujian menggunakan metode *CNN* dengan model *EfficientNetV2M* yang sudah di lakukan oleh peneliti:

TABEL II.  
AKURASI HASIL PENGUJIAN CITRA MAKANAN DENGAN *EFFICIENTNETV2M*

Nama Makanan	BENAR		SALAH		Total Gambar Pengujian
	Jumlah Gambar	Persentase (%)	Jumlah Gambar	Persentase (%)	
Ayam Lodho	14	77,78	4	22,22	18
Gado - Gado	14	93,33	1	6,67	15
Gule Kambing	13	86,67	2	13,33	15
Krengsengan	17	94,44	1	5,56	18
Lodeh	13	81,25	3	18,75	16
Lontong Kikil	8	72,73	3	27,27	11
Opor Ayam	4	66,67	2	33,33	6
Oseng – Oseng Kerang	9	90,00	1	10,00	10
Oseng – Oseng Udang	14	93,33	1	6,67	15
Rawon	11	100,00	0	0,00	11
Rujak Cingur	8	66,67	4	33,33	12
Sate Madura	6	85,71	1	14,29	7
Sayur Asem	11	78,57	3	21,43	14
Sayur Bayam	9	81,82	2	18,18	11
Sayur Bobor	7	87,50	1	12,50	8
Sop Ayam	13	76,47	4	23,53	17
Sop Daging	8	72,73	3	27,27	11
Soto Lamongan	9	90,00	1	10,00	10
Tahu Campur	9	100,00	0	0,00	9
Tahu Tek	5	71,43	2	28,57	7
Rata-rata	202	83,82	39	16,18	241

Berdasarkan hasil pengujian klasifikasi citra makanan dengan model *EfficientNetV2M* pada Tabel II mendapatkan hasil pengujian sistem dengan akurasi 83,82% dan kesalahan rata-rata 16,18%.

### C. Uji Coba


Dalam bagian ini, uji coba dilakukan untuk mendapatkan model terbaik sehingga dapat memprediksi bahan-bahan makanan dengan cara mengganti parameter-parameter, seperti jumlah *layer*, *learning rate*, dan jumlah *frame*. Tahap awal dalam melakukan prediksi bahan makanan yaitu membuat list bahan makanan yang tampak pada setiap gambar, kemudian membuat *dataset* proses *Transfer Learning* dengan memberi nilai 0 pada bahan makanan yang tidak terlihat dan memberi nilai 1 untuk bahan makanan yang terlihat. Kemudian memproses *pickle dataset* agar data mudah dibaca oleh sistem. Untuk memprediksi bahan-bahan makanan peneliti memanfaatkan model *EfficientNetB6* dan *EfficientNetV2M* dengan data sebanyak 1.202 data, rincian 961 data training dan 241 data testing. Dibawah ini contoh hasil prediksi bahan-bahan makanan :



<p><b>PREDICTION:</b> Cabe : 0.7813321 Bawang Goreng : 0.33727598 Daun Bawang : 0.4122431 Daging Kambing : 0.92558545 =====</p> <p><b>ACTUAL:</b> Tomat : 1.0 Daun Bawang : 1.0 Seledri : 1.0 Daging Kambing : 1.0</p> <p>(a)</p>	<p><b>PREDICTION:</b> Ayam : 0.3653078 Cabe : 0.8718002 Daun Jeruk : 0.5747717 Bawang Goreng : 0.809900 =====</p> <p><b>ACTUAL:</b> Tomat : 1.0 Daun Bawang : 1.0 Seledri : 1.0 Daging Kambing : 1.0</p> <p>(b)</p>
-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

**GAMBAR 2.** Hasil Prediksi bahan-bahan Makanan (Gule Kambing)

Gambar 2 (a) adalah hasil prediksi bahan makanan pada Gule Kambing dengan model *EfficientNetV2M* yang mampu memprediksi Cabe, Bawang Goreng, Daun Bawang dan Daging Kambing. Dari hasil prediksi terdapat 2 bahan makanan yang diprediksi benar yaitu Daun Bawang dan Daging Kambing. Sedangkan gambar 2 (b) adalah hasil prediksi bahan makanan Gule Kambing dengan model *EfficientNetB6* dengan hasil prediksi Ayam, Cabe, Daun Jeruk, Bawang Goreng. Berdasarkan hasil prediksi semua bahan tidak terprediksi dengan benar.



<p><b>PREDICTION:</b> Cabe : 0.55596274 Bawang Goreng : 0.6890229 Tomat : 0.8668066 Daging Kambing : 0.5979996 Daging Sapi : 0.5736612 Bawang Merah : 0.47917238 Bumbu Kecap : 0.48936975 =====</p> <p><b>ACTUAL:</b> Cabe : 1.0 Bawang Goreng : 1.0 Tomat : 1.0 Bumbu Kacang : 1.0 Daging Kambing : 1.0 Bawang Merah : 1.0 Bumbu Kecap : 1.0</p> <p>(a)</p>	<p><b>PREDICTION:</b> Daging Kambing : 0.8127581 Bumbu Kecap : 0.47282726 =====</p> <p><b>ACTUAL:</b> Cabe : 1.0 Bawang Goreng : 1.0 Tomat : 1.0 Bumbu Kacang : 1.0 Daging Kambing : 1.0 Bawang Merah : 1.0 Bumbu Kecap : 1.0</p> <p>(b)</p>
--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

**GAMBAR 3.** Hasil Prediksi bahan-bahan Makanan (Sate Madura)

Gambar 3 (a) adalah hasil prediksi bahan makanan pada Sate Madura dengan model *EfficientNetV2M* yang mampu

memprediksi Cabe, Bawang Goreng, Tomat, Daging Kambing, Daging Sapi, Bawang Merah, dan Bumbu Kecap. Dari hasil prediksi terdapat 6 bahan makanan yang diprediksi benar yaitu Cabe, Bawang Goreng, Tomat, Daging Kambing, Bawang Merah, dan Bumbu Kecap. Sedangkan gambar 3 (b) adalah hasil prediksi bahan makanan Sate Madura dengan model *EfficientNetB6* dengan hasil Daging Kambing dan Bumbu Kecap. Berdasarkan hasil prediksi tidak semua bahan dapat diprediksi dengan benar, namun hanya 2 saja yang terprediksi dengan benar.

Dalam memprediksi bahan-bahan makanan dengan model terbaik dapat menampilkan hasil *confusion matrix* seperti pada Tabel III. Dari Tabel III tampak bahwa sistem dapat memprediksi bahan-bahan makanan dengan baik.

TABEL III.  
HASIL UJI COBA KLASIFIKASI *MULTICLASS*

Model CNN	Weighted avg		
	Precision	Recall	F1 Score
<i>EfficientNetV2M</i>	0,65	0,65	0,64
<i>EfficientNetB6</i>	0,57	0,65	0,59

## VI. KESIMPULAN

Berdasarkan hasil percobaan yang telah dilakukan oleh peneliti dalam mengklasifikasi citra makanan tradisional Indonesia dengan menggunakan metode DCNN model *EfficientNetV2M* dan *EfficientNetB6*. Dengan melalui beberapa tahap, pengumpulan *dataset*, *image processing*, *training*, *testing* untuk mendeteksi citra makanan dan dilanjutkan memprediksi bahan makanan. Data yang digunakan sebanyak 1.202 yang terdiri dari 961 data *training*, 241 data *testing*. Sistem dapat mengklasifikasi citra makanan sehingga dapat memprediksi makanan tradisional Indonesia dengan akurasi 83,82% dan kesalahan 16,18% sedangkan model *EfficientNetB6* tingkat akurasinya 80,08% dan kesalahan 19,92% dengan Sedangkan dalam memprediksi bahan-bahan makanan dengan model *EfficientNetB6* mendapatkan nilai *F1Score* 59%, *Recall* 65%, *Precision* 57%, dan untuk model *EfficientNetV2M* mendapatkan nilai *F1Score* 64%, *Recall* 65%, *Precision* 65%, sehingga dapat disimpulkan bahwa model *EfficientNetV2M* lebih baik dari model *EfficientNetB6* dalam mengklasifikasikan citra makanan dan memprediksi bahan-bahan makanan.

## PERAN PENULIS

**Citra Mahaputri:** Konseptualisasi, metodologi, perangkat lunak, validasi, investigasi, sumber daya, kurasi data, penyusunan draft asli, visualisasi;

**Yosi Kristian:** Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, penyusunan draft asli, peninjauan dan penyuntingan, visualisasi, pengawasan, administrasi proyek;

**Endang Setyati:** Validasi, analisis formal, investigasi,



peninjauan dan penyuntingan, pengawasan, administrasi proyek;

## DAFTAR PUSTAKA

- [1] I. Pamela, "Perilaku Konsumsi Makanan Cepat Saji Pada Remaja Dan Dampaknya Bagi Kesehatan," *Ikesma*, vol. 14, no. 2, p. 144, 2018, doi: 10.19184/ikesma.v14i2.10459.
- [2] Y. Mursono, "Prospek Pengembangan Makanan Fungsional," *J. Teknol. Pangan dan Gizi*, vol. 7, no. 1, pp. 19–27, 2007, [Online]. Available: [http://elearning.unsri.ac.id/pluginfile.php/635/mod\\_forum/attachment/23137/ipi113801.pdf](http://elearning.unsri.ac.id/pluginfile.php/635/mod_forum/attachment/23137/ipi113801.pdf).
- [3] A. Baequny, A. S. Harnany, and E. Rumimper, "Pengaruh Pola Makan Tinggi Kalori terhadap Peningkatan Kadar Gula Darah pada Penderita Diabetes Mellitus Tipe 2," *J. Ris. Kesehat.*, vol. 4, no. 1, pp. 687–692, 2015, [Online]. Available: <http://ejournal.poltekkes-smg.ac.id/ojs/index.php/jrk/article/view/347>.
- [4] G. A. Pamungkas, R. R. Isnanto, and K. T. Martono, "Pembuatan Aplikasi Panduan Gizi Seimbang Berbasis Android Dengan Menggunakan Metode Backward Chaining," *J. Teknol. dan Sist. Komput.*, vol. 4, no. 2, p. 369, 2016, doi: 10.14710/jtsiskom.4.2.2016.369-379.
- [5] Z. Shen, "ScienceDirect Machine Learning Based Approach on Food Recognition Approach on Food Recognition Machine Based Approach on and Nutrition Estimation Machine Learning Based Approach on Food Food Recognition Recognition Machine Learning Based Approach," vol. 100, pp. 1–6, 2019.
- [6] J. Teng, D. Zhang, D. J. Lee, and Y. Chou, "Recognition of Chinese food using convolutional neural network," *Multimed. Tools Appl.*, vol. 78, no. 9, pp. 11155–11172, 2019, doi: 10.1007/s11042-018-6695-9.
- [7] D. Kraft and G. Bieber, "Vietnamese Food Recognition System Using Convolutional Neural Networks Based Features," *ACM Int. Conf. Proceeding Ser.*, vol. 3, pp. 423–428, 2020, doi: 10.1145/3389189.3397993.
- [8] I. P. A. E. Darma Udayana, M. Sudarma, and P. G. Surya Cipta Nugraha, "Implementation of Convolutional Neural Networks to Recognize Images of Common Indonesian Food," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 846, no. 1, 2020, doi: 10.1088/1757-899X/846/1/012023.
- [9] Sandhopi, Lukman Zaman P.C.S.W, and Yosi Kristian, "Identifikasi Motif Jepara pada Ukiran dengan Memanfaatkan Convolutional Neural Network," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 4, pp. 403–413, 2020, doi: 10.22146/jnteti.v9i4.541.
- [10] Y. Kristian, I. K. E. Purnama, E. H. Sutanto, L. Zaman, E. I. Setiawan, and M. H. Purnomo, "Klasifikasi Nyeri pada Video Ekspresi Wajah Bayi Menggunakan DCNN Autoencoder dan LSTM," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 7, no. 3, pp. 308–316, 2018, doi: 10.22146/jnteti.v7i3.440.
- [11] S. J. Park, A. Palvanov, C. H. Lee, N. Jeong, Y. I. Cho, and H. J. Lee, "The development of food image detection and recognition model of Korean food for mobile dietary management," *Nutr. Res. Pract.*, vol. 13, no. 6, pp. 521–528, 2019, doi: 10.4162/nrp.2019.13.6.521.
- [12] J. Sun, K. Radecka, and Z. Zilic, "Exploring better food detection via transfer learning," *Proc. 16th Int. Conf. Mach. Vis. Appl. MVA 2019*, pp. 1–6, 2019, doi: 10.23919/MVA.2019.8757886.
- [13] N. Martinel, G. L. Foresti, and C. Micheloni, "Wide-slice residual networks for food recognition," *Proc. - 2018 IEEE Winter Conf. Appl. Comput. Vision, WACV 2018*, vol. 2018-Janua, pp. 567–576, 2018, doi: 10.1109/WACV.2018.00068.
- [14] S. R. Suartika E. P, I Wayan, Wijaya Arya Yudhi, "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>.
- [15] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation," *J. Appl. Informatics Comput.*, vol. 4, no. 1, pp. 45–51, 2020, doi: 10.30871/jaic.v4i1.2017.
- [16] C. Y. Lee, P. W. Gallagher, and Z. Tu, "Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree," *Proc. 19th Int. Conf. Artif. Intell. Stat. AISTATS 2016*, pp. 464–472, 2016.
- [17] M. A. Abu, N. H. Indra, A. H. A. Rahman, N. A. Sapiee, and I. Ahmad, "A study on image classification based on deep learning and tensorflow," *Int. J. Eng. Res. Technol.*, vol. 12, no. 4, pp. 563–569, 2019.
- [18] K. Seetala, W. Birdsong, and Y. B. Reddy, "Image classification using tensorflow," *Adv. Intell. Syst. Comput.*, vol. 800 Part F, no. Itng, pp. 485–488, 2019, doi: 10.1007/978-3-030-14070-0\_67.
- [19] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, *A Survey on Deep Transfer Learning Chuanqi*, vol. 11141, no. November. Springer International Publishing, 2018.
- [20] Y. Wu, X. Qin, Y. Pan, and C. Yuan, "Convolution neural network based transfer learning for classification of flowers," *2018 IEEE 3rd Int. Conf. Signal Image Process. ICSSIP 2018*, pp. 562–566, 2019, doi: 10.1109/SIPROCESS.2018.8600536.
- [21] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [22] A. Rohim, Y. A. Sari, and Tibyani, "Convolution neural network (cnn) untuk pengklasifikasian citra makanan tradisional," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 7, pp. 7038–7042, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5851/2789>.