



DETEKSI BAHAN MAKANAN UNTUK REKOMENDASI RESEP MASAKAN PADA PROGRAM DIET MENGGUNAKAN ALGORITMA CNN

Berliani Risqi Dwi Saputri¹⁾, Fadiyah Desi Asmawati²⁾, Asih Rahmawati³⁾, Ilham Hatta Manggala⁴⁾, Muhammad Fikri Hidayattullah⁵⁾

^{1,2,3,4,5} Teknik Informatika, Politeknik Harapan Bersama

email: ¹ berlianirsq@gmail.com, ² fadiyahdesi1@gmail.com, ³ asihrahmatwati008@gmail.com,

⁴ ilhamhattamanggala123@gmail.com, ⁵ fikri@poltektegal.ac.id

ARTICLE INFO	ABSTRACT
<p>Article History: Recieved : 21 Juni 2024 Accepted : 25 November 2024 Published : 16 Desember 2024</p> <p>Keywords: Convolutional Neural Network Diet Klasifikasi Resep Masakan VGG16</p> <p>IEEE style in citing this article: B. R. D. Saputri, F. D. ASmawati, A. Rahmawati, I. H. Manggala, M. F. Hidayattullah, "Deteksi Bahan Makanan Untuk Rekomendasi Resep Masakan Pada Program Diet Menggunakan Algoritma CNN", jurnal.ilmiah.informatika, vol. 9, no. 2, pp. 134-141, Des. 2024.</p>	<p><i>The increasing need for efficient dietary planning has led to the development of automated systems for identifying food ingredients and generating suitable diet recommendations. This study focuses on implementing a Convolutional Neural Network (CNN) using the VGG16 architecture to classify food ingredients and determine appropriate diet recipes. The problem addressed is the difficulty of manually identifying various food ingredients, which can be time-consuming and error-prone, especially in large-scale dietary planning. The proposed solution integrates deep learning technology with a user-friendly application that automates the classification process and generates diet suggestions. The method involves utilizing the VGG16 model pre-trained on the ImageNet dataset. The dataset underwent preprocessing techniques, including Gaussian Blur for noise reduction, normalization, and data augmentation, to improve model generalization. The model was trained over 50 epochs, achieving a training accuracy of 96.28% and a validation accuracy of 95%. This study contributes to the development of intelligent dietary systems, providing significant benefits in enhancing user convenience, accuracy in food classification, and promoting healthier lifestyles.</i></p>

1. PENDAHULUAN

Kesehatan gizi merupakan suatu hal yang penting dalam hidup. Asupan nutrisi yang baik dan tepat tidak hanya dapat menjaga kesehatan fisik, tetapi juga mendukung produktivitas harian [1]. Pola makan merupakan suatu hal yang penting dalam kesehatan tubuh. Pola makan yang salah dapat memengaruhi gizi dan kesehatan suatu individu. Sumber gizi buruk juga dapat berasal dari pola makan yang tidak teratur dan tidak sehat. Tidak selektif dalam memilih makanan sehari-hari atau tidak tahu tentang nilai gizi dari suatu makanan akan menyebabkan pola konsumsi yang tidak mempertimbangkan kesehatan tubuh [2]. Permasalahan kesehatan gizi saat ini masih menjadi suatu isu penting yang dihadapi oleh kalangan masyarakat di Indonesia [3]. Sekarang ini, banyak penyakit yang datang menyerang di usia yang masih produktif seperti gangguan pencernaan, kolesterol, diabetes, ataupun obesitas. Semua disebabkan oleh pola hidup yang tidak sehat, utamanya dari pola makan yang tidak teratur [4].

Meski kesadaran akan pentingnya pola makan sehat sudah meningkat sejak tahun 2022 karena adanya tren program diet, banyak masyarakat Indonesia masih mengalami berbagai hambatan dalam menerapkan program makan sehat yang sesuai dengan kebutuhan tubuh [5]. Salah satu tantangan utama adalah minimnya pemahaman mengenai cara merancang rencana diet sehat yang sesuai dengan kebutuhan gizi dan ketersediaan bahan makanan. Banyak program diet yang ada bersifat umum dan tidak memperhatikan preferensi individu atau kondisi tertentu seperti alergi atau batasan bahan. Hal ini menyebabkan banyak program diet yang tidak berkelanjutan dan kurang efektif dalam jangka panjang. Selain itu, tren diet

ekstrem yang sering kali mengharuskan pengurangan kalori secara drastis atau pembatasan kelompok makanan tertentu, hal tersebut seringkali berisiko terhadap kesehatan tubuh dan menyebabkan efek samping yang berbahaya. Tidak jarang pula, banyak orang ingin memiliki berat badan ideal dengan cepat, mereka memilih mengikuti tren obat pelangsing yang menjanjikan penurunan berat badan dengan cepat tanpa perlu merubah pola makan atau pola hidup. Namun, tentu saja hal tersebut memiliki dampak jangka panjang bagi kesehatan yang dapat menimbulkan efek samping serius atau bahkan memperburuk kondisi tubuh.

Penelitian ini bertujuan menerapkan algoritma CNN (*Convolutional Neural Network*) guna mendeteksi bahan makanan untuk menentukan resep diet yang sesuai dengan preferensi pengguna. Identifikasi bahan makanan yang akurat dan penentuan diet yang tepat merupakan langkah penting dalam membantu pengguna merancang pola makan sehat yang personal dan berkelanjutan. Namun, proses tersebut seringkali membutuhkan pengetahuan mendalam tentang gizi serta kemampuan untuk merancang rencana diet yang sesuai dengan kebutuhan tiap individu. Oleh karena itu, diperlukan metode yang mampu mengenali bahan makanan secara otomatis dan memberikan rekomendasi resep diet yang tepat berdasarkan data yang tersedia. Pentingnya pengelolaan pola makan yang baik tidak hanya mendukung kesehatan fisik, tetapi juga membantu meningkatkan kualitas hidup secara keseluruhan. Dengan menggunakan teknologi deteksi citra berbasis CNN, penelitian ini diharapkan dapat mempermudah perencanaan diet dan memberikan kontribusi dalam

meningkatkan kesadaran pentingnya pola makan sehat.

Penerapan algoritma CNN dalam bidang deteksi gambar telah banyak digunakan dan terbukti memberikan hasil yang baik. Sebagai contoh, pada penelitian terdahulu yang membahas mengenai Pengenalan Makanan Tradisional Indonesia Beserta Bahan-bahannya dengan Memanfaatkan *Deep Convolutional Neural Networks* (DCNN) menggunakan 1.202 dataset foto makanan dengan 20 tipe makanan berhasil mencapai akurasi sebesar 83.82% dalam klasifikasinya. Hal ini menunjukkan potensi yang signifikan dalam memprediksi bahan makanan secara akurat sehingga dapat berkontribusi terhadap penilaian pola makan sekaligus mempromosikan masakan tradisional Indonesia [6].

Penelitian lain membahas pengembangan aplikasi *website* menggunakan metode *MASK R-CNN* untuk mendeteksi kandungan kalori pada gambar makanan. Dengan menggunakan 220 dataset gambar makanan yang terbagi dalam 5 kategori, model tersebut berhasil mencapai akurasi keseluruhan sebesar 72% setelah melalui proses pelatihan selama 20 *epoch*. Penelitian ini menunjukkan bahwa metode yang digunakan cukup efektif, meskipun masih memerlukan penyempurnaan lebih lanjut untuk meningkatkan akurasi data dan hasil klasifikasi [7].


Penelitian selanjutnya membahas mengenai pemanfaatan CNN untuk pengenalan makanan dan prediksi kalori. Studi ini menekankan potensi CNN dalam membantu pengguna, khususnya penderita diabetes, untuk mengatur asupan kalori mereka melalui aplikasi penghitungan kalori berbasis pengenalan gambar, menyoroti pentingnya pola makan sehat dalam mengatasi penyakit tidak menular di Indonesia. Pada

prosesnya melibatkan beberapa tahapan seperti *pooling*, *activation layers*, dan mengukur akurasi. Sistem ini menunjukkan akurasi kisaran 66% hingga 98% pada 20 jenis makanan [8].

Dari beberapa penelitian yang ada, dapat disimpulkan bahwa penerapan algoritma berbasis CNN menunjukkan prospek yang baik dalam mengatasi tantangan deteksi gambar, khususnya dalam konteks makanan. Penelitian ini bertujuan untuk melanjutkan pengembangan tersebut dengan menerapkan algoritma CNN untuk mendeteksi bahan makanan secara otomatis dan memberikan rekomendasi resep diet yang sesuai. Dengan pendekatan berbasis kecerdasan buatan ini, diharapkan penelitian ini mampu meningkatkan akurasi deteksi, mempermudah perencanaan pola makan sehat, dan memberikan solusi yang lebih personal serta relevan bagi kebutuhan pengguna.

2. METODE PENELITIAN

Pada metode penelitian ini mencakup langkah-langkah yang dilakukan selama penelitian. Langkah-langkah tersebut terbagi menjadi delapan bagian, yaitu: identifikasi masalah, pengumpulan data, *preprocessing* data, augmentasi data, Pembangunan model CNN, pelatihan model, evaluasi model dan implementasi model.



Gambar 1. Alur penelitian

2.1. Identifikasi Masalah

Langkah pertama dalam melakukan penelitian ini yaitu mengenali masalah yang ada dan merancang solusi yang paling sesuai. Dalam penelitian ini, perhatian utamanya terletak pada tujuan

untuk mengembangkan model berbasis CNN yang dapat secara otomatis mendeteksi bahan makanan dari citra untuk memberikan rekomendasi resep diet yang personal dan sesuai dengan kebutuhan.

2.2. Pengumpulan Data

Tahap awal dalam riset ini melibatkan proses pengumpulan data untuk mendapatkan informasi yang sesuai dan relevan dengan fokus penelitian. Data yang digunakan dalam penelitian ini merupakan citra bahan makanan mentah yang dikumpulkan dari berbagai sumber, seperti *Kaggle* dan *Roboflow*. Pada studi kasus ini kami menetapkan 12 *class* bahan makanan dengan 4 kategori yang diperinci secara lebih lengkap dalam *dataset* yang disajikan pada Tabel 1.

Tabel 1. Informasi *dataset*

NO	KELAS	BANYAK DATA
KARBOHIDRAT		
1	Kentang	500
2	Pisang	500
3	Jagung	500
PROTEIN		
4	Daging ayam	500
5	Telur	500
6	Tempe	500
7	Tahu	500
LEMAK		
8	Ikan salmon	500
9	Alpukat	500
SAYURAN		
10	Brokoli	500
11	Wortel	500
12	Sawi putih	500

2.3. Preprocessing Data

Preprocessing merupakan langkah awal yang dilakukan pada citra sebelum memasuki tahapan selanjutnya. Tahap ini sangat penting karena di sini citra akan diolah agar dapat dimodelkan lebih bagus. Pada studi kasus ini, tahap *preprocessing* meliputi pengaplikasian *noise reduction* menggunakan *Gaussian blur*

untuk memastikan citra pada dataset tidak memiliki *noise*, sehingga dapat mengoptimalkan proses pelatihan model. Penggunaan *Gaussian blur* dapat dihitung dengan rumus matematis:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$


Berfungsi untuk mengurangi *noise* dengan cara memfilter citra berdasarkan standar deviasi (σ) yang mengontrol kekuatan blur. Hasil dari penerapan *Gaussian blur* memastikan bahwa fitur-fitur penting pada citra tetap dipertahankan sambil mengurangi elemen yang tidak relevan, seperti *noise*. Selain itu dilakukan proses *splitting* data menjadi data *training* sebesar 80% dan data *testing* 20%.

2.4. Augmentasi Data

Selanjutnya yaitu tahapan augmentasi gambar, tahapan ini dilakukan untuk meningkatkan variasi dataset dengan mempertahankan karakteristik utama citra, sehingga model dapat lebih generalisasi terhadap data baru. Beberapa teknik augmentasi yang diterapkan pada studi kasus ini meliputi:

1. Rotasi acak: menerapkan rotasi hingga 30 derajat untuk meningkatkan kemampuan model dalam mengenali objek dengan orientasi berbeda.
2. Perpidahan secara horizontal/vertikal: memindahkan posisi citra secara acak hingga 20% dari lebar atau tinggi gambar untuk mensimulasikan perubahan perspektif.
3. *Sheer* transformasi: menerapkan transformasi geser pada citra untuk menciptakan variasi dalam bentuk.
4. *Zoom*: membesarkan atau mengecilkan citra hingga 20% untuk menangani objek dengan ukuran yang bervariasi.

5. *Brightness adjustment*: mengubah kecerahan citra dalam rentang 0.9 hingga 1.1 untuk mengatasi perubahan pencahayaan dalam kondisi nyata.
6. Flip horizontal: membalikkan citra secara horizontal untuk



memperluas variasi orientasi objek.

2.5. Pembangunan Model CNN

Penelitian ini menggunakan algoritma *Convolutional Neural Network* (CNN) dengan memanfaatkan arsitektur *pretrained* model VGG16 untuk mendeteksi bahan makanan berdasarkan gambar. VGG16 adalah arsitektur deep neural network yang terdiri dari 16 layer [9]. Arsitektur VGG16 ditunjukkan pada gambar 2. VGG16 mempunyai 13 *layer* *convolution*, 2 *layer* *fully connected*, dan 1 *layer* *classifier*.

Gambar 2. Arsitektur VGG16

VGG16 dipilih karena telah terbukti efektif dalam berbagai tugas klasifikasi gambar, dengan kemampuan untuk mengekstraksi fitur visual secara mendalam dari citra input. Model *pretrained* ini menggunakan bobot yang

telah dilatih pada dataset *ImageNet*, sebuah dataset besar dengan jutaan gambar dari berbagai kategori. Parameter *include_top=False* diterapkan untuk menghapus lapisan *fully connected* standar dari VGG16, sehingga dapat menyesuaikan keluaran model dengan jumlah kelas baru sesuai dataset penelitian ini. Setelah menghapus bagian atas model VGG16. Lapisan tambahan ditambahkan untuk melengkapi arsitektur CNN. Tahapan pembentukan model terdiri dari:

1. *Global Average Pooling Layer*(GAP): lapisan ini digunakan untuk mereduksi keluaran dimensi tinggi dari lapisan fitur menjadi rata-rata global untuk setiap kanal fitur. Proses ini menggantikan lapisan *flatten* konvensional, sehingga mengurangi jumlah parameter dalam model dan mengurangi risiko *overfitting*.
2. *Dense Layers (Fully Connected Layers)*: dua lapisan ditambahkan setelah GAP untuk proses klasifikasi. Lapisan pertama terdiri dari 256 *neuron* dengan fungsi aktivasi ReLu. Fungsi aktivasi *ReLu* ($f(x) = \max(0, x)$) digunakan untuk menangkap pola *non-linear* dalam data. Lapisan kedua terdiri dari 128 *neuron* dengan fungsi aktivasi *ReLu* untuk menambahkan kedalaman model, sehingga meningkatkan kemampuan deteksi fitur yang kompleks dari citra input.
3. *Output layer* dengan *Softmax Activation*: lapisan terakhir merupakan *dense layer* dengan jumlah *neuron* yang sesuai dengan jumlah kelas pada dataset, yaitu 12 kelas. Fungsi aktivasi *softmax* diterapkan pada lapisan ini untuk menghasilkan probabilitas setiap kelas. Probabilitas ini

menunjukkan seberapa besar kemungkinan suatu gambar termasuk ke dalam salah satu kelas yang ada. Rumus matematis dari *softmax* yaitu:

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}$$

Di mana z_i adalah keluaran dari setiap *neuron*, dan C adalah jumlah kelas.

2.6. Pelatihan Model

Tahapan pelatihan model melibatkan beberapa parameter utama untuk memastikan proses belajar berjalan optimal. Model dilatih menggunakan *batch* berisi 32 citra untuk memungkinkan pembaruan bobot secara bertahap, sehingga penggunaan memori lebih efisien dibandingkan dengan melatih seluruh dataset sekaligus. Proses pelatihan dilakukan selama 50 *epoch*, di mana setiap *epoch* mencakup satu putaran penuh melalui seluruh dataset, dengan jumlah yang dipilih untuk memastikan model dapat belajar secara optimal tanpa risiko *overfitting*. *Optimizer Adam* digunakan untuk mempercepat

```
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
base_model.trainable = False

model = Sequential([
    base_model,
    GlobalAveragePooling2D(),
    Dense(256, activation='relu'),
    Dense(128, activation='relu'),
    Dense(train_generator.num_classes, activation='softmax')
])

model.compile(optimizer=Adam(), loss='categorical_crossentropy', metrics=['accuracy'])
```

konvergensi model menuju nilai minimum *loss*, menggabungkan keunggulan momentum dan *adaptive learning rate*, yang sangat cocok untuk arsitektur seperti CNN. Data validasi digunakan secara berkala untuk memantau kinerja model pada data yang tidak terlihat sebelumnya, guna mengukur kemampuan generalisasi. Pada setiap *epoch*, akurasi dan *loss* dihitung untuk memantau perkembangan pelatihan dan menentukan apakah model sudah cukup terlatih atau memerlukan

penyesuaian lebih lanjut.

2.7. Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan data validasi untuk mengukur kinerja dalam mendeteksi bahan makanan. Evaluasi ini bertujuan untuk memastikan model mampu melakukan generalisasi dengan baik pada data yang tidak pernah dilihat sebelumnya. Dua metrik utama yang dihitung adalah *loss* dan akurasi. *Loss* mencerminkan tingkat kesalahan model dalam membuat prediksi, sedangkan akurasi menunjukkan persentase prediksi yang benar dari total data validasi. Proses evaluasi dilakukan dengan memanfaatkan fungsi *model evaluate*, yang secara otomatis menghitung kedua metrik tersebut berdasarkan dataset validasi.

2.8. Implementasi Model


Model yang telah dilatih dan dievaluasi kemudian diintegrasikan ke dalam website yang telah dibuat untuk setelah itu diintegrasikan dengan aplikasi mobile. Pada tahap ini, model digunakan untuk memproses gambar bahan makanan yang diunggah oleh pengguna, mengklasifikasikannya ke dalam kategori tertentu, dan merekomendasikan resep yang sesuai berdasarkan hasil deteksi. Sistem ini memanfaatkan prediksi model untuk menghasilkan rekomendasi yang personal dan relevan sesuai dengan preferensi pengguna dan ketersediaan bahan makanan. Implementasi model dilakukan dengan menggunakan format .h5, sehingga memungkinkan integrasi yang mulus dalam proses penggunaannya.

3. HASIL DAN PEMBAHASAN

Dari hasil pelatihan data yang telah dilakukan, hasil pelatihan model CNN menunjukkan performa yang optimal dengan akurasi pelatihan mencapai 96.28% dan akurasi validasi setelah dilakukan dengan 50 *epoch* sebesar 95%.

Gambar 3. Pembangunan model CNN

Nilai *loss* untuk data *training* dan validasi mengalami penurunan signifikan pada tahap awal pelatihan dan telah mencapai stabilitas setelah *epoch* ke-10 seperti yang terlihat pada grafik.



Gambar 4. Evaluasi model


Akurasi training yang lebih tinggi dibandingkan dengan akurasi validasi menunjukkan bahwa model belajar secara optimal tanpa indikasi terjadinya *overfitting*. Hal ini menunjukkan bahwa peran dari jumlah dataset yang digunakan dan penerapan *preprocessing* data seperti penggunaan *Gaussian blur* dan proses augmentasi data dapat meningkatkan kemampuan generalisasi model. Selanjutnya, dilakukan pengujian model untuk melihat hasil prediksi gambar apakah model mampu mengklasifikasikan objek dengan benar sesuai dengan label aslinya.



Gambar 5. Hasil prediksi

Berdasarkan hasil prediksi, model mampu mengklasifikasikan objek sesuai dengan label aslinya. Dari hasil ini, menandakan bahwa model memiliki performa yang baik dalam mendeteksi berbagai jenis bahan makanan. Selanjutnya, model yang telah dilatih kemudian disimpan dalam format .h5 sehingga memudahkan proses implementasi di *platform mobile* yang

dibangun. Pada aplikasi *mobile*, model yang telah ditanam mampu membaca gambar bahan makanan yang telah diunggah atau diambil melalui kamera, kemudian mengklasifikasikan jenis bahan makanan tersebut.



Gambar 6. Mockup aplikasi rekomendasi resep masakan

Setelah proses klasifikasi berhasil, aplikasi akan mengeluarkan rekomendasi resep makanan yang disesuaikan dengan preferensi diet pengguna yang telah dipilih di awal, rekomendasi tersebut memberikan informasi mengenai resep tersebut meliputi berapa kandungan karbohidrat, protein, dan lemak, serta cara membuat resep tersebut. Hasil dari rekomendasi ini memberikan solusi praktis dan efisien untuk membantu pengguna dalam merencanakan pola makan yang sehat dan sesuai dengan target diet mereka.

4. KESIMPULAN

Penelitian ini menunjukkan performa yang optimal dalam implementasi algoritma *Convolutional Neural Network* (CNN) dengan menggunakan arsitektur VGG16, VGG16 merupakan arsitektur pretrained dengan bobot *ImageNet*. Model yang telah dilatih menggunakan data gambar bahan makanan menghasilkan performa dengan akurasi pelatihan mencapai 96.28% dan akurasi validasi sebesar 95% setelah 50 *epoch*. Hasil pengujian menunjukkan bahwa model VGG16 mampu mengklasifikasikan berbagai jenis bahan makanan seperti tempe, brokoli, kentang, dan alpukat dengan benar.

Setelah model dapat mengklasifikasikan dengan baik, model kemudian disimpan dalam format .h5 dan diimplementasikan ke dalam *website*, yang selanjutnya diintegrasikan ke dalam *mobile* aplikasi. Pada aplikasi *mobile*, model digunakan dalam memberikan rekomendasi resep makanan yang sudah disesuaikan dengan preferensi diet pengguna yang telah dipilih di awal.

Penggunaan algoritma dan arsitektur ini walaupun sudah menghasilkan akurasi dan hasil deteksi yang baik, namun masih terdapat keterbatasan dalam mendeteksi, yaitu hanya bisa mendeteksi 12 bahan makanan dan belum menerapkan *multi-object detection* sehingga untuk penelitian selanjutnya disarankan untuk membuat model dengan *class* yang lebih banyak dan menerapkan konsep *multi-object detection* untuk kemudahan user dalam menentukan resep diet berdasarkan bahan makanan.

5. REFERENSI

- [1] G. R. Fikri, S. Lina, and M. Sitio, "Android Menggunakan Metode Extreme Programming," *Jurnal Ilmu Komputer dan Pendidikan*, vol. 2, no. 2, pp. 517–523, 2024.
- [2] E. S. Baihaki, "Gizi Buruk dalam Perspektif Islam: Respon Teologis Terhadap Persoalan Gizi Buruk," *SHAHIH: Journal of Islamicate Multidisciplinary*, vol. 2, no. 2, 2017, doi: 10.22515/shahih.v2i2.953.
- [3] A. F. Anisa *et al.*, "Permasalahan Gizi Masyarakat dan Upaya Perbaikannya," *Gizi Masyarakat*, vol. 40, pp. 1–22, 2017.
- [4] Unicef, "Analisis Lanskap Kelebihan Berat Badan dan Obesitas di Indonesia," *Unicef*, p. 6, 2023, [Online]. Available: [https://www.unicef.org/indonesia/](https://www.unicef.org/indonesia/media/16691/file/Ringkasan untuk Pemangku Kebijakan.pdf)
- [5] D. Vilasari, A. N. Ode, R. Sahilla, N. Febriani, and S. H. Purba, "Peran Promosi Kesehatan Dalam Meningkatkan Kesadaran Masyarakat Terhadap Penyakit Tidak Menular (PTM): Studi Literatur," *Jurnal Kolaboratif Sains*, vol. 7, no. 7, pp. 2635–2648, 2024, doi: 10.56338/jks.v7i7.5626.
- [6] C. Mahaputri, Y. Kristian, and E. Setyati, "Pengenalannya Makanan Tradisional Indonesia Beserta Bahan-bahannya dengan Memanfaatkan DCNN Transfer Learning," *Journal of Intelligent System and Computation*, vol. 4, no. 2, pp. 61–68, 2022, doi: 10.52985/insyst.v4i2.252.
- [7] M. E. Putri, M. Khairi, M. Furqan, and B. Yusman, "Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi Deteksi Objek Untuk Menghitung Perkiraan Kalori Makanan Menggunakan Metode R-CNN Mask Berbasis Web," vol. 5, no. 1, pp. 84–92, 2024.
- [8] I. P. A. E. Darma Udayana and P. G. S. C. Nugraha, "Prediksi Citra Makanan Menggunakan Convolutional Neural Network Untuk Menentukan Besaran Kalori Makanan," *Jurnal Teknologi Informasi dan Komputer*, vol. 6, no. 1, pp. 30–38, 2020, doi: 10.36002/jutik.v6i1.1001.
- [9] R. Rismiyati and A. Luthfiarta, "VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification," *Telematika*, vol. 18, no. 1, p. 37, 2021, doi: 10.31315/telematika.v18i1.4025.