



INNOVATIVE: Journal Of Social Science Research

Volume 4 Nomor 6 Tahun 2024 Page 2397-2419

E-ISSN 2807-4238 and P-ISSN 2807-4246

Website: <https://j-innovative.org/index.php/Innovative>

Pengembangan Aplikasi Klasifikasi Makanan Dengan Metode Transfer Learning Menggunakan MobilenetV2 dan Integrasi Api Nutrisi Berbasis Web

Ahmad Hidayat¹, Faqih Syarif Ash-Shiddiq², Farida Amalya³✉

Universitas Gunadarma

Email: farida_a@staff.gunadarma.ac.id¹✉

Abstrak

Penelitian ini mengembangkan aplikasi berbasis web dengan Streamlit yang mengklasifikasikan jenis makanan dari gambar menggunakan metode transfer learning, salah satu teknik machine learning, dengan model MobileNetV2. Aplikasi ini juga mengintegrasikan API Ninjas Nutrition untuk menampilkan rincian nutrisi dan menilai status kesehatan makanan sesuai dengan parameter yang telah ditetapkan. Model dilatih menggunakan dataset Food-101 yang disesuaikan, dengan menghapus kelas yang tidak dapat dipanggil oleh API dan memiliki akurasi rendah, menghasilkan 38.000 gambar dalam 76 kelas untuk pelatihan, validasi, dan pengujian. Evaluasi model menunjukkan akurasi keseluruhan sebesar 60%, dengan beberapa kelas makanan diidentifikasi dengan f1-score tinggi, namun terdapat juga kelemahan pada beberapa kelas lainnya. Data nutrisi yang diperoleh melalui API mencakup lemak total, lemak jenuh, natrium, kolesterol, dan gula, yang digunakan untuk menilai status kesehatan makanan berdasarkan pedoman WHO, AHA, UCSF, dan HaloDoc. Aplikasi ini telah di-deploy dan dapat diakses melalui <https://web-prediksi-makanandannutrisinya.streamlit.app>. Hasil pengujian menggunakan System Usability Scale (SUS) menunjukkan skor rata-rata 89,5 yang berarti B atau "excellent" dari 10 responden, mencerminkan tingkat aksesibilitas dan kenyamanan yang sangat baik.

Kata Kunci: *API Ninjas, Klasifikasi Gambar, Machine Learning, MobileNetV2, Transfer Learning*

Abstract

This study developed a web-based application with Streamlit that classifies food types from images using the transfer learning method, one of the machine learning techniques, with the MobileNetV2 model. The application also integrates the Ninjas Nutrition API to display nutritional details and assess the health status of food according to predetermined parameters. The model was trained using a customized Food-101 dataset, by removing classes that could not be called by the API and had low accuracy, resulting in 38,000 images in 76 classes for training, validation, and testing. The evaluation of the model showed an overall accuracy of 60%, with some food classes identified with high f1-scores, but there were also weaknesses in some other classes. Nutritional data obtained through the API includes total fat, saturated fat, sodium, cholesterol, and sugar, which is used to assess the health status of food based on WHO, AHA, UCSF, and HaloDoc guidelines. The app has been deployed and can be accessed via <https://web-prediksi-makanandannutrisinya.streamlit.app>. The results of the test using the System Usability Scale (SUS) showed an average score of 89.5 which means B or "excellent" of the 10 respondents, reflecting an excellent level of accessibility and convenience.

Keywords: API Ninjas, Image Classification, Machine Learning, MobileNetV2, Transfer Learning

PENDAHULUAN

Dalam era digital yang semakin maju, teknologi machine learning (ML) telah menunjukkan potensi besar dalam berbagai aspek kehidupan, termasuk membantu masyarakat menjadi lebih sadar akan nutrisi makanan yang mereka konsumsi. Machine learning, yang merupakan cabang dari kecerdasan buatan (artificial intelligence atau AI) dan ilmu komputer, memungkinkan mesin untuk belajar dari data dan menghasilkan model yang dapat membuat prediksi atau mengambil tindakan secara otomatis, seperti dalam prediksi nutrisi makanan. Machine learning meniru cara manusia belajar dengan meningkatkan akurasi seiring dengan penggunaan data dan algoritma yang lebih banyak (Eriana & Zein, 2023).

Seiring meningkatnya kesadaran masyarakat akan pentingnya gaya hidup sehat, kebutuhan akan alat berbasis website yang dapat memberikan informasi nutrisi secara cepat dan akurat semakin meningkat. Teknologi machine learning memainkan peran penting dalam mewujudkan hal ini, terutama melalui berbagai teknik seperti supervised learning dan unsupervised learning. Dalam supervised learning, model dilatih menggunakan data yang telah diberi label untuk memprediksi hasil yang tepat, sementara unsupervised learning menganalisis data tanpa label untuk menemukan pola tersembunyi. Selain itu, teknik reinforcement learning melibatkan pelatihan model melalui pendekatan

coba-coba (trial and error) guna memaksimalkan hasil berdasarkan umpan balik dari lingkungan.

Dengan fleksibilitas yang ditawarkan oleh teknik-teknik ini, machine learning telah memungkinkan pengembangan aplikasi berbasis website yang mampu mengklasifikasikan gambar makanan, menyediakan informasi nutrisi, dan membantu masyarakat membuat keputusan yang lebih baik terkait pola makan mereka. Alat seperti ini menjadi semakin relevan dalam membantu masyarakat menjaga kesehatan mereka di tengah meningkatnya prevalensi penyakit tidak menular yang disebabkan oleh gaya hidup tidak sehat.

Perkembangan teknologi informasi telah mendorong perubahan signifikan dalam cara masyarakat mengakses dan memproses informasi, terutama dalam konteks kesehatan dan nutrisi. Salah satu penerapan teknologi yang menonjol adalah dalam klasifikasi gambar (image classification), yang memungkinkan identifikasi makanan melalui foto. Image classification merupakan teknik dasar dalam visi komputer yang bertujuan untuk menentukan kategori atau kelas dari gambar input. Algoritma klasifikasi gambar, menganalisis gambar berdasarkan fitur-fitur seperti bentuk, tekstur, dan hubungan spasial, lalu memberikan label sesuai dengan objek yang terdeteksi (Paneru & Jeelani, 2021). Misalnya, algoritma dapat mengklasifikasikan gambar makanan sebagai 'buah,' 'daging,' atau 'sayuran' dengan probabilitas tertentu, yang kemudian diintegrasikan dengan database nutrisi untuk memberikan informasi rinci mengenai kandungan nutrisi dari makanan tersebut. Dalam konteks ini, proses klasifikasi makanan melalui foto sangat membantu pengguna untuk mendapatkan informasi secara real-time melalui integrasi dengan API, seperti API Ninjas Nutrition.

API (Application Programming Interface) adalah serangkaian aturan yang memungkinkan aplikasi perangkat lunak untuk saling berkomunikasi dan bertukar data, fitur, serta fungsionalitas (Goodwin, 2024). Dalam konteks klasifikasi gambar makanan, API memungkinkan aplikasi untuk mengirim permintaan data ke server dan menerima respons yang relevan secara cepat dan aman. API web, yang paling umum digunakan, mentransfer data melalui internet menggunakan protokol HTTP, memungkinkan integrasi antara aplikasi klasifikasi gambar dengan database nutrisi secara efisien. Dengan menggunakan API, pengembang dapat mempercepat proses pengembangan aplikasi tanpa perlu membangun seluruh sistem dari awal, dan pengguna dapat dengan mudah mengakses informasi nutrisi langsung dari perangkat mereka.

Untuk meningkatkan akurasi dan efisiensi dalam klasifikasi gambar, metode transfer learning sering digunakan, terutama ketika data yang tersedia sangat beragam dan mungkin tidak terstruktur dengan baik. Transfer learning adalah teknik pembelajaran mesin yang memungkinkan penggunaan model yang telah dilatih sebelumnya untuk menyelesaikan tugas-tugas baru dengan penyesuaian minimal (Urwin, 2024). Teknik ini sangat relevan dalam konteks pengenalan makanan karena memungkinkan model yang sudah dilatih pada dataset besar seperti ImageNet untuk diadaptasi guna mengklasifikasikan gambar makanan. Dengan menggunakan transfer learning, proses pengembangan model menjadi lebih cepat dan akurat, karena model telah memiliki pemahaman dasar mengenai pola-pola visual umum yang ada pada gambar. Ini sangat penting untuk alat yang dirancang untuk memberikan informasi nutrisi secara cepat dan akurat kepada pengguna.

Dalam penelitian ini, arsitektur machine learning yang digunakan adalah MobileNetV2, sebuah jaringan saraf konvolusional (CNN) yang didesain khusus untuk perangkat mobile dan telah dilatih sebelumnya pada dataset ImageNet. MobileNetV2, memanfaatkan struktur residual terbalik dan depthwise convolutions untuk meningkatkan efisiensi tanpa mengorbankan akurasi (Sandler et al., 2018). Arsitektur ini sangat cocok untuk tugas klasifikasi gambar makanan, di mana efisiensi komputasi dan kecepatan pengolahan menjadi prioritas. Dengan tambahan lapisan dense custom, model ini mampu mengklasifikasikan gambar makanan dengan lebih akurat, sementara teknik augmentasi data diterapkan untuk meningkatkan keanekaragaman data pelatihan dan mencegah overfitting, sehingga model dapat menggeneralisasi dengan baik pada data baru.

Pentingnya informasi nutrisi yang akurat juga didukung oleh berbagai pedoman internasional yang menganjurkan konsumsi makanan sehat untuk mencegah penyakit tidak menular, seperti diabetes, penyakit jantung, stroke, dan kanker. Menurut pedoman dari World Health Organization (WHO), asupan total lemak sebaiknya tidak melebihi 30% dari total energi harian, dengan lemak jenuh dibatasi hingga kurang dari 10%. WHO juga merekomendasikan pembatasan konsumsi gula bebas hingga kurang dari 10% dari total energi, serta pengurangan lebih lanjut hingga kurang dari 5% untuk manfaat kesehatan tambahan (WHO, 2020). Konsumsi garam juga harus dibatasi hingga di bawah 5 gram per hari, setara dengan asupan natrium kurang dari 2 gram per hari, sementara asupan kalium disarankan tidak kurang dari 3,5 gram per hari. WHO juga menekankan pentingnya mengonsumsi berbagai jenis makanan kaya nutrisi, termasuk buah-buahan, sayuran, kacang-kacangan, dan biji-bijian utuh, sebagai bagian dari pola makan sehat.

Selain itu, American Heart Association (AHA) merekomendasikan agar asupan kolesterol tidak melebihi 300 miligram per hari untuk mencegah hipertensi dan mengurangi risiko penyakit jantung serta stroke (Carson et al., 2020). AHA juga memberikan anjuran bahwa asupan karbohidrat harus mencapai 45% hingga 65% dari total kalori yang masuk (Merschel, 2023). Sementara itu, menurut University of California San Francisco (UCSF), konsumsi serat harian yang ideal adalah antara 25 gram hingga 30 gram untuk mendukung pola hidup yang lebih sehat (UCSF, 2024).

Kebutuhan kalori individu bervariasi berdasarkan usia, jenis kelamin, dan tingkat aktivitas fisik. Sebagai contoh, wanita berusia 19 hingga 30 tahun memerlukan sekitar 2.000 hingga 2.400 kalori per hari, sedangkan wanita di atas usia 60 tahun membutuhkan 1.600 hingga 2.000 kalori. Bagi pria, rentang kebutuhan kalori juga berkurang seiring bertambahnya usia, dari 2.400 hingga 3.000 kalori per hari pada usia 19 hingga 30 tahun, menjadi 2.000 hingga 2.600 kalori untuk pria di atas usia 60 tahun (Makarim, 2024). Sehingga dapat disimpulkan, manusia membutuhkan sekitar 2.000 kalori setiap harinya untuk mempertahankan fungsi tubuh yang optimal.

Data dari International Food Information Council (IFIC) menunjukkan bahwa sekitar 52% konsumen mengatakan bahwa mereka mengubah kebiasaan makan mereka untuk menjadi lebih sehat pada tahun 2023, menunjukkan kebutuhan yang semakin besar akan alat yang dapat membantu mereka dalam upaya ini (Food Insight, 2023). Penerapan machine learning dalam konteks ini berpotensi memberikan informasi nutrisi yang cepat dan akurat, membantu masyarakat membuat keputusan yang lebih baik terkait pola makan mereka. Meskipun terdapat tantangan seperti ketergantungan pada kualitas gambar yang diunggah dan akurasi dari database nutrisi yang digunakan, teknologi ini tetap menawarkan peluang besar untuk meningkatkan kesadaran dan pengetahuan masyarakat tentang kesehatan dan nutrisi melalui platform yang mudah diakses.

Dalam konteks pengembangan aplikasi berbasis web untuk identifikasi makanan, pendekatan konservatif menjadi penting dalam menyesuaikan skala makanan untuk memastikan akurasi dan keandalan hasil. Pendekatan ini berfokus pada penggunaan metode yang paling berhati-hati dalam menghadapi ketidakpastian dan keraguan dalam estimasi data (Darmawan, 2023). Dengan menerapkan metode konservatif, estimasi yang dihasilkan akan lebih aman dan mengurangi risiko kesalahan, walaupun mungkin mengabaikan potensi keuntungan maksimal. Hal ini menjadikan pendekatan konservatif sebagai teori yang paling sesuai untuk menyesuaikan skala makanan dalam konteks


aplikasi ini, mengingat ketidakpastian yang mungkin muncul dari variabilitas gambar dan database nutrisi.

Selain itu, evaluasi dari System Usability Scale (SUS) memberikan indikasi penting mengenai kegunaan aplikasi yang telah dikembangkan. SUS, yang dikembangkan oleh John Brooke pada tahun 1986, merupakan metode yang sederhana namun efektif untuk mengukur tingkat kegunaan produk atau layanan (Veni Manik et al., 2021). Dengan mengaplikasikan SUS, dapat diketahui bahwa aplikasi yang dibuat memenuhi kriteria usability yang baik, terbukti dari skor yang didapatkan. Evaluasi SUS menunjukkan bahwa aplikasi ini layak digunakan dan berdampak positif terhadap masyarakat, dengan hasil skor yang menunjukkan bahwa aplikasi memiliki tingkat aksesibilitas dan kenyamanan yang sangat baik.

Penelitian ini dibatasi pada pengembangan aplikasi berbasis website menggunakan Streamlit untuk mengidentifikasi jenis makanan dari gambar dengan metode transfer learning menggunakan MobileNetV2 dan menampilkan rincian nutrisi melalui integrasi API Ninjas Nutrition, yang mencakup komponen seperti lemak total, lemak jenuh, natrium, kalium, kolesterol, karbohidrat total, serat, dan gula, dengan keterbatasan pemanggilan API akibat penggunaan akun non-premium. Dataset yang digunakan terdiri dari 38.000 gambar dalam 76 kelas makanan, diambil dari Food-101 dan disesuaikan dengan kemampuan model serta integrasi API. Selain itu, status kesehatan makanan ditentukan berdasarkan pedoman WHO, AHA, UCSF, dan HaloDoc dengan klasifikasi sehat atau tidak sehat berdasarkan parameter nutrisi tertentu. Tujuan dari penelitian ini adalah mengembangkan aplikasi machine learning yang dapat mengidentifikasi jenis makanan serta memberikan rincian nutrisi secara real-time, membantu masyarakat membuat keputusan lebih baik terkait pola makan mereka dengan menyediakan informasi yang akurat dan cepat.

METODE PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah CRISP-DM (Cross Industry Standard Process for Data Mining) yang memiliki enam tahapan yang harus diselesaikan selama proses penelitian, yaitu Business Understanding (pemahaman bisnis), Data Understanding (pemahaman data), Data Preparation (persiapan data), Modeling (pemodelan), Evaluation (evaluasi), dan Deployment (penerapan) [14]. Gambar 1., yang menggambarkan alur penelitian sesuai dengan CRISP-DM.



Gambar 1. Alur Penelitian CRISP-DM

Business Understanding

Pada tahap ini, dilakukan pemahaman menyeluruh terhadap tujuan yang ingin dicapai, yaitu membangun sistem klasifikasi makanan menggunakan MobileNetV2 dan menampilkan informasi nutrisi yang terkait dengan API. Ruang lingkup proyek ditentukan, seperti pengembangan model prediksi makanan dan integrasinya ke dalam website. Identifikasi kebutuhan sumber daya perangkat keras dan lunak juga dilakukan untuk mendukung pengembangan sistem.

Data Understanding

Pada tahap ini, dataset yang digunakan adalah Food-101 dari Kaggle, yang terdiri dari 101 kelas makanan dengan 1.000 gambar per kelas. Dilakukan analisis mendalam untuk memahami distribusi data dan memastikan bahwa dataset tersebut cocok untuk melatih model klasifikasi makanan. Selain itu, data nutrisi diambil dari API Ninjas Nutrition untuk melengkapi sistem dengan informasi yang relevan. Pemahaman terhadap data ini menjadi dasar dalam membentuk model yang kuat dan relevan dengan tujuan pembuatan aplikasi.

Data Preparation

Pada tahap ini, dilakukan pembersihan dataset dan proses augmentasi data untuk meningkatkan kualitas dan keragaman data yang akan digunakan dalam pelatihan model. Gambar-gambar yang memiliki kualitas rendah atau tidak sesuai disaring, dan dilakukan pengurangan jumlah gambar untuk meminimalkan waktu pemrosesan tanpa mengorbankan performa model. Tahap ini juga melakukan pembagian data pada dataset menjadi data pelatihan, validasi, dan pengujian. Selain itu, tahap ini juga mencakup pembuatan parameter kesehatan dan parameter keterangan tambahan yang akan

diproses dan disesuaikan dengan data nutrisi dari API untuk menentukan status kesehatan makanan.

Modeling

Pada tahap ini, pengembangan model klasifikasi makanan dilakukan menggunakan arsitektur MobileNetV2. Proses ini mencakup kustomisasi layer sesuai kebutuhan, kompilasi model, serta pelatihan model menggunakan dataset yang telah dipersiapkan. Model dilatih dengan metode transfer learning untuk mempercepat pelatihan dan meningkatkan akurasi prediksi. Selain itu, teknik augmentasi data diterapkan selama pelatihan untuk mencegah overfitting. Tahap ini hanya melibatkan proses pengembangan dan pelatihan model, sedangkan evaluasi dilakukan pada tahap berikutnya.

Evaluation

Setelah model dilatih, tahap evaluasi dilakukan untuk memastikan bahwa model memiliki kinerja yang baik dalam memprediksi jenis makanan. Evaluasi dilakukan menggunakan metrik seperti classification report dan confusion matrix untuk mengukur presisi, recall, dan F1-score dari model. Pengujian dilakukan menggunakan data yang tidak digunakan dalam pelatihan untuk memastikan generalisasi model terhadap data baru.

Deployment

Pada tahap deployment, model yang telah dikembangkan dan dievaluasi diimplementasikan menggunakan framework Streamlit untuk membangun aplikasi berbasis website. Use case diagram, activity diagram, dan wireframe disiapkan untuk merancang fungsionalitas dan antarmuka pengguna aplikasi. Setelah aplikasi selesai dikembangkan, sistem di-deploy melalui GitHub dan di-hosting pada platform Streamlit di link: <https://web-prediksi-makanandannutrisinya.streamlit.app>. Selanjutnya, dilakukan pemantauan performa sistem dan penanganan bug, serta evaluasi aplikasi menggunakan System Usability Scale (SUS) untuk memastikan kepuasan pengguna dan efektivitas aplikasi dalam membantu pola hidup sehat.

HASIL DAN PEMBAHASAN

Dalam kerangka metodologi CRISP-DM, tahap business understanding dalam penelitian ini merespons kebutuhan masyarakat akan akses informasi nutrisi yang mudah dan cepat. Dengan pendekatan machine learning yang efisien serta integrasi API, penelitian ini menawarkan solusi inovatif terhadap masalah kesehatan dan gizi di era modern. Langkah-langkah penelitian meliputi persiapan data, pengembangan model

menggunakan MobileNetV2 yang telah dikustomisasi, hingga implementasi aplikasi web yang memungkinkan pengguna mengunggah gambar makanan untuk diprediksi nutrisinya secara real-time.

Semua langkah tersebut diambil untuk mencapai tujuan penelitian, yaitu mengembangkan aplikasi berbasis web yang mampu mengklasifikasikan makanan menggunakan machine learning serta menampilkan rincian nutrisinya melalui API secara real-time. Harapannya, aplikasi ini dapat membantu masyarakat membuat keputusan yang lebih baik terkait pola makan mereka. Relevansi penelitian ini semakin meningkat di tengah tren gaya hidup sehat, didukung oleh rekomendasi dari lembaga kesehatan global seperti WHO, yang menekankan pentingnya keseimbangan nutrisi untuk pencegahan penyakit.

Hasil Persiapan dan Pra-Pemrosesan Data

Pada tahap persiapan dan pra-pemrosesan data, langkah-langkah yang diterapkan mencakup pemilihan dataset, pembersihan data, penyaringan gambar, dan augmentasi data. Proses ini dilakukan untuk memastikan bahwa data yang digunakan memiliki kualitas yang memadai dan siap untuk digunakan dalam pelatihan model klasifikasi makanan. Dataset yang digunakan dalam penelitian ini adalah Food-101 dari Kaggle, yang terdiri dari 101 kelas makanan dengan total 101.000 gambar. Namun, melalui serangkaian proses penyaringan, dataset tersebut disesuaikan agar lebih relevan dengan kebutuhan penelitian.

Sebagai bagian dari tahap Data Understanding dan Data Preparation dalam metodologi CRISP-DM, data nutrisi makanan yang digunakan dalam penelitian ini diperoleh melalui API Nutrition Ninjas. API ini menyediakan informasi nutrisi detail untuk setiap makanan dalam dataset, termasuk komponen seperti kalori, total lemak, lemak jenuh, natrium, kolesterol, dan gula. API ini dipilih karena fleksibilitasnya dalam mengembalikan data nutrisi berdasarkan nama makanan yang diberikan, sehingga dapat diintegrasikan dengan mudah ke dalam model klasifikasi makanan yang dikembangkan.

Penentuan parameter kesehatan makanan dilakukan berdasarkan pedoman dari World Health Organization (WHO), American Heart Association (AHA), University of California San Francisco (UCSF), dan HaloDoc. Pedoman tersebut digunakan untuk menilai apakah suatu makanan tergolong sehat atau tidak, dengan mempertimbangkan komponen nutrisi seperti lemak, gula, garam, dan kolesterol. Nilai-nilai yang didapat dari pedoman tersebut kemudian disesuaikan dengan data nutrisi di API kemudian dilakukan

teori perkiraan konservatif dengan harapan dapat menyesuaikan nilainya dengan skala makanan di API yaitu 100 gram, yang memberikan perhitungan lebih relevan dengan porsi makanan standar dalam konteks penelitian ini. Perhitungan tersebut dapat dilihat pada Tabel 1.

Tabel 1. Hasil Perhitungan Parameter Kesehatan dan Keterangan Tambahan

Parameter	Rekomendasi Harian	Perhitungan Per 1 Porsi	Hasil (gram/miligram)
Kalori	2000 kalori	$2000/3$	666,67 kalori
Total Lemak	$\leq 30\%$ kalori	$(30\% \times 2000/9)/3$	22,22 gram
Lemak Jenuh	$\leq 10\%$ kalori	$(10\% \times 2000/9)/3$	7,4 gram
Gula	$\leq 10\%$ kalori	$(10\% \times 2000/4)/3$	16,67 gram
Natrium	≤ 2000 mg	$2000/3$	666,67 mg
Kolesterol	≤ 300 mg	$300/3$	100 mg
Serat	25 gram	$25/3$	8,33 gram
Karbohidrat	225 gram	$225/3$	75 gram
Kalium	3500 mg	$3500/3$	1166,67 mg

Berdasarkan perhitungan dari Tabel 1., dapat dilihat bahwa hasilnya belum di sesuaikan dengan teori perkiraan konservatif. Oleh karena itu, dilakukannya teori perkiraan konservatif dengan membagi nilai untuk parameter kesehatan dengan angka 2 dan dibuatkannya 3 kategori untuk parameter keterangan tambahan. Setelah penyesuaian, makanan dianggap sehat jika memiliki total lemak kurang dari 11,11 gram, lemak jenuh kurang dari 3,7 gram, natrium kurang dari 333,335 miligram, kolesterol kurang dari 50 miligram, dan gula kurang dari 8,335 gram per porsi. Selain itu, untuk parameter tambahan, serat dianggap sangat cukup jika lebih dari 8,33 gram, cukup jika lebih dari 4,165 gram, dan hampir cukup jika lebih dari 2,0825 gram. Karbohidrat dianggap sangat cukup jika lebih dari 75 gram, cukup jika lebih dari 37,5 gram, dan hampir cukup jika lebih dari 18,75 gram. Kalium dianggap sangat cukup jika lebih dari 1166,67 miligram, cukup jika lebih dari 583,335 miligram, dan hampir cukup jika lebih dari 291,6675 miligram.

Proses selanjutnya, dalam persiapan data adalah pemilihan kelas makanan yang relevan. Dari 101 kelas awal, sebanyak enam kelas dihapus karena tidak memiliki informasi nutrisi di API Nutrition Ninjas sesuai dengan pernyataan yang ada di Tabel 1. Selain itu, pada Tabel 2 dilakukan penyesuaian nama-nama kelas agar sesuai dengan nama makanannya di Indonesia, sehingga memastikan data nutrisi yang diambil relevan dengan

gambar yang tersedia. Hasilnya adalah dataset yang terdiri dari 95 kelas makanan.

Tabel 2. Rincian Daftar Kelas Makanan dan Pemetaan API

No.	Nama Makanan	Nama Lain Makanan di Indonesia	Catatan
1	apple_pie	Pai Apel	
2	baby_back_ribs	Iga Punggung	
3	baklava	Baklava	
4	beef_carpaccio	Carpaccio	
5	beef_tartare	Daging Sapi Tartar	
6	beet_salad	Salat Bit	
7	beignets	Roti Goreng Prancis	
8	bibimbap	Bibimbap	
9	bread_pudding	Puding Roti	
10	breakfast_burrito	Buritto	
11	bruschetta	Bruschetta	
12	caesar_salad	Salad Caesar	
13	cannoli	Cannoli	
14	caprese_salad	Salad Caprese	
15	carrot_cake	Kue Wortel	
16	ceviche	Ceviche	
17	cheesecake	Kue Keju	
18	cheese_plate	Piringan Keju	
19	chicken_curry	Kari Ayam	
20	chicken_quesadilla	Ayam Quesadilla	
21	chicken_wings	Sayap Ayam	
22	chocolate_cake	Kue Coklat	
23	chocolate_mousse	Coklat Mousse	
24	churros	Churros	
25	clam_chowder	Sup Krim Kerang	
26	club_sandwich	Sandwich Club	
27	crab_cakes	Kue Kepiting	
28	creme_brulee	Crème Brulee	
29	croque_madame	Madam Croque	Tidak Terpanggil di API
30	cup_cakes	Kue Cangkir	
31	deviled_eggs	Telur Isi	
32	donuts	Donat	

33	dumplings	Pangsit	
34	edamame	Kedelai Jepang	
35	eggs_benedict	Telur Benedict	
36	escargots	Siput	
37	falafel	Falafel	
38	filet_mignon	Daging Sapi Filet	
39	fish_and_chips	Ikan dan Kentang Goreng	
40	foie_gras	Foie Gras	
41	french_fries	Kentang Goreng	
42	french_onion_soup	Sup Bawang Merah	
43	french_toast	Roti Panggang Prancis	
44	fried_calamari	Calamari	
45	fried_rice	Nasi Goreng	
46	frozen_yogurt	Yogurt	
47	garlic_bread	Roti Bawang Putih	
48	gnocchi	Gnocchi	
49	greek_salad	Salad Yunani	
50	grilled_cheese_sandwich	Sandwich Keju Panggang	
51	grilled_salmon	Salmon Panggang	
52	guacamole	Guacamole	
53	gyoza	Gyoza	
54	hamburger	Hamburger	
55	hot_and_sour_soup	Sup Asam Pedas	
56	hot_dog	Hot Dog	
57	huevos_rancheros	Huevos Rancheros	
58	hummus	Hummus	
59	ice_cream	Es Krim	
60	lasagna	Lasagna	
61	lobster_bisque	Lobster Bisque	
62	lobster_roll_sandwich	Sandwich Lobster Gulung	Tidak Terpanggil di API
63	macaroni_and_cheese	Makaroni dan Keju	
64	macarons	Makaron	
65	miso_soup	Sop Miso	
66	mussels	Kerang	
67	nachos	Nacho	
68	omelette	Omelet	

69	onion_rings	Cincin Bawang	
70	oysters	Tiram	
71	pad_thai	Pad Thai	
72	paella	Paella	
73	pancakes	Panekuk	
74	panna_cotta	Panna Cotta	
75	peking_duck	Bebek Peking	
76	pho	Pho	
77	pizza	Pizza	
78	pork_chop	Daging Babi	
79	poutine	Poutine	
80	prime_rib	Iga Utama	
81	pulled_pork_sandwich	Sandwich Babi Suwir	
82	ramen	Ramen	
83	ravioli	Ravioli	
84	red_velvet_cake	Kue Red Velvet	Tidak Terpanggil di API
85	risotto	Risotto	
86	samosa	Samosa	
87	sashimi	Sashimi	
88	scallops	Simping	
89	seaweed_salad	Salad Rumput Laut	
90	shrimp_and_grits	Bubur Udang	
91	spaghetti_bolognese	Spageti Bolognese	
92	spaghetti_carbonara	Spageti Carbonara	Tidak Terpanggil di API
93	spring_rolls	Lumpia	
94	steak	Steak	
95	strawberry_shortcake	Kue Stroberi	
96	sushi	Sushi	
97	tacos	Taco	
98	takoyaki	Takoyaki	Tidak Terpanggil di API
99	tiramisu	Tiramisu	
100	tuna_tartare	Tuna Tartar	Tidak Terpanggil di API
101	waffles	Wafel	

Langkah berikutnya adalah pembersihan gambar, di mana gambar-gambar buram atau yang tidak sesuai dengan kelas makanannya dihapus. Lalu terjadinya pembersihan

secara acak, sehingga datasetnya terdiri dari 95 kelas dengan masing-masing 500 gambar per kelas. Gambar-gambar yang tersisa kemudian diatur dalam direktori yang memudahkan proses pelatihan model, dengan ukuran gambar diseragamkan menjadi 224x224 piksel sesuai dengan arsitektur model MobileNetV2. Setiap batch pelatihan terdiri dari 32 gambar, yang diproses secara bersamaan dalam satu iterasi selama pelatihan model.

Pada tahap pra-pemrosesan, augmentasi data diterapkan untuk memperluas variasi gambar tanpa menambah dataset secara langsung. Teknik augmentasi seperti rotasi, zoom, flipping horizontal, dan pergeseran lebar digunakan untuk meningkatkan ketahanan model terhadap variasi gambar yang contohnya dapat dilihat pada Gambar 2. Selain itu, dataset dibagi menjadi subset pelatihan dan validasi dengan rasio 80:20, yang memungkinkan pengujian kinerja model secara lebih akurat selama proses pelatihan. Hasil dari seluruh proses ini adalah dataset yang siap digunakan untuk membangun model klasifikasi makanan yang andal dan relevan.



Gambar 2. Contoh Hasil Augmentasi

Hasil Pengembangan dan Pelatihan Model

Pada tahap pengembangan, model yang digunakan dalam penelitian ini adalah MobileNetV2, yang sudah di-pretrain dengan dataset ImageNet. MobileNetV2 dipilih karena efisiensinya dalam menangani tugas klasifikasi gambar, terutama dengan jumlah parameter yang lebih kecil dibandingkan model lainnya, tanpa mengorbankan akurasi. Dengan mengimpor MobileNetV2 tanpa top layer, model ini dapat dimodifikasi lebih lanjut untuk disesuaikan dengan tugas klasifikasi makanan yang lebih spesifik. Dalam hal ini, arsitektur model diadaptasi dengan menambahkan lapisan-lapisan baru di atas output MobileNetV2. Tahap ini melibatkan penambahan beberapa lapisan Dense yang bertujuan untuk meningkatkan kemampuan model dalam mengenali fitur-fitur yang lebih kompleks


pada gambar makanan.

MobileNetV2 disiapkan dengan parameter trainable disetel ke False, yang berarti bobot dari MobileNetV2 tidak akan diperbarui selama proses pelatihan. Hal ini membantu mempertahankan kemampuan generalisasi yang telah dipelajari dari dataset ImageNet. Kemudian, output dari MobileNetV2, yang berupa fitur hasil pooling rata-rata global, digunakan sebagai masukan untuk lapisan-lapisan kustom yang terdiri dari dua lapisan Dense dengan aktivasi ReLU dan satu lapisan Dense akhir dengan aktivasi softmax, yang berfungsi untuk mengklasifikasikan gambar ke dalam kelas-kelas makanan yang telah ditentukan.


Setelah arsitektur model selesai disesuaikan, proses kompilasi dilakukan. Optimizer Adam dipilih karena fleksibilitasnya dalam menyesuaikan learning rate secara otomatis, sementara fungsi loss yang digunakan adalah categorical crossentropy, yang tepat untuk tugas klasifikasi multi-kelas. Akurasi dipilih sebagai metrik evaluasi kinerja model selama pelatihan.

Proses pelatihan model dilakukan menggunakan dataset gambar makanan yang telah disiapkan, dengan augmentasi data untuk meningkatkan variasi gambar selama pelatihan. Pelatihan dijalankan selama maksimal 100 epoch, namun model dilengkapi dengan callback EarlyStopping untuk menghentikan pelatihan lebih awal jika tidak ada perbaikan pada validation loss selama lima epoch berturut-turut. Dengan adanya mekanisme ini, model dapat menghindari overfitting, dan model yang disimpan adalah model terbaik yang memiliki performa optimal pada dataset validasi.

Hasil dari pelatihan yang dapat dilihat pada Gambar 3. dan Gambar 4., menunjukkan bahwa pelatihan dihentikan pada epoch ke-12 karena tidak ada perbaikan pada validation loss. Grafik pelatihan menunjukkan bahwa training accuracy terus meningkat sementara validation accuracy cenderung stabil setelah beberapa epoch, mengindikasikan potensi overfitting. Meski training loss menurun dengan cepat, validation loss hanya menunjukkan penurunan kecil yang stabil setelah beberapa epoch, yang mengisyaratkan bahwa model lebih unggul dalam mengenali pola pada data pelatihan namun tidak cukup baik dalam generalisasi terhadap data baru. Model akhir yang berhasil dilatih kemudian disimpan dengan nama "mobilenetv2_food_classification_finalmodel.keras" untuk digunakan dalam prediksi selanjutnya.



Gambar 3. Grafik Accuracy Hasil Pelatihan



Gambar 4. Grafik Loss Hasil Pelatihan

Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengukur seberapa baik model dapat melakukan prediksi pada data yang belum pernah dilihat sebelumnya. Berdasarkan hasil evaluasi awal, ditemukan bahwa model mengalami kesulitan dalam mengklasifikasikan 19 kelas makanan, termasuk apple pie, burrito, grilled cheese sandwich, dan lainnya, dengan F1 score di bawah 30%. Ini menunjukkan bahwa model gagal mengenali kelas-kelas tersebut dengan baik, baik pada data uji maupun input dari pengguna. Akurasi rata-rata model secara keseluruhan hanya mencapai 48,32%, yang ditunjukkan pada Gambar 5.


```

297/297 ————— 167s 557ms/step
Jumlah kelas pada data validasi: 95
Jumlah kelas yang terbaca oleh validation_generator: 95
Akurasi model: 48.32%
Classification Report:

```

	precision	recall	f1-score	support
apple_pie	0.346939	0.170000	0.228188	100.000000
baby_back_ribs	0.534247	0.390000	0.450867	100.000000
baklava	0.394366	0.560000	0.462810	100.000000
beef_tartare	0.444444	0.440000	0.442211	100.000000
beet_salad	0.357143	0.300000	0.326087	100.000000
beignet	0.657658	0.730000	0.691943	100.000000
bibimbap	0.642202	0.700000	0.669856	100.000000
bread_pudding	0.317073	0.130000	0.184397	100.000000
bruschetta	0.590909	0.260000	0.361111	100.000000
burrito	0.666667	0.380000	0.484076	100.000000
caesar_salad	0.515464	0.500000	0.507614	100.000000
calamari	0.464567	0.590000	0.519824	100.000000
cannoli	0.529412	0.540000	0.534653	100.000000
caprese_salad	0.353846	0.460000	0.400000	100.000000
carpaccio	0.583333	0.560000	0.571429	100.000000
carrot_cake	0.622642	0.330000	0.431373	100.000000
ceviche	0.354839	0.220000	0.271605	100.000000
cheese_plate	0.767442	0.330000	0.461538	100.000000
cheesecake	0.341463	0.280000	0.307692	100.000000
...				
yogurt	0.807692	0.630000	0.707865	100.000000
accuracy	0.483158	0.483158	0.483158	0.483158
macro avg	0.497995	0.483158	0.476294	9500.000000
weighted avg	0.497995	0.483158	0.476294	9500.000000

Gambar 5. Hasil Classification Report 95 Kelas Makanan Dengan Data Validasi

Untuk meningkatkan performa, 19 kelas makanan yang sulit dikenali ini dihapus dari dataset, menyisakan 76 kelas yang digunakan untuk melatih ulang model. Hasil pelatihan ulang dapat dilihat pada Gambar 6., yang menunjukkan peningkatan yang cukup signifikan, dengan akurasi rata-rata mencapai 55,97% per kelas makanan. Meski demikian, terdapat satu kelas makanan, yaitu ceviche, yang masih memiliki F1 score di bawah 30%, sementara kelas lainnya, seperti edamame, menunjukkan performa yang sangat baik dengan F1 score di atas 90%. Hasil ini mengindikasikan bahwa meskipun model mengalami peningkatan performa, masih ada beberapa kelas yang sulit dikenali dan membutuhkan perbaikan lebih lanjut.

```

... Found 7600 images belonging to 76 classes.
238/238 ————— 138s 574ms/step
Jumlah kelas pada data validasi: 76
Jumlah kelas yang terbaca oleh validation_generator: 76
Akurasi model: 55.97%
Classification Report:


```

	precision	recall	f1-score	support
baby_back_ribs	0.483146	0.430000	0.455026	100.000000
baklava	0.496350	0.680000	0.573840	100.000000
beef_tartare	0.520408	0.510000	0.515152	100.000000
beet_salad	0.528571	0.370000	0.435294	100.000000
beignet	0.666667	0.740000	0.701422	100.000000
bibimbap	0.626984	0.790000	0.699115	100.000000
bruschetta	0.236052	0.550000	0.330330	100.000000
caesar_salad	0.457143	0.640000	0.533333	100.000000
cannoli	0.769231	0.400000	0.526316	100.000000
caprese_salad	0.457944	0.490000	0.473430	100.000000
carrot_cake	0.571429	0.440000	0.497175	100.000000
ceviche	0.461538	0.180000	0.258093	100.000000
cheese_plate	0.398936	0.750000	0.520833	100.000000
cheesecake	0.279661	0.330000	0.302752	100.000000
chicken_curry	0.490196	0.250000	0.331126	100.000000
chicken_quesadilla	0.528302	0.560000	0.543689	100.000000
chicken_wings	0.564103	0.660000	0.608295	100.000000
chocolate_cake	0.466019	0.480000	0.472906	100.000000
...				
waffles	0.685714	0.480000	0.564706	100.000000
accuracy	0.559737	0.559737	0.559737	0.559737
macro avg	0.581456	0.559737	0.558487	7600.000000
weighted avg	0.581456	0.559737	0.558487	7600.000000

Gambar 6. Hasil Classification Report 76 Kelas Makanan Dengan Data Validasi

Evaluasi performa model juga ditunjukkan melalui confusion matrix yang dapat dilihat pada Gambar 7., yang Dimana memperlihatkan bahwa sebagian besar prediksi

benar berada pada elemen diagonal, menunjukkan bahwa model dapat mengidentifikasi gambar dengan benar. Namun, beberapa kesalahan prediksi masih terjadi pada kelas makanan yang memiliki kemiripan visual, seperti ceviche yang sering disalahartikan sebagai bruschetta atau gnocchi yang sering diprediksi sebagai risotto. Kesalahan ini kemungkinan disebabkan oleh kemiripan visual antara makanan-makanan tersebut, terutama dari segi warna dan tekstur.




Gambar 7. Hasil Confusion Matrix 76 Kelas Makanan Dengan Data Uji

Selanjutnya, pengujian akhir dilakukan menggunakan 7.600 gambar dari dataset uji, dengan setiap kelas terdiri dari 100 gambar. Hasilnya dapat dilihat pada Gambar 8., model mencapai akurasi sebesar 60% pada data uji, sedikit lebih tinggi dibandingkan akurasi pada data validasi yang sebesar 55,97%. Perbedaan akurasi ini mungkin disebabkan oleh variasi distribusi data antara set validasi dan set uji, atau faktor acak lainnya. Selain itu, model juga diuji pada gambar dari sumber eksternal yang dapat dilihat pada Gambar 9., di mana model berhasil mengenali gambar ramen dengan tingkat kepercayaan sebesar 94%. Hal ini menunjukkan bahwa model memiliki fleksibilitas dan potensi yang baik untuk digunakan dalam aplikasi dunia nyata.

```
self._warn_if_super_not_called()
238/238 125s 518ms/step
Akurasi Model: 0.60
Classification Report:
```

	precision	recall	f1-score	support
baby_back_ribs	0.53	0.55	0.54	100
baklava	0.51	0.74	0.61	100
beef_tartare	0.65	0.44	0.52	100
beet_salad	0.42	0.32	0.36	100
beignet	0.66	0.85	0.74	100
bibimbap	0.60	0.86	0.71	100
bruschetta	0.31	0.51	0.39	100
caesar_salad	0.49	0.61	0.54	100
cannoli	0.81	0.42	0.55	100
caprese_salad	0.43	0.52	0.47	100
carrot_cake	0.67	0.46	0.54	100
ceviche	0.56	0.24	0.34	100
cheese_plate	0.44	0.74	0.55	100
cheesecake	0.34	0.37	0.35	100
chicken_curry	0.64	0.34	0.44	100
chicken_quesadilla	0.58	0.58	0.58	100
chicken_wings	0.62	0.70	0.66	100
chocolate_cake	0.54	0.45	0.49	100
churros	0.59	0.72	0.65	100
clam_chowder	0.59	0.79	0.68	100
...				
accuracy			0.60	7600
macro_avg	0.62	0.60	0.59	7600
weighted_avg	0.62	0.60	0.59	7600

Gambar 8. Hasil Classification Report 76 Kelas Makanan Dengan Data Uji



Gambar 9. Hasil Pengujian Model Dengan Data Gambar Diluar Dataset


Hasil Implementasi dan Pengujian Aplikasi Berbasis Website

Implementasi program dilakukan dengan membangun aplikasi berbasis web menggunakan framework Streamlit. Tujuan utama dari aplikasi ini adalah menyediakan antarmuka interaktif yang memungkinkan pengguna mengunggah gambar makanan dan mendapatkan hasil prediksi jenis makanan beserta informasi nutrisinya. Aplikasi ini berhasil di-deploy dan dapat diakses melalui tautan: <https://web-prediksi-makanandannutrisinya.streamlit.app>. Pembangunan aplikasi ini mengacu pada tahap deployment dalam metodologi CRISP-DM, yang memastikan aplikasi tersedia untuk pengguna akhir.

Dalam implementasinya, aplikasi ini menggunakan berbagai pustaka, termasuk TensorFlow untuk memuat model klasifikasi yang dilatih, serta PIL untuk memproses gambar. API dari Nutrition Ninjas diintegrasikan untuk memberikan informasi nutrisi berdasarkan hasil klasifikasi. Aplikasi dirancang sedemikian rupa sehingga pengguna hanya perlu mengunggah gambar makanan, dan aplikasi akan menampilkan jenis makanan yang dikenali oleh model beserta skor kepercayaan prediksi. Selain itu, aplikasi juga menyajikan informasi nutrisi, seperti kalori, lemak, protein, dan kandungan lainnya yang relevan, serta mengevaluasi status kesehatan makanan tersebut.


Tampilan antarmuka aplikasi dibuat sederhana dan mudah digunakan, dengan fitur-fitur utama yang tersusun secara sistematis seperti yang ditunjukkan pada Gambar 10.. Pada halaman utama, pengguna akan menemukan tombol unggah gambar makanan yang dilengkapi dengan instruksi jelas. Setelah gambar diunggah, hasil prediksi makanan dan informasi nutrisi ditampilkan di bagian bawah halaman. Untuk memudahkan

pengguna dalam memahami jenis makanan yang dapat diklasifikasikan oleh model, disediakan pula bagan yang menampilkan 76 kelas makanan dalam format grid yang teratur.



Gambar 10. Kumpulan Hasil Tampilan Aplikasi

Proses deployment aplikasi dilakukan melalui GitHub dan di-hosting di platform Streamlit, yang memungkinkan pengelolaan dan penyebaran aplikasi secara cepat tanpa memerlukan konfigurasi server yang kompleks. Setelah di-deploy, aplikasi diuji melalui serangkaian uji coba mandiri untuk memastikan bahwa semua fungsi bekerja sesuai harapan yang dapat dilihat pada Gambar 11.. Hasil pengujian menunjukkan bahwa aplikasi dapat digunakan dengan lancar tanpa masalah teknis, dan seluruh fitur yang telah dirancang, termasuk klasifikasi makanan dan penarikan data nutrisi, berfungsi dengan baik.



Gambar 11. Hasil Pengujian Mandiri Aplikasi

Hasil Evaluasi Akhir

Evaluasi akhir dilakukan untuk menilai tingkat kegunaan dan kenyamanan aplikasi

berbasis web yang telah dikembangkan. Salah satu metode yang digunakan adalah System Usability Scale (SUS), sebuah alat evaluasi yang umum digunakan untuk mengukur pengalaman pengguna terhadap aplikasi. Dalam penelitian ini, sebanyak 10 responden dilibatkan untuk memberikan penilaian terhadap aplikasi menggunakan kuesioner SUS.

Berdasarkan hasil evaluasi yang dirangkum dalam Tabel 3, skor rata-rata SUS yang diperoleh adalah 89,5. Nilai ini menunjukkan bahwa aplikasi berada dalam kategori grade B dengan predikat "Excellent", yang berarti bahwa pengguna merasa sangat nyaman dan mudah dalam mengoperasikan aplikasi ini. Penilaian ini mencerminkan keberhasilan dari sisi desain antarmuka dan pengalaman pengguna (user experience), di mana aplikasi dinilai intuitif dan mudah diakses.

Tabel 3. Hasil Perhitungan SUS dari 10 Responden

1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Jumlah Skor	Nilai SUS
4	4	4	3	4	4	4	3	4	4	38	95
3	4	4	4	3	2	4	4	4	4	36	90
3	3	3	4	3	2	3	3	1	4	29	72,5
4	4	4	4	4	3	3	2	3	3	34	85
3	4	4	4	3	4	4	4	4	4	38	95
4	4	4	4	4	4	4	4	4	4	40	100
3	4	4	4	3	3	3	4	4	4	36	90
4	4	4	4	4	4	4	4	4	4	40	100
3	2	4	4	4	3	4	4	4	2	34	85
3	3	4	4	3	2	3	4	4	3	33	82,5
Hasil Akhir (Rata-Rata Nilai Skor SUS)											89,5

Skor SUS yang tinggi juga mengindikasikan bahwa aplikasi mampu memenuhi harapan pengguna, terutama dalam hal aksesibilitas, responsivitas, dan kinerja keseluruhan. Pengguna dapat dengan mudah memahami cara kerja aplikasi, mulai dari mengunggah gambar makanan hingga mendapatkan hasil prediksi dan informasi nutrisi. Kesederhanaan dalam desain dan navigasi turut memberikan kontribusi besar terhadap kenyamanan pengguna, sehingga aplikasi ini dinilai sukses dari aspek kegunaan dan efektivitas fungsional.

Secara keseluruhan, hasil evaluasi akhir melalui metode SUS menegaskan bahwa aplikasi ini telah memenuhi kriteria kualitas yang diharapkan, baik dari sisi teknis maupun pengalaman pengguna. Predikat "Excellent" yang diraih dalam evaluasi ini menjadi bukti bahwa aplikasi berbasis web ini layak digunakan dan diimplementasikan secara luas untuk

klasifikasi makanan dan penelusuran informasi nutrisi.

SIMPULAN

Penelitian ini telah berhasil mengembangkan aplikasi klasifikasi makanan berbasis web dengan metode transfer learning menggunakan MobileNetV2, yang mampu mengidentifikasi jenis makanan dari gambar dan memberikan rincian nutrisi secara real time melalui integrasi API, serta membantu masyarakat dalam membuat keputusan yang lebih baik terkait pola makan mereka, aplikasi ini juga telah di-deploy dan dapat diakses secara online.

Dari hasil evaluasi menggunakan Classification Report dan Confusion Matrix, aplikasi ini menunjukkan hasil yang cukup berhasil dengan akurasi keseluruhan model mencapai 60%. Meskipun model ini mampu mengidentifikasi beberapa jenis makanan dengan presisi dan recall yang tinggi yaitu di atas 60%, seperti pada kategori "edamame". Akan tetapi, terdapat juga beberapa performa yang buruk seperti "ceviche" yang dimana menunjukkan f1-score rendah yaitu di bawah 40%.

Selain itu, hasil evaluasi terhadap tingkat kepuasan pengguna menggunakan System Usability Scale (SUS) menunjukkan bahwa aplikasi ini memiliki tingkat aksesibilitas dan kenyamanan yang sangat baik. Berdasarkan hasil perhitungan SUS, diperoleh skor rata-rata sebesar 89,5, yang memberikan grade B dengan penilaian 'Excellent'. Skor ini mengindikasikan bahwa pengguna merasa nyaman dan mudah dalam menggunakan aplikasi, sehingga aplikasi ini memiliki potensi yang kuat untuk diterima secara luas oleh masyarakat.

DAFTAR PUSTAKA

- Carson, J. A. S., Lichtenstein, A. H., Anderson, C. A. M., Appel, L. J., Kris-Etherton, P. M., Meyer, K. A., Petersen, K., Polonsky, T., & Van Horn, L. (2020). Dietary Cholesterol and Cardiovascular Risk: A Science Advisory from the American Heart Association. *Circulation*, 141(3), E39–E53. <https://doi.org/10.1161/CIR.0000000000000743>
- Darmawan, I. M. D. H. (2023). Membedah Prinsip Pelaporan Konservatisme Akuntansi: Pro Kontra, Kegunaan Dan Pertimbangan Untuk Pemangku Kepentingan. *Jurnal Maneksi*, 12(2), 410–416. <https://doi.org/10.31959/jm.v12i2.1531>
- Eriana, E. S., & Zein, A. (2023). *Artificial Intelligence (AI)*. EUREKA MEDIA AKSARA.
- Food Insight. (2023). Food and Health Survey. International Food Information Council. In *Food and Health Survey. International Food Information Council* (pp. 38–74).

- Goodwin, M. (2024). *What is an API (application programming interface)? IBM*.
- Makarim, F. R. (2024). Catat, Ini Jumlah Minimal Kalori yang Harus Dipenuhi saat Diet. *Halodoc*.
- Merschel, M. (2023). Confused about carbs? This Might Help. *American Heart Association News*.
- Paneru, S., & Jeelani, I. (2021). *Version of Record*: <https://www.sciencedirect.com/science/article/pii/S0926580521003915>.
- Sandler, M., Howard, A., Zhu, M., & Zhmoginov, A. (2018). Sandler_MobileNetV2_Inverted_Residuals_CVPR_2018_paper.pdf. *ArXiv*, 4510–4520.
- UCSF. (2024). Increasing Fiber Intake. *UCSF Health*.
- Urwin, M. (2024). *What Is Transfer Learning? Exploring the Popular Deep Learning Approach. Builtin*.
- Veni Manik, Hetty Primasari, C., Yohanes Priadi Wibisono, & Aloysius Bagas Pradipta Irianto. (2021). Evaluasi Usability pada Aplikasi Mobile ACC.ONE menggunakan System Usability Scale (SUS) dan Usability Testing. *Jurnal Sains Dan Informatika*, 7(1), 1–10. <https://doi.org/10.34128/jsi.v7i1.286>
- WHO. (2020). *Healthy Diet. WHO*.