

Klasifikasi Citra Makanan Khas Kota Pasuruan menggunakan Convolutional Neural Network

Erfan Zidni¹, Mutaqin Akbar²

^{1,2}Program Studi Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta

¹erfanzidni14@gmail.com, ²mutaqin@mercubuana-yogya.ac.id

ABSTRACT

Typical food is an important part of Indonesia's cultural and social heritage, with each region having its own unique identity and characteristics. These variations are influenced by geographical location, distribution of spices, and local habits, creating distinctive flavors and various serving variations. Several typical dishes from Pasuruan City, such as BipangANGKAr, Botok Tempe, Cenil, and Klepon, are famous among the people. Even though it is familiar to most people, it is sometimes difficult for people to clearly distinguish types of food typical of other regions, especially if there are similarities in form or presentation. In this context, researchers consider it necessary to conduct research related to the image classification of typical food in Pasuruan City. For this purpose, the Convolution Neural Network (CNN) algorithm is used, a type of neural network specifically designed for processing visual or image data. CNNs are effective for object recognition and detection in images, with the ability to achieve high accuracy and satisfactory results. This research includes 1000 data on typical food from Pasuruan City, focusing on four types of food, namely BipangANGKAr, Botok Tempe, Cenil, and Klepon. Through the use of a single Graphical Processing Unit (GPU) in scenario 2, training time was successfully reduced to 335 seconds. The results show that with a configuration of 32 filters in the first convolution, 64 in the second convolution, and 128 in the third convolution, the model is able to produce a lower error value, namely 0.7438, with an accuracy of 100%.

Keyword: Classification, Typical Food, Pasuruan City, Image, Deep Learning, *Convolutional Neural Network*

1. Pendahuluan

Makanan adalah suatu substansi atau materi yang dikonsumsi oleh makhluk hidup, termasuk manusia. Asal-usul makanan dapat bervariasi, mencakup sumber-sumber seperti tumbuhan (seperti sayuran, buah-buahan, dan biji-bijian), hewan (termasuk daging, ikan, dan produk susu), serta produk makanan yang telah diolah. Tiap wilayah memiliki makanan khasnya sendiri, mencerminkan karakteristik unik dari daerah tersebut. Keberagaman kuliner regional memiliki peran yang signifikan dalam membentuk budaya, tradisi, dan gaya hidup suatu masyarakat. Makanan khas daerah bukan hanya menjadi bagian dari aspek kuliner, tetapi juga memiliki nilai sosial dan psikologis yang berdampak pada identitas dan kebanggaan masyarakat setempat. Tiap daerah menonjolkan keunikan cita rasa makanannya dengan variasi tampilan penyajian yang khas. Makanan khas tidak hanya menjadi simbol identitas kelompok masyarakat yang mengonsumsinya, melainkan juga berperan sebagai alat untuk mempersatukan bangsa dan memupuk rasa cinta terhadap tanah air [1].

Pasuruan, sebuah kota dan kabupaten yang terletak di sepanjang pantai utara Jawa Timur, menempati posisi strategis di jalur utama yang menghubungkan Pulau Jawa dan Pulau Bali. Kehadirannya sebagai titik persinggahan seringkali menarik minat para pelancong. Pasuruan membanggakan berbagai variasi masakan dan hidangan khususnya, termasuk Kupang Kraton, Rawon, Sate Komoh, Nasi Punel, Klepon, Botok Tempe, Bipang Jangkar, dan Cenil Pasuruan. Keberagaman kuliner yang dimiliki oleh kota Pasuruan menjadi motivasi bagi peneliti untuk memperkenalkan kekayaan kuliner khususnya. Tujuannya adalah agar ragam kuliner Pasuruan dapat dikenal tidak hanya di tingkat nasional, tetapi juga internasional. Ada beberapa metode yang dapat digunakan untuk mengklasifikasikan gambar makanan khas Kota Pasuruan, seperti Analisis Komponen Minor, Analisis Segmentasi *Fuzzy C-Means*, *Convolutional Neural Network* (CNN), dan beberapa pendekatan lainnya.

Analisis Komponen Minor (MCA), juga dikenal sebagai Analisis Subspasi Minor (MSA), merupakan metode statistika yang digunakan untuk mengidentifikasi varian terkecil dalam suatu *dataset* [2]. *Fuzzy C-Means* (FCM) Clustering merupakan suatu metode pengelompokan data yang merupakan generalisasi dari algoritma C-Means dengan memasukkan konsep tingkat keanggotaan *fuzzy*. Dalam FCM, setiap titik data memiliki tingkat keanggotaan terhadap setiap kluster, yang berbeda dengan pendekatan pada C-Means di mana titik data dapat menjadi anggota atau bukan anggota kluster secara tegas [3]. Dalam penelitian ini, diusulkan pengklasifikasi makanan khas Kota Pasuruan dengan memanfaatkan CNN.

2. Landasan Teori

2.1. Makanan Khas

Makanan adalah istilah yang merujuk pada pangan yang telah mengalami proses pengolahan dan siap untuk dikonsumsi. Bahan-bahan yang dapat dikonsumsi sehari-hari, baik dalam bentuk padat maupun cair, digunakan untuk memenuhi kebutuhan nutrisi tubuh disebut sebagai makanan [4].

Makanan tidak hanya menjadi bagian integral dari kehidupan sehari-hari, tetapi juga mencerminkan ruang budaya dan sosial yang selalu dipengaruhi oleh peristiwa terkini. Sebagai ekspresi identitas sosial, makanan memiliki peran dalam menghubungkan manusia dengan seluruh makhluk hidup. Ketika kita berbicara tentang masakan daerah, kita merujuk pada hidangan khas dari suatu wilayah tertentu, yang memiliki cita rasa unik yang berbeda dari hidangan biasa dan populer di kalangan penduduk setempat. Penyajian masakan daerah seringkali melibatkan penggunaan bahan-bahan tradisional dan rempah-rempah lokal, memberikan sentuhan istimewa dan menarik perhatian bagi mereka yang baru pertama kali mengalami hidangan tersebut. Penduduk setempat cenderung memiliki kontrol yang signifikan terhadap proses pengolahan makanan khas daerah tersebut [5].

Kota Pasuruan, terletak di provinsi Jawa Timur, Indonesia, berjarak 60 km ke arah tenggara dari Kota Surabaya, ibu kota Provinsi Jawa Timur, dan 355 km ke arah barat laut dari Kota Denpasar, Bali. Wilayah ini dikenal karena cita rasa makanannya yang cenderung memiliki tingkat kepedasan. Banyak hidangan khas Pasuruan disiapkan dengan metode seperti merebus, menggoreng, atau memanggang, dengan terasi sebagai salah satu bumbu yang sering digunakan. Beberapa contoh masakan khas Kota Pasuruan yang telah dikenal luas antara lain bipang jangkar, cenil, krepon, dan sebagainya. Meski demikian, masih banyak masyarakat yang keliru mengira bahwa makanan khas Kota Pasuruan serupa dengan makanan khas kota lain di Indonesia, hal ini mungkin disebabkan oleh kemiripan dalam penyajian atau bentuknya, seperti pada Gambar 1 dan Gambar 2.



Gambar 1. Bipang Jangkar



Gambar 2. Botok Tempe

2.2. Citra

Citra adalah representasi dua dimensi dari bentuk fisik tiga dimensi yang sebenarnya. Penafsiran ulang representasi visual dapat bervariasi dari gambar diam (statis) dalam foto hingga gambar berwarna bergerak di layar televisi. Proses perubahan wujud tiga dimensi menjadi wujud dua dimensi untuk menghasilkan suatu gambar dipengaruhi oleh banyak faktor berbeda yang menyebabkan bayangan suatu benda tidak selalu menyerupai bentuk fisik sebenarnya. Faktor-faktor tersebut antara lain memudar atau hilangnya efek kualitas, tercermin pada objek dengan rentang kontras yang terlalu sempit atau terlalu lebar, distorsi geometris, skala abu-abu, keburaman gerakan objek *video*, keburaman gerakan, serta noise atau interferensi yang dapat disebabkan oleh *noise*. dari produsen pencitraan, baik probe, elektronik, atau *optic* [6]. Dalam konteks penelitian, terdapat beberapa jenis citra yang secara umum digunakan, antara lain sebagai berikut:

1. Citra Biner

Pada citra digital *biner*, setiap piksel memiliki dua nilai eksklusif, yaitu 0 dan 1. Representasi nilai 0 mengindikasikan warna hitam, sementara nilai 1 melambangkan warna putih. Karena setiap piksel hanya memiliki dua kemungkinan nilai, maka ukuran setiap piksel pada citra ini hanya sebesar 1 bit. Jenis citra *biner* ini dapat disimpan dengan efisiensi yang tinggi [7].

2. Citra Grayscale

Citra *grayscale* mengacu pada jenis gambar digital yang terdiri dari serangkaian piksel, dengan setiap piksel berisi tingkat abu-abu yang mewakili tingkat kecerahan. Pada gambar skala abu-abu, tidak ada informasi warna, yang ada hanya informasi abu-abu. Artinya setiap piksel memiliki nilai kecerahan unik yang berkisar antara 0 (hitam) hingga 255 (putih) pada skala intensitas abu-abu pada umumnya [8].

3. Citra Warna

Citra warna merupakan representasi visual suatu objek atau pemandangan yang memuat informasi warna. Gambar jenis ini dapat ditemukan dalam berbagai format, seperti foto, gambar digital, scan, atau hasil pengolahan gambar digital. Berbeda dengan gambar skala abu-abu atau gambar hitam putih yang hanya berisi informasi intensitas cahaya tanpa komponen warna, gambar berwarna sering kali diwakili oleh tiga saluran warna utama: merah, hijau, dan biru, sering disebut saluran RGB. Dengan menggabungkan intensitas warna-warna primer ini, kita dapat menciptakan banyak warna lain dalam sebuah gambar. Selain itu, terdapat beberapa model warna lain seperti *yan*, *magenta*, *yellow*, *key/black* (CMYK) yang banyak digunakan dalam pencetakan dan model warna *hue*, *saturation*, *value* (HSV) yang sesuai untuk diproses warna sesuai dengan karakteristik manusia [9].

2.3. Pengolahan Citra

Pengolahan citra merupakan suatu bentuk pengolahan sinyal yang melibatkan masukan berupa suatu gambar, yang kemudian diubah menjadi gambar keluaran lain dengan menggunakan teknik tertentu. Tujuan pengolahan citra antara lain memperbaiki kesalahan data sinyal gambar yang terjadi selama transmisi dan penerimaan sinyal, serta meningkatkan kualitas tampilan gambar untuk memudahkan sistem visual interpretasi manusia. Hal ini dapat dicapai melalui manipulasi dan analisis gambar [10].

2.4. Deep Learning

Pembelajaran mendalam (*deep learning*) adalah cabang pembelajaran mesin (*machine learning*) yang berfokus pada penggunaan jaringan saraf tiruan yang dalam, yaitu jaringan dengan banyak lapisan, untuk memahami dan secara otomatis mempelajari fitur dari data. Keberhasilan pembelajaran mendalam telah meningkat dalam beberapa tahun terakhir, terutama karena kemampuannya menangani tugas-tugas kompleks, seperti pengenalan wajah, pengenalan suara, pengenalan teks, pemrosesan gambar, dan banyak lagi [11].

2.5. Convolutional Neural Network

Yann LeCun bersama dengan rekan-rekannya mengembangkan *Convolutional Neural Network* (CNN) pada periode awal hingga pertengahan tahun 1990-an. Yann LeCun, seorang ilmuwan komputer asal Perancis, merupakan seorang ahli dalam bidang kecerdasan buatan [12]. *Convolutional Neural Network* pada awalnya terdiri dari komponen-komponen utama seperti *Convolutional Layers*, *Pooling Layers*, *Fully Connected Layers*, *Activation Functions*, dan *Training* dengan *Backpropagation*. Sejak pertama kali diperkenalkan, telah banyak arsitektur CNN yang dikembangkan untuk tujuan pengklasifikasian citra, antara lain *LetNet-5*, *GoogLeNet*, *ResNet*, dan *AlexNet*. Kepopuleran CNN melesat sekitar tahun 2012 ketika model CNN AlexNet mencapai kemajuan signifikan dalam tugas pelabelan gambar, terutama dalam kompetisi ImageNet [13].

CNN adalah bentuk *multilayer perceptron* (MLP) yang terinspirasi dari struktur jaringan saraf manusia. CNN terdiri dari satu atau lebih lapisan yang memiliki susunan neuron dalam tiga dimensi, mencakup dimensi lebar, tinggi, dan kedalaman [14]. Penelitian ini dilakukan untuk mengimplementasikan convolutional neural network dalam pengenalan rambu lalu lintas dengan tujuan mengidentifikasi berbagai jenis rambu lalu lintas di Indonesia melalui pengolahan citra. Dalam penelitian ini, terdapat 10 jenis rambu lalu lintas yang diidentifikasi menggunakan 2.050 citra sebagai *dataset*. Hasil penelitian menunjukkan bahwa sistem berhasil mengenali rambu lalu lintas dengan tingkat error sebesar 0,107 dan mencapai tingkat akurasi sebesar 97,33% [15].

Dalam penelitian pengenalan rambu lalu lintas di Indonesia menggunakan multiscale convolutional neural network, khususnya pada *Traffic Sign Recognition* (TSR), penggunaan *dataset* melibatkan 2.050 citra rambu lalu lintas yang dibagi ke dalam 10 kelas. Pada fase pengujian, model CNN berhasil mencapai nilai error sebesar 0,017 dan tingkat akurasi sebesar 99,67% saat diuji dengan 300 citra rambu lalu lintas [16]. Studi berjudul "Klasifikasi Varietas Nanas Menggunakan *Convolutional Neural Networks*" yang dijalankan oleh Jhody Dwi Marfianto dan Mutaqin Akbar. Dalam penelitian ini, proses konvolusi gambar nanas dilakukan dengan menggunakan paket Keras pada platform Google Colab. Sampel yang digunakan untuk pengujian mencakup 120 gambar nanas, dan akurasi dalam mengidentifikasi ketiga jenis nanas tersebut mencapai 91,66% [17].

Studi dengan judul "*Convolutional Neural Network* untuk Klasifikasi Wajah Bermasker" membicarakan mengenai tren baru yang muncul selama masa pandemi, yakni kebiasaan menggunakan masker yang menyulitkan identifikasi individu. Untuk mengatasi tantangan ini, diperlukan suatu sistem yang mampu membedakan wajah yang menggunakan masker dengan yang tidak menggunakan masker, dan hal ini dilakukan dengan tingkat akurasi yang tinggi melalui penerapan metode *convolutional neural network* (CNN) [18].

Penelitian dengan judul "*Convolutional Neural Network* untuk Klasifikasi Citra Makanan Khas Indonesia" mengulas tentang makanan tradisional Indonesia yang diwariskan dari satu generasi ke generasi berikutnya. Dalam penelitian ini, dilakukan 8 kali percobaan dengan menggunakan 27 model, dan hasilnya menghasilkan model terbaik dengan tingkat akurasi pengujian sebesar 0,6 dan tingkat akurasi evaluasi sebesar

0,91[19]. Penelitian dengan judul "Klasifikasi Jenis Kendaraan Menggunakan Metode *Convolutional Neural Network* (CNN)" memiliki tujuan untuk mengatasi kemacetan dengan mengkategorikan jenis kendaraan, memungkinkan kendaraan untuk mengikuti rute yang telah ditentukan. Penelitian ini melibatkan penggunaan 120 citra yang mencakup mobil, motor, dan sepeda. Hasil dari penelitian ini mencapai tingkat akurasi sebesar 94,4% pada tahap pelatihan dan 73,3% pada tahap pengujian [20].

3. Metodologi

Langkah-langkah yang diimplementasikan dalam penelitian ini terdiri dari pengumpulan data, *resize* data, pembagian *dataset*, implementasi CNN, dan skenario pengujian model.

3.1. Pengumpulan Data

Dalam penelitian ini, peneliti mengumpulkan data citra dengan melakukan pengambilan gambar secara langsung terhadap makanan khas daerah Pasuruan. Citra yang berhasil dikumpulkan sebanyak 1000 citra yang terbagi menjadi empat jenis makanan yang menjadi objek penelitian, yaitu Bipang Jangkar, Botok Tempe, Cenil, dan Klepon, sebagaimana dapat dilihat pada Tabel 1.

Tabel 1. Citra makanan khas Pasuruan

Nama Makanan			
Bipang Jangkar	Botok Tempe	Cenil	Klepon
			

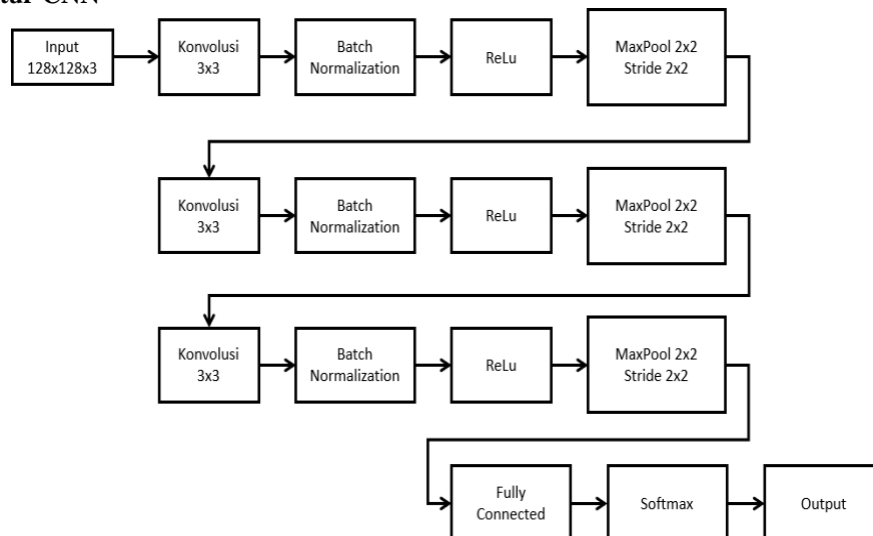
3.2. Resize Data

Setelah mengumpulkan data, langkah pertama adalah mengubah ukuran gambar secara manual menggunakan XnViewMP. Hal ini dikarenakan ukuran gambar awal yang cukup besar sehingga dapat memakan waktu yang lama dalam proses pembentukan gambar. Ukuran asli gambar masakan daerah Pasuruan sebelum diresize adalah 1,50 MB per gambar, dan setelah proses *resize*, ukuran gambar menjadi kurang lebih 250 KB per gambar. Dengan melakukan *resize*, proses pembuatan gambar dapat dilakukan dengan lebih efisien dan cepat.

3.3. Pembagian Dataset

Kemudian dibagikan *dataset* berupa 1.000 gambar masakan khas daerah Pasuruan. Gambar-gambar tersebut ditempatkan pada map yang telah disiapkan yaitu Bipang Jangkar, Botok Tempe, Cenil dan Klepon, dengan masing-masing makanan berisi 250 gambar dalam setiap map. Pemisahan kumpulan data dilakukan dengan perbandingan 80% data latih dan 20% data uji.

3.4. Arsitektur CNN



Gambar 3. Arsitektur CNN yang digunakan

Dalam penelitian ini, digunakan arsitektur CNN yang telah dirancang seperti yang terillustrasi pada Gambar 3. Terdapat tiga lapisan konvolusi, tiga lapisan *batch normalization*, tiga lapisan ReLU, dan tiga lapisan MaxPooling. Setiap lapisan konvolusi menggunakan jumlah filter yang berbeda dan dibagi menjadi dua skenario.

- a. Skenario 1 melibatkan konfigurasi jumlah filter pada lapisan konvolusi, dengan lapisan pertama memiliki 32 filter, lapisan kedua memiliki 48 filter, dan lapisan konvolusi ketiga memiliki 64 filter.
- b. Skenario 2, konfigurasi jumlah filter pada lapisan konvolusi disusun sebagai berikut: lapisan pertama memiliki 32 filter, lapisan kedua memiliki 64 filter, dan lapisan konvolusi ketiga memiliki 128 filter.

Langkah selanjutnya adalah menuju ke lapisan *fully connected*, dimana data akan diklasifikasikan menggunakan fungsi aktivasi *softmax*. Hasil dari lapisan ini berupa output yang menyajikan probabilitas untuk setiap kelas.

4. Hasil dan Pembahasan


Bagian ini berisi 2 subbagian yaitu pelatihan dan pengujian. Proses pelatihan menggunakan parameter seperti *optimizer* SGDM, 15 *epoch*, tingkat pembelajaran sebesar 0,01, ukuran mini batch 128, dan frekuensi validasi 6. Informasi mengenai galat dan akurasi pelatihan dapat ditemukan dalam Tabel 2.

4.1. Pelatihan

Tabel 2. Hasil pelatihan untuk setiap skenario


Epoch	Skenario 1		Skenario 2	
	Galat	Akurasi (%)	Galat	Akurasi (%)
1	4.9301	52.00	5.9998	57.00
2	3.0415	69.00	1.3576	82.00
3	0.0059	100.00	0.9736	87.50
4	0.0241	100.00	0.1238	96.50
5	0.0808	94.50	0.0542	97.50
6	0.0993	91.50	0.0052	100.00
7	0.0816	95.50	0.0162	99.50
8	0.0516	98.50	0.0255	99.00
9	0.0428	97.50	0.1153	97.00
10	0.0402	97.50	0.0039	100.00
11	0.0303	100.00	0.0685	98.00
12	0.0281	100.00	0.0050	100.00
13	0.0263	100.00	0.0040	100.00
14	0.0332	100.00	0.0356	98.50
15	0.0224	100.00	0.0027	100.00

Berdasarkan Tabel 2, pada fase pelatihan menggunakan skenario 1, terlihat bahwa pada *epoch* pertama hingga ke-3 terjadi penurunan nilai galat, namun pada *epoch* ke-4 terjadi peningkatan nilai galat secara fluktuatif hingga ke *epoch*-14 dan akhirnya menurun di *epoch* terahir. Tingkat akurasi pada skenario ini juga menunjukkan stabilitas dengan kenaikan, meskipun pada *epoch* ke-5 terjadi penurunan, namun selanjutnya mengalami peningkatan yang stabil. Pada *epoch* ke-11, tingkat akurasi mencapai 100% dan tetap stabil hingga *epoch* ke-15. Detail grafik galat dan akurasi untuk skenario 1 dapat dilihat pada Gambar 4.



Gambar 4. Grafik galat dan akurasi skenario 1

Pada skenario 2, nilai galat menunjukkan penurunan yang cukup stabil hingga ke *epoch* ke-6, setelah itu, terjadi kenaikan pada *epoch* ke-7 dan mengalami perubahan secara fluktuatif Pada hingga *epoch* ke-14, dan pada *epoch* ke-15 mengalami penurunan galat. Tingkat akurasi pada skenario ini mengalami perubahan fluktuatif, namun pada *epoch* ke-15 mengalami kenaikan, untuk skenario 2 dapat dilihat pada Gambar 5.



Gambar 5. Grafik galat dan akurasi skenario 2

4.2. Pengujian

Model CNN setiap skenario yang telah dilatih pada proses pelatihan kemudian diuji menggunakan 200 data citra uji yang terdiri dari citra yang berbeda dari *dataset* yang digunakan saat proses pelatihan. Dilihat dari Tabel 3, skenario kedua memiliki nilai galat terendah pada tahap pengujian, yakni sebesar 0.7437. Meskipun begitu, tingkat akurasi pada keduanya adalah sama, yakni mencapai 100%. Sehingga dapat dikatakan bahwa model CNN yang dikembangkan dalam artikel ini mampu menggeneralisir data citra makanan khas kota Pasuruan dengan baik. Model CNN dengan skenario 2 yakni melibatkan 32 filter pada konvolusi pertama, 64 pada konvolusi kedua, dan 128 pada konvolusi ketiga, mampu mencapai nilai galat yang lebih rendah dari skenario 1, baik dalam proses pelatihan maupun proses pengujian dan nilai akurasi yang mencapai 100%.

Tabel 3. Hasil pengujian untuk setiap skenario

Skenario 1		Skenario 2	
Galat	Akurasi (%)	Galat	Akurasi (%)
0.7476	100.00	0.7437	100.00

5. Kesimpulan

Klasifikasi citra makanan khas kota pasuruan menggunakan convolutional neural network (CNN) telah disajikan dalam artikel ini. CNN diaplikasikan pada citra makanan khas Pasuruan. CNN tersebut dilatih dengan menggunakan 800 data citra latih dan diuji menggunakan 200 data citra uji. Hasil pengujian menunjukkan bahwa model CNN dengan skenario 2 yakni melibatkan 32 filter pada konvolusi pertama, 64 pada konvolusi kedua, dan 128 pada konvolusi ketiga, mampu mencapai nilai galat yang lebih rendah dari skenario 1 yakni 0.7437, baik dalam proses pelatihan maupun proses pengujian dan nilai akurasi yang mencapai 100%.

References

- [1] M. Harsana and M. Triwidayati, "Potensi Makanan Tradisional Sebagai Daya Tarik Wisata Kuliner Di D.I. Yogyakarta," *Prosiding Pendidikan Teknik Boga Busana FT UNY*, vol. 15, no. 1, 2020.
- [2] V. Yunita and Y. Herdiyani, "Klasifikasi Citra Menggunakan Metode Minor Component Analysis pada Sistem Temu Kembali Citra," *Jurnal Ilmiah Ilmu Komputer*, vol. 15, no. 2, pp. 38–41.
- [3] A. Wicaksono, F. A. Bachtiar, and N. Y. Setiawan, "Segmentasi Pelanggan Menggunakan Fuzzy C-Means Clustering berdasarkan RFM Model pada E-Commerce (Studi Kasus: E-Commerce XYZ)," *JPTIHK*, vol. 5, no. 4, Apr. 2021.
- [4] D. S. Ningsih, Y. Indriani, and A. Suryani, "Keragaan Pedagang Makanan Jajanan Olahan Di Kampus Universitas Lampung," *Jurnal Ilmu Ilmu Agribisnis*, vol. 6, no. 2, 2018.
- [5] Y. M. Roza, G. Razali, E. Fatmawati, S. Syamsuddin, and G. A. Wibowo, "Identitas Budaya Dan Sosial Pada Makanan Khas Daerah: Tinjauan Terhadap Perilaku Konsumsi Masyarakat Muslim Pada Bulan Ramadan Di Indonesia," *Jurnal Ilmiah Manajemen*, vol. 4, no. 1, pp. 305–315, Apr. 2023, doi: 10.15575/jim.v4i1.25031.
- [6] A. R. Putri, "Pengolahan Citra Dengan Menggunakan Web Cam Pada Kendaraan Bergerak Di Jalan Raya," *JUPI*, vol. 1, no. 01, Aug. 2016, doi: 10.29100/jupi.v1i01.18.
- [7] M. R. Rasyid, Z. Tahir, and N. Syafaruddin, "Digital Image Processing for Detecting Industrial Machine Work Failure with Quantization Vector Learning Method," *Pekommas*, vol. 4, no. 2, p. 131, Oct. 2019, doi: 10.30818/jpkm.2019.2040203.
- [8] J. Hendarto, "Denoising Pada Citra Grayscale Menggunakan Metode Fraktal," *Jurnal Produktif*, vol. 1, no. 1, 2017.
- [9] D. A. Prabowo and D. Abdullah, "Deteksi dan Perhitungan Objek Berdasarkan Warna Menggunakan Color Object Tracking," *pseudocode*, vol. 5, no. 2, pp. 85–91, Sep. 2018, doi: 10.33369/pseudocode.5.2.85-91.
- [10] M. Z. Andrekha and Y. Huda, "Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan Opencv Python," *Voteteknika*, vol. 9, no. 4, p. 27, Dec. 2021, doi: 10.24036/voteteknika.v9i4.114251.
- [11] A. Peryanto, A. Yudhana, and R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Jurnal Format*, vol. 8, no. 2, p. 2019.
- [12] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [13] I. W. Suartika E.P, A. Y. Wijaya, and R. Soelaiman, "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101," *Jurnal Teknik ITS*, vol. 5, no. 1, 2016.
- [14] A. Rahim, K. Kusriani, and E. T. Luthfi, "Convolutional Neural Network untuk Kalasifikasi Penggunaan Masker," *j. inspir.*, vol. 10, no. 2, p. 109, Dec. 2020, doi: 10.35585/inspir.v10i2.2569.
- [15] M. Akbar, "Traffic sign recognition using convolutional neural networks," *J. Teknol. dan Sist. Komput.*, vol. 9, no. 2, pp. 120–125, Apr. 2021, doi: 10.14710/jtsiskom.2021.13959.
- [16] M. Akbar, "Pengenalan Rambu Lalu-lintas menggunakan Convolutional Neural Network (Studi Kasus: Rambu Lalu-lintas Indonesia)," *InfoTekJar*, vol. 6, no. 2, pp. 272–276, Mar. 2022, doi: http://dx.doi.org/10.30743/infotekjar.v6i2.4564.
- [17] J. D. Marfianto and M. Akbar, "Klasifikasi Jenis Buah Nanas Menggunakan Convolution Neural Network," *JT*, vol. 21, no. 1, Aug. 2023, doi: 10.26623/transformatika.v21i2.6369.
- [18] F. M. Qotrunnada and P. H. Utomo, "Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker," in *PRISMA: Prosiding Seminar Nasional Matematika*, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Semarang, 2022, pp. 799–807.

- [19] M. D. Darajat, Y. A. Sari, and R. C. Wihandika, “*Convolutional Neural Network* untuk Klasifikasi Citra Makanan Khas Indonesia,” *JPTIIK*, vol. 5, no. 11, Nov. 2021.
- [20] N. Fadlia and R. Kosasih, “Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN),” *tekno*, vol. 24, no. 3, pp. 207–215, 2019, doi: 10.35760/tr.2019.v24i3.2397.