

Implementasi Algoritma Convolutional Neural Network (CNN) untuk Pengenalan dan Klasifikasi Buah Berdasarkan Citra Digital

Ahmad Fariz Fuady ^{1*}, Dwiky Oldi Amsyah ², Muhammad Farhan ³, Rusma Riansyah ⁴, M. Dayyan Dhiyaul Haq ⁵

¹⁻⁵ Universitas Islam Negeri Sumatera Utara, Indonesia 1-5; email : ahmadfarizfuady26@gmail.com

*Penulis yang sesuai : Ahmad Fariz Fuady

Abstract: Object recognition, particularly fruit classification, plays a crucial role in various fields, ranging from agricultural automation to digital marketplaces. This study proposes a fruit classification system based on RGB images, developed using a Convolutional Neural Network (CNN) architecture consisting of convolutional layers, pooling layers, fully connected layers, and dropout for model stability. The model was trained using the Adam optimization algorithm on an augmented dataset to enhance data variation and reduce overfitting. The resulting model achieved an average accuracy of 98%, demonstrating the reliability of CNNs in pattern recognition tasks. To enhance usability, the model was integrated into a graphical user interface (GUI) built with MATLAB R2023b App Designer, allowing users to add datasets, train the model, and predict new images without writing any code. The findings highlight that while the model performs well, its accuracy remains dependent on consistent image backgrounds; therefore, expanding the variety of fruit types and background conditions in the dataset is essential to improve the system's robustness in real-world applications.

Keywords: Classification; CNN; Fruit; Recognition

Abstrak: Pengenalan objek, khususnya penentuan jenis buah, memiliki peran penting di berbagai bidang, mulai dari otomatisasi pertanian hingga pasar digital. Penelitian ini mengusulkan sistem klasifikasi buah berbasis citra RGB yang dibangun dengan arsitektur Convolutional Neural Network (CNN) tersusun atas lapisan konvolusi, pooling, fully connected, serta dropout dan dilatih menggunakan algoritma Adam pada dataset yang telah diperluas lewat augmentasi guna meningkatkan variasi data serta menekan overfitting. Model yang dihasilkan mencapai rata – rata akurasi 98%, memperlihatkan keandalan CNN dalam tugas pengenalan pola. Untuk mempermudah pemanfaatannya, model diintegrasikan ke dalam antarmuka grafis (GUI) berbasis MATLAB R2023b App Designer, sehingga pengguna dapat menambah dataset, melatih, dan memprediksi gambar baru tanpa menulis kode. Kesimpulan penelitian menekankan bahwa performa tinggi tersebut masih bergantung pada keseragaman latar belakang citra, oleh karena itu, perluasan jenis buah dan penambahan variasi latar di dataset menjadi langkah penting agar sistem semakin baik pada penerapan nyata.

Kata kunci: Klasifikasi; CNN; Buah; Pengenalan

Diterima: Maret, 31 2025

Direvisi: April, 14 2025

Diterima: Mei, 07 2025

Diterbitkan: Mei, 21 2025

Versi sekarang: Mei, 21 2025



Hak cipta: © 2025 oleh penulis.

Diserahkan untuk kemungkinan

publikasi akses terbuka

berdasarkan syarat dan ketentuan

lisensi Creative Commons

Attribution (CC BY SA) (

[https://creativecommons.org/lic](https://creativecommons.org/licenses/by-sa/4.0/)

[enses/by-sa/4.0/](https://creativecommons.org/licenses/by-sa/4.0/))

1. Latar Belakang

Perkembangan teknologi digital telah mendorong kemajuan di berbagai bidang, salah satunya dalam pengolahan citra digital. Pengolahan citra digital memungkinkan komputer untuk memahami, memproses, dan mengambil informasi dari gambar atau video secara otomatis. Salah satu penerapannya yang semakin berkembang adalah sistem pengenalan objek berbasis citra atau computer vision. Sistem ini memiliki peranan penting dalam berbagai sektor, seperti keamanan, kesehatan, industri, dan pertanian.

Di bidang pertanian, pengenalan objek secara otomatis khususnya pada identifikasi buah-buahan memiliki manfaat besar. Proses ini dapat membantu meningkatkan efisiensi dalam sortir buah, pendeteksian kualitas, serta pengembangan aplikasi pembelajaran yang interaktif. Dengan adanya sistem otomatis, pengolahan buah mampu diselenggarakan dengan instan dan akurat tanpa mesti mengandalkan tenaga manusia secara penuh.

Namun, proses pengenalan objek berbasis citra bukanlah hal yang sederhana. Tantangan seperti variasi warna, bentuk, ukuran, dan kondisi pencahayaan seringkali mempersulit proses klasifikasi. Oleh karena itu, dibutuhkan metode yang mampu mengekstraksi fitur kompleks dari citra secara efektif dan efisien. Convolutional Neural Network (CNN) yakni satu strategi yang populer dan sering diaplikasikan dalam pengolahan citra, khususnya untuk klasifikasi objek. CNN mampu mengenali pola dan fitur dalam citra dengan sangat baik melalui lapisan-lapisan konvolusi dan pooling yang ada pada arsitekturnya. Penelitian-penelitian sebelumnya telah menunjukkan bahwa CNN dapat mencapai tingkat akurasi yang tinggi dalam pengenalan berbagai jenis objek, termasuk buah – buahan.

Dengan terdapatnya perkembangan terkait pengelolaan citra digital, pekerjaan sorting buah – buahan dapat dilakukan secara otomatis. Maka dari itu, penelitian ini bermaksud mengembangkan dan menguji performa CNN dalam identifikasi buah – buahan lokal Indonesia. Penelitian ini akan mengevaluasi akurasi klasifikasi buah berdasarkan citra yang diolah dengan menggunakan CNN.

Terdapat beberapa kontribusi utama pada penelitian ini, di antaranya menghasilkan model arsitektur CNN yang efisien, memberikan hasil akurasi yang lebih tinggi dibandingkan penelitian terdahulu, serta menghasilkan sebuah aplikasi berbasis desktop yang berfungsi untuk mendeteksi buah yang user friendly.

2. Kajian Teoritis

Citra merupakan representasi visual dari satu atau sejumlah objek, mencakup gambar, hasil rontgen, hingga citra dari satelit. Citra dibagi ke dalam tiga jenis, yakni citra biner (monokrom), citra skala keabuan (grayscale), dan citra berwarna. Citra digital sendiri bisa direpresentasikan dalam bentuk matriks yang terbangun atas M kolom dan N baris, di mana titik temu antara kolom dan baris disebut piksel. Piksel ini menjadi bagian terkecil dari sebuah citra (Sriani & Nabila, 2024).


Penggunaan metode prediksi dapat digunakan di dalam berbagai bidang, seperti dalam bidang kesehatan untuk mengklasterisasi penyakit diabetes (Gibran & Saleh, 2023), serta dalam bidang peternakan untuk mengidentifikasi kualitas daging (Winardi & Setyati, 2021). Proses identifikasi buah secara otomatis memiliki banyak manfaat, seperti membantu proses sortir buah di industri pertanian, pendeteksian kualitas, hingga pengembangan aplikasi pembelajaran interaktif (Yanto et al., 2023).

Namun, pengenalan objek berbasis citra bukanlah hal yang sederhana. Variasi warna, bentuk, ukuran, dan kondisi pencahayaan menjadi tantangan tersendiri dalam proses klasifikasi (Saleh et al., 2023). Oleh karena itu, diperlukan metode yang mampu mengekstraksi fitur kompleks dari citra secara efektif dan efisien.

Salah satu strategi yang terkenal dan sering diaplikasikan adalah Convolutional Neural Network (CNN), yaitu bagian dari deep learning yang dirancang khusus untuk menangani data citra. Terdapat beberapa penelitian sebelumnya yang dilakukan untuk mendeteksi jenis buah secara otomatis dengan tingkat akurasi sebesar 90% (Fachrezzy & Budisusila, 2025). Menurut (Naranjo-Torres et al., 2020), CNN adalah arsitektur deep learning utama yang digunakan untuk pemrosesan gambar. CNN adalah jenis jaringan saraf buatan yang menggunakan operasi konvolusi setidaknya di salah satu lapisannya.

3. Metode Penelitian

Penelitian ini menggunakan algoritma CNN dalam hal deteksi atau pengenalan jenis buah – buahan. Penggunaan CNN disebabkan dapat menghasilkan sistem deteksi buah dengan performa yang tinggi dengan menggunakan gambar yang tidak banyak (Risdin et al., 2020). Sebelum data gambar dilatih pada algoritma CNN ini, terdapat alur atau diagram prosedur yang menggambarkan bagaimana alur data pada sistem yang akan digunakan, darimana data berasal dan data akan dikirimkan, serta dimana data akan disimpan.



Gambar 1. Diagram Blok Sistem yang Diusulkan

3.1. Pengumpulan Data

Pengumpulan data diselenggarakan dengan taktik mencari citra lewat media digital, disini kami menggunakan beberapa data yang dapat diambil dari beberapa sumber diantaranya yaitu Kaggle, Istock dan Depositphotos, gambar – gambar yang digunakan yaitu gambar yang

memiliki latar belakang berwarna putih. Pada penelitian ini kami menggunakan 100 gambar per kategori untuk dataset dan 20 data per kategori untuk data tes.

Tabel 1. Dataset Buah CNN

NO	Kategori Buah	Jumlah Data
1	Apel	100
2	Bit	100
3	Jeruk	100
4	Mangga	100
5	Semangka	100
Total		500

3.2 Membaca Data

Langkah selanjutnya setelah dilakukannya pengumpulan data yang akan digunakan maka akan dilakukannya pembacaan data yang disimpan pada folder yang telah diberikan label untuk tiap kategorinya.

3.3 Membagi Data


Setelah data telah terbaca maka langkah selanjutnya yaitu membagi dataset menjadi set pelatihan dan validasi menggunakan fungsi `splitEachLabel` pada Matlab, yang memungkinkan pembagian data dilakukan secara acak dengan rasio perbandingan 8:2, 80% untuk set pelatihan dan 20% untuk validasi

3.4 Augmentasi Data

Augmentasi data merupakan teknik untuk mengurangi overfitting dengan memperbesar ukuran dan keragaman dataset melalui transformasi seperti rotasi, penskalaan, translasi, dan refleksi citra tanpa mengubah label aslinya (Fadillah et al., 2021). Cara ini memungkinkan model belajar dari variasi data yang lebih beragam tanpa perlu menambah data baru (Husen, 2024). Pada penelitian ini augmentasi yang digunakan yaitu diputar sebesar -20 hingga 20 derajat secara acak, digeser secara horizontal maupun vertikal sebesar -6 hingga 6 piksel secara acak, diperbesar dan diperkecil.

3.5 Membuat Model CNN

CNN bekerja dengan menggabungkan beberapa jenis layer untuk mengekstrak fitur, mengurangi dimensi, dan melakukan klasifikasi (Purwono et al., 2022). Arsitektur CNN yang dipakai pada studi ini mencakup tiga blok konvolusi, beberapa layer aktivasi, normalisasi, pooling, dan fully connected layer.



Gambar 2. Model Arsitektur CNN

a. Image Input Layer

Image Input Layer merupakan layer yang berfungsi sebagai pintu masuk sebuah citra kedalam jaringan, pada penelitian ini jaringan menerima citra berukuran $64 \text{ piksel} \times 64 \text{ piksel} \times 3$ chanel warna (RGB).


b. Convolutional Layer

Convolutional Layer bertugas mengekstraksi fitur lokal dari sebuah citra dengan menggunakan filter atau kernel, proses ini menghitung hasil konvolusi antara input dan filter (Alwanda et al., 2020). Dalam penelitian ini terdapat tiga layer konvolusi.

Tabel 2. Data Layer Konvolusi

Conv ⁿ	Ukuran Filter	Jumlah Filter
Conv ¹	3x3	32
Conv ²	3x3	64
Conv ³	3x3	128

Berikut merupakan tampilan tiap layer convolutional pada model yang digunakan:



Gambar 3. Tampilan Convolutional Layer

c. Batch Normalization Layer

Batch Normalization Layer ini berfungsi untuk menormalkan output dari convolutional layer agar jaringan lebih stabil dan konvergen lebih cepat saat pelatihan

(Rectified Linear Unit) ReLU Layer

ReLU Layer merupakan salah satu fungsi aktivasi paling populer dalam jaringan syaraf tiruan, terkhusus didalam CNN (Magdalena et al., 2021). Fungsi ini digunakan untuk memperkenalkan non-linearitas ke dalam model setelah operasi linear seperti konvolusi atau transformasi matriks.

$$f(x) = \max\{f_0; 0, x\} \quad (2)$$

d. Max Pooling Layer

Max Pooling Layer bertujuan untuk mengurangi dimensi data dan ekstraksi fitur penting. Operasi pooling mengambil nilai maksimum dari area tertentu pada fitur map. Pooling membantu jaringan menjadi lebih tahan terhadap pergeseran atau rotasi objek pada citra.

$$P(i,j) = \max_{(m,n) \in R} \{f_0\} [S(i+m,j+n)] \quad (3)$$

Pada penelitian ini menggunakan 3 buah blok max pooling, dengan dimensi 2×2 dan stride 2, yang dimana input dari sebuah citra memiliki dimensi 64×64 piksel serta 3 chanel RGB

e. Fully Connected Layer

Setelah fitur diekstrak dan direduksi, Fully Connected Layer ini berfungsi untuk menghubungkan semua neuron dan melakukan klasifikasi (Pratama et al., 2024). Pada penelitian ini terdapat 3 Fully Connected Layer yang dimulai dari FC pertama yaitu memiliki sebanyak 256 neuron, kemudian FC kedua memiliki 128 neuron dan FC ketiga dengan neuron sesuai jumlah kategori.

f. Dropout Layer

Dropout Layer merupakan teknik regularisasi yang mengurangi overfitting dengan cara menonaktifkan secara acak beberapa neuron selama proses training.

g. Softmax Layer

Softmax Layer merupakan komponen terakhir dalam arsitektur CNN untuk tugas klasifikasi multi-kelas. Fungsi utama dari softmax yaitu mengubah output dari layer sebelumnya menjadi probabilitas yang bisa ditafsirkan sebagai kemungkinan suatu input termasuk dalam tiap – tiap kelas.

$$P(y=i | x) = e^{z_i} / (\sum_{j=1}^K e^{z_j}) \quad (4)$$

h. Classification Layer

Classification Layer merupakan layer terakhir dalam arsitektur CNN yang bertugas untuk menentukan kelas akhir dari hasil prediksi. Layer ini bekerja setelah softmax layer, yang mengubah output menjadi probabilitas.

3.6 Latih Model CNN

Metode pelatihan yang digunakan pada penelitian ini yaitu menggunakan metode Adam dikarenakan metode ini memiliki kemampuan dalam menyesuaikan laju pembelajaran secara adaptif dan cepat (Anggara et al., 2023). Skema pembelajaran yang digunakan yaitu epoch sebesar 50, minibatch 16 serta droprate sebesar 0,5 setiap 15 epoch.

3.7 Simpan Hasil Uji CNN

Setelah dataset telah dilatih dengan metode Adam, maka hasilnya akan disimpan yang nantinya akan digunakan untuk penentuan jenis buah untuk datates.

3.8 Uji Data Baru

Langkah selanjutnya dalam penelitian ini yaitu melakukan uji terhadap data baru untuk melihat apakah akurasi yang diberikan pada saat pelatihan sesuai dengan hasil uji berdasarkan model yang telah disimpan.

4. Hasil dan Pembahasan

4.1 Pelatihan, Uji dan Validasi pada Model

Sebagai langkah untuk mengetahui peforma dari model yang digunakan, maka dilakukan pembagian data menjadi data pelatihan, uji dan validasi. Data pelatihan digunakan untuk menjalankan pelatihan model yang selanjutnya akan divalidasi oleh Data validasi. Data uji


digunakan untuk mengetahui performa dari model. Dataset pada penelitian ini terdapat sekitar 500 data, 80% dari dataset (400 data) digunakan untuk data latihan dan 20% dari dataset (100 data) digunakan untuk data validasi.

4.2 Performa Model

Penelitian ini melakukan beberapa skema pembelajaran yang menghasilkan beberapa statistik performa, dari beberapa skema tersebut terdapat satu skema yang paling tinggi akurasi yang menggunakan epoch 50, mini-batch-size 16, learning-rate 0,001 dan maksimal literasinya 1250 dengan akurasi 98%. Berikut tabel berisikan beberapa skema pembelajaran dan hasilnya:

Tabel 3. Data Skema Pembelajaran

No	Epoch	Mini Batch Size	Learning Rate	Total Iterasi	Durasi (sec)	Akurasi (%)
1	50	8	0,001	2500	491	95,00
2	50	16	0,001	1250	293	98,00
3	50	16	0,0001	1250	216	97,00
4	50	16	0,005	1250	306	94,00
5	50	32	0,001	625	226	95,00
6	60	8	0,001	3000	404	96,00
7	75	32	0,001	950	257	96,00
8	80	16	0,0008	2000	345	97,00
9	100	16	0,001	2500	436	94,00
10	100	32	0,0005	1250	340	97,00



Gambar 4. Hasil Pelatihan Model

Setelah mendapatkan model yang paling tinggi akurasi, maka data pelatihan model akan disimpan, dan langkah selanjutnya yaitu melakukan uji terhadap model menggunakan data buah baru yang menggunakan model yang telah tersimpan, berikut merupakan tabel hasil uji menggunakan data baru:

Tabel 4. Pengujian Model dengan Buah Apel

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
1	0,0104	Apel	Benar
2	0,0043	Apel	Benar
3	0,0035	Apel	Benar
4	0,0036	Apel	Benar
5	0,0043	Apel	Benar
6	0,0041	Apel	Benar
7	0,0041	Apel	Benar
8	0,0039	Apel	Benar
9	0,0039	Apel	Benar
10	0,0036	Apel	Benar

Pada tabel 4 terdapat data hasil pengujian model dengan buah apel, dari tabel diatas dapat dikatakan bahwa dari 10 percobaan tidak ada prediksi yang salah. Maka dengan ini percobaan model terhadap data apel memiliki akurasi 100% dengan rata – rata waktu 0,0045 detik.

Tabel 5. Pengujian Model dengan Buah Bit

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
1	0,0042	Bit	Benar
2	0,0042	Bit	Benar
3	0,0042	Bit	Benar
4	0,0041	Bit	Benar
5	0,0044	Bit	Benar
6	0,0035	Bit	Benar
7	0,0043	Bit	Benar
8	0,0043	Bit	Benar
9	0,0040	Bit	Benar
10	0,0045	Bit	Benar

Pada tabel 5 terdapat data hasil pengujian model dengan buah bit, dari tabel diatas dapat dikatakan bahwa dari 10 percobaan tidak ada prediksi yang salah. Maka dengan ini percobaan model terhadap data bit memiliki akurasi 100% dengan rata – rata waktu 0,0041 detik.

Tabel 6. Pengujian Model dengan Buah Jeruk

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
1	0,0038	Jeruk	Benar
2	0,0041	Jeruk	Benar
3	0,0035	Jeruk	Benar
4	0,0036	Jeruk	Benar
5	0,0035	Jeruk	Benar
6	0,0041	Jeruk	Benar
7	0,0041	Jeruk	benar
8	0,0037	Jeruk	Benar
9	0,0040	Jeruk	Benar
10	0,0041	Jeruk	Benar

Pada tabel 6 terdapat data hasil pengujian model dengan buah jeruk, dari tabel diatas dapat dikatakan bahwa dari 10 percobaan tidak ada prediksi yang salah. Maka dengan ini percobaan model terhadap data jeruk memiliki akurasi 100% dengan rata – rata waktu 0,0038 detik.

Tabel 7. Pengujian Model dengan Buah Mangga

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
1	0,0036	Mangga	Benar
2	0,0042	Mangga	Benar
3	0,0040	Mangga	Benar
4	0,0043	Mangga	Benar
5	0,0042	Mangga	Benar
6	0,0037	Mangga	Benar
7	0,0040	Mangga	Benar
8	0,0039	Mangga	Benar
9	0,0053	Mangga	Benar
10	0,0049	Mangga	Benar

Pada tabel 7 terdapat data hasil pengujian model dengan buah mangga, dari tabel diatas dapat dikatakan bahwa dari 10 percobaan tidak ada prediksi yang salah. Maka dengan ini percobaan model terhadap data mangga memiliki akurasi 100% dengan rata – rata waktu 0,0042 detik.

Tabel 8. Pengujian Model dengan Buah Semangka

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
1	0,0082	Semangka	Benar
2	0,0055	Semangka	Benar
3	0,0053	Seamngka	Benar
4	0,0055	Semangka	Benar
5	0,0048	Semangka	Benar

Pengujian ke-	Waktu (sec)	Terdeteksi	Benar/Salah
6	0,0051	Semangka	Benar
7	0,0050	Semangka	Benar
8	0,0056	Semangka	Benar
9	0,0044	Semangka	Benar
10	0,0050	Semangka	Benar

Pada tabel 8 terdapat data hasil pengujian model dengan buah semangka dari tabel diatas dapat dikatakan bahwa dari 10 percobaan tidak ada prediksi yang salah. Maka dengan ini percobaan model terhadap data semangka memiliki akurasi 100% dengan rata – rata waktu 0,0054 detik.


4.3 Implementasi Antarmuka (GUI) Model CNN

Dalam mempermudah penggunaan model Convolutional Neural Network (CNN) dalam penelitian ini, dikembangkan sebuah aplikasi berbasis antarmuka grafis pengguna (GUI) menggunakan MATLAB R2023b dengan bantuan fitur App Designer. Aplikasi ini dirancang agar pengguna, baik yang memiliki latar belakang teknis maupun non-teknis, dapat berinteraksi secara langsung dengan sistem klasifikasi gambar tanpa perlu menulis atau menjalankan kode secara manual. Melalui antarmuka ini, seluruh proses mulai dari penambahan dataset, pelatihan model, hingga prediksi gambar baru dapat dilakukan dengan lebih efisien, terstruktur, dan user-friendly.



Gambar 5. Tampilan Utama Aplikasi Fruit Detector

Pada gambar 5 diatas terdapat halaman utama aplikasi berbasis antarmuka grafis yang memiliki beberapa fitur, terdapat fitur untuk menambahkan dataset, untuk melihat jumlah total dataset, melatih model yang nantinya akan disimpan dan akan menjadi modal untuk memprediksi gambar dan terdapat satu tombol yang jika ditekan akan memunculkan 1 halaman baru yang digunakan untuk memprediksi gambar.



Gambar 6. Tampilan Halaman Prediksi Buah

Pada gambar 6 diatas terdapat halaman untuk mendeteksi gambar, langkah untuk mendeteksi gambar yaitu pilih gambar yang akan diprediksi, kemudian tekan tombol cek gambar, dan setelahnya sistem akan menampilkan hasil prediksinya.

Pada bagian ini, penulis perlu menjelaskan perangkat keras dan perangkat lunak yang digunakan, sumber dataset, analisis data awal, hasil, dan analisis/pembahasan hasil. Sangat disarankan untuk menyajikan hasil dengan gambar, grafik, dan tabel. Rumus atau alat ukur evaluasi juga perlu disertakan di sini. Harus ada pembahasan/analisis, dan Anda tidak bisa hanya menulis ulang hasil dalam bentuk kalimat, tetapi Anda perlu memberikan penjelasan tentang hubungannya dengan hipotesis awal. Selain itu, bagian ini perlu membahas dan menguraikan temuan-temuan penting.

5. Kesimpulan Dan Saran

Penelitian ini berhasil merancang antarmuka grafis berbasis MATLAB R2023b App Designer yang terintegrasi dengan model Convolutional Neural Network (CNN) untuk klasifikasi buah, sehingga pengguna dapat menambah dataset, melatih, dan memprediksi gambar tanpa menulis kode. Model CNN yang dihasilkan mencapai akurasi pelatihan 98% dan akurasi pengujian 100%, menunjukkan performa sangat baik selama karakteristik data uji terutama latar belakang serupa dengan data pelatihan. Meski demikian, akurasi menurun ketika latar belakang citra terlalu dominan atau berbeda signifikan, sehingga perlu perluasan jenis buah dan penambahan variasi dataset agar model semakin bagus di masa depan.

Kesimpulan dan Saran

Terima kasih diberikan terhadap kedua orang tua para penulis dan dosen mata kuliah pengolahan citra, bapak M. Khalil Gibran, M. Kom, yang telah memberikan pembelajaran mengenai citra sehingga penelitian ini dapat terlaksanakan.

Referensi

- [1] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *Jurnal Algoritme*, vol. 1, no. 1, pp. 45–56, 2020. [Online]. Available: <https://doi.org/10.35957/algoritme.v1i1.434>
- [2] D. Anggara, N. Suarna, and Y. A. Wijaya, "Performance Comparison Analysis Of Optimizer Adam, SGD, and RMSPROP on The H5 Model," *Jurnal Ilmiah NERO*, vol. 8, no. 1, 2023. [Online]. Available: <https://www.kaggle.com/datasets/jonathanoheix/face-expression-recognition-dataset>
- [3] I. R. Fachrezzy and E. N. Budisusila, "Implementasi Neural Network untuk Deteksi Otomatis Jenis Buah Berdasarkan Citra Warna dan Bentuk Menggunakan MATLAB," *Jurnal Teknologi Pembelajaran Interaktif*, vol. 5, no. 1, pp. 1–7, 2025.
- [4] R. Z. Fadillah, A. Irawan, M. Susanty, and I. Artikel, "Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *Jurnal Informatika*, vol. 8, no. 2, pp. 208–214, 2021. [Online]. Available: <https://ejournal.bsi.ac.id/ejournal/index.php/ji/article/view/10768>
- [5] M. K. Gibran and A. Saleh, "A Hybrid RBF Neural Network and FCM Clustering for Diabetes Prediction Dataset," *Journal of Computer Science, Information Technology and Telecommunication Engineering*, vol. 4, no. 2, pp. 395–401, 2023. [Online]. Available: <https://doi.org/10.30596/jcositte.v4i2.15573>
- [6] D. Husen, "Evaluasi teknik augmentasi data untuk klasifikasi tumor otak menggunakan cnn pada citra mri," *TEKNIMEDIA*, vol. 5, no. 2, pp. 219–228, 2024.
- [7] R. Magdalena, S. Saidah, N. K. C. Pratiwi, and A. T. Putra, "Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN)," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 7, no. 3, p. 335, 2021. [Online]. Available: <https://doi.org/10.26418/jp.v7i3.48195>
- [8] J. Naranjo-Torres et al., "A review of convolutional neural network applied to fruit image processing," *Applied Sciences (Switzerland)*, vol. 10, no. 10, p. 2, 2020. [Online]. Available: <https://doi.org/10.3390/app10103443>
- [9] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "Convolutional Neural Network dan Faster Region Convolutional Neural Network untuk Klasifikasi Kualitas Biji Kopi Arabika," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2776–2785, 2024. [Online]. Available: <https://doi.org/10.23960/jitet.v12i3.4887>
- [10] Purwono, A. Ma'arif, W. Rahmiani, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, "Understanding of Convolutional Neural Network (CNN): A Review," *International Journal of Robotics and Control Systems*, vol. 2, no. 4, pp. 739–748, 2022. [Online]. Available: <https://doi.org/10.31763/ijrcs.v2i4.888>
- [11] F. Risdin, P. K. Mondal, and K. M. Hassan, "Convolutional Neural Networks (CNN) for Detecting Fruit Information Using Machine Learning Techniques," *IOSR Journal of Computer Engineering*, vol. 22, no. 2, pp. 1–13, 2020. [Online]. Available: <https://doi.org/10.9790/0661-2202010113>
- [12] A. Saleh, A. Ridwan, and M. K. Gibran, "Machine Learning and Fuzzy C-Means Clustering for the Identification of Tomato Diseases," *Indonesian Journal of Computer Science*, vol. 12, no. 5, pp. 2401–2413, 2023. [Online]. Available: <https://doi.org/10.33022/ijcs.v12i5.3379>
- [13] S. Sriani and A. Nabila, "Implementasi Deep Learning Untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (CNN)," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 1836–1843, 2024. [Online]. Available: <https://doi.org/10.23960/jitet.v12i3.4457>
- [14] P. Winardi and E. Setyati, "Identifikasi Jenis Daging dengan Menggunakan Algoritma Convolution Neural Network," *Journal of Information System, Graphics, Hospitality and Technology*, vol. 3, no. 2, pp. 82–88, 2021. [Online]. Available: <https://doi.org/10.37823/insight.v3i02.178>
- [15] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, "Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 1, pp. 59–66, 2023. [Online]. Available: <https://doi.org/10.25126/jtiik.20231015695>