

Analisis Deteksi Citra Mata Ikan Nila dengan Metode *Convolutional Neural Network* Arsitektur Alexnet

Angga Prasetyo¹, Fauzan Masykur², Arief Rahman Yusuf³, Arin Yuli Astuti⁴, Sugianti⁵, Ismail Abdurrozzaq⁶
Yovi Litanianda⁷

Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Ponorogo

¹angga_raspi@umpo.ac.id, ²fauzan@umpo.ac.id, ³yusuf@umpo.ac.id, ⁴arinyulias@umpo.ac.id, ⁵sugianti@umpo.ac.id,
⁶ismail@umpo.ac.id, ⁷yovi@umpo.ac.id

Abstract

The quality of fresh tilapia depends on the freezing process. Tilapia has a thick layer of scales covering its entire body, which can prevent even freezing. Irregularities in this process can reduce the quality and freshness of the fish during storage. This condition makes it difficult for consumers to assess the freshness of the fish through manual visual observation, such as checking the condition of the eyes. Therefore, the main objective of this research is to develop a fish eye image detection system that provides a fast, accurate, and objective method of assessing freshness to help consumers make an informed decision. The CNN model has advantages in accuracy and image classification. Additionally, the CNN model can be improved by adding architecture; one example is the AlexNet architecture. The dataset classification methodology's process stages are obtained from Kaggle based on tilapia eye images. The images are divided into two classes: 'fresh tilapia eye' and 'less fresh tilapia eye.' Preprocessing produces CNN modeling for fish eye image detection. Tilapia images were used as test data and input into the trained model at a rate of 68 milliseconds per step. Based on the analysis of visual patterns such as eye color, skin texture, and other physical characteristics, the model categorizes the fish as not fresh. Further research requires balancing the image dataset using Bayesian hyperparameters.

Keywords: CNN, fish's eyes, alexnet, visual patterns

Abstrak

Kualitas kesegaran ikan nila terletak pada proses pembekuan. ikan nila memiliki lapisan sisik yang tebal di seluruh permukaan tubuhnya, yang dapat menghambat proses pembekuan secara merata. Ketidakteraturan dalam proses ini berpotensi menurunkan kualitas dan kesegaran ikan selama penyimpanan. Kondisi ini merugikan dan menyulitkan konsumen dalam menilai tingkat kesegaran ikan hanya melalui pengamatan penglihatan secara manual, seperti memeriksa kondisi mata ikan. Oleh karena itu, tujuan utama riset yaitu, membangun sistem deteksi citra mata ikan dengan metode penilaian kesegaran yang cepat, akurat, dan objektif untuk membantu konsumen menjadikannya opsi utama yang harus dilakukan. Model CNN memiliki keunggulan dalam akurasi serta klasifikasi citra, selain itu model CNN dapat ditingkatkan melalui penambahan arsitektur salah satunya arsitektur *alexnet*. Proses tahapan metodologi klasifikasi dataset yaitu diperoleh dari *kaggle* berdasarkan citra mata ikan Nila dengan membaginya ke dalam dua kelas, yaitu kelas 'mata ikan nila segar' dan kelas 'mata ikan nila kurang segar' dan *preprocessing* menghasilkan modeling cnn untuk deteksi citra mata ikan. Hasil analisis diperoleh Gambar ikan nila digunakan sebagai data uji dan diberikan sebagai input ke dalam model yang telah dilatih dengan hanya memerlukan waktu sekitar 68 milidetik per langkah (68 ms/step). Berdasarkan analisis terhadap pola visual, seperti warna mata, tekstur kulit, serta ciri fisik lainnya, model mengkategorikan ikan tersebut dikondisi tidak segar. Untuk kelanjutan riset perlu dilakukan keseimbangan dataset citra dengan menggunakan *Bayesian hyperparameter*.

Kata kunci: CNN, ikan nila, Alexnet, pola visual.



1. Pendahuluan

Tantangan utama dalam menjaga kualitas kesegaran ikan nila terletak pada proses pembekuan. ikan nila memiliki lapisan sisik yang tebal di seluruh permukaan tubuhnya, yang dapat menghambat proses pembekuan secara merata[1]. Ketidakteraturan dalam proses ini berpotensi menurunkan kualitas dan kesegaran ikan selama penyimpanan.

Akibat dari proses pembekuan yang kurang optimal, sebagian ikan mengalami penurunan tingkat kesegaran serta berkurangnya kandungan nutrisi. Kondisi ini merugikan konsumen, karena mereka kesulitan dalam menilai tingkat kesegaran ikan hanya melalui pengamatan manual, seperti memeriksa kondisi mata ikan[2].

Situasi ini sering menimbulkan keraguan dalam pengambilan keputusan konsumen terkait kesegaran ikan Nila yang dibeli. Oleh karena itu, tujuan utama riset yaitu, membangun sistem deteksi citra mata ikan dengan metode penilaian kesegaran yang cepat, akurat, dan objektif untuk membantu konsumen menjadikannya opsi utama yang harus dilakukan. Berbagai model kecerdasan buatan dalam pemrosesan citra digital sering kali digunakan pada aktivitas deteksi obyek. beberapa model yang sering digunakan seperti, *K-Nearest Neighbour* (KNN), *Support Vector Machine* (SVM), *Random Forest*, dan *Convolutional Neural Network* (CNN). model CNN memiliki keunggulan dalam akurasi serta klasifikasi citra, selain itu model CNN dapat ditingkatkan melalui penambahan arsitektur salah satunya arsitektur *alexnet*, *AlexNet* merupakan arsitektur dalam CNN, *alexnet* memiliki susunan delapan layer utama, lima layer konvolusi serta tiga layer *fully connected*, yang mampu mengekstraksi fitur secara mendalam dari citra[3], sehingga sangat efektif dalam tugas klasifikasi dengan menawarkan solusi modern untuk mengatasi permasalahan tersebut melalui analisis visual yang lebih andal dan konsisten[4].

CNN mampu mengolah citra visual mata ikan dan mengidentifikasi ciri-ciri kesegaran dengan tingkat akurasi yang tinggi, sehingga sangat potensial untuk diterapkan dalam proses penilaian mutu ikan secara otomatis[5]. Penelitian sebelumnya[6] menunjukkan bahwa CNN memiliki potensi besar dalam mendeteksi tingkat kesegaran ikan. Salah satu contohnya adalah penelitian yang dilakukan[7]. proses penelitian sebelumnya[8], menggunakan metode *Deep Convolutional Neural Network*


(DCNN) untuk mengidentifikasi kesegaran ikan melalui citra insang. Hasil penelitian tersebut menunjukkan tingkat akurasi yang tinggi dalam klasifikasi kesegaran ikan. Namun, fokus penelitian tersebut terbatas pada citra insang dan belum mencakup parameter mata ikan, padahal mata ikan merupakan indikator visual utama yang sering digunakan dalam penilaian kesegaran secara manual.

Selain itu, penelitian sebelumnya[7][8], belum mengintegrasikan proses penyimpanan hasil prediksi. Akibatnya, pencatatan dan pengelolaan data menjadi tidak terstruktur dan kurang efisien. Oleh karena itu, dibutuhkan pengembangan sistem yang tidak hanya mampu melakukan klasifikasi kesegaran ikan melalui citra mata menggunakan CNN, tetapi juga dilengkapi dengan database untuk mendukung penyimpanan dan pengelolaan data secara sistematis. Untuk mengatasi keterbatasan pada penelitian sebelumnya[11], penelitian ini mengembangkan model deteksi tingkat kesegaran ikan Nila berbasis *Convolutional Neural Network* (CNN) dengan fokus pada parameter citra mata ikan. Model yang dikembangkan menerapkan pendekatan *hyperparameter tuning* guna meningkatkan akurasi dalam proses klasifikasi. Penelitian sebelumnya[12] menunjukkan bahwa metode *Convolutional Neural Network* (CNN) mampu mendeteksi akurasi obyek tingkat kerapatan *threshold* 95%. Hal ini jika diterapkan pada citra mata ikan nila berdasarkan perubahan warna di mata, maka bisa mencapai akurasi lebih dari 95%. Meskipun demikian, masih terdapat peluang untuk meningkatkan performa model serta melakukan evaluasi yang lebih komprehensif. Penelitian ini akan mengembangkan model serupa dengan penekanan pada evaluasi performa menggunakan metrik objektif[11], [12], [13], [14], [15], seperti *confusion matrix* dan *mean squared error* (MSE), sehingga hasil yang diperoleh lebih terukur dan relevan dalam konteks penilaian tingkat kesegaran ikan Nila. Secara fundamental, penelitian ini memberikan kontribusi kebaruan dalam pengembangan performa akurasi, kecepatan, deteksi citra mata ikan melalui model CNN serta arsitektur *alexnet* untuk mengetahui kesegaran ikan nila yang terintegrasi gawai konsumen. di bidang perikanan, khususnya dalam klasifikasi mutu ikan berbasis citra mata.

2. Metode Penelitian

Langkah-langkah yang diambil pada riset ini akan dipaparkan melalui desain penelitian secara detail pada Gambar 2. mencakup setiap tahap yang dilalui dalam


memberikan proses penyelesaian masalah yang lengkap mengenai fase penelitian yang dilakukan.



Gambar 2. Alur Penelitian

2.1 Pengumpulan Dataset

Proses klasifikasi dataset yaitu diperoleh dari kaggle berdasarkan citra mata ikan Nila dengan membaginya ke dalam dua kelas[13], yaitu kelas 'mata ikan nila segar' dan kelas 'mata ikan nila kurang segar'. Gambar 3 dan gambar 4 menyajikan contoh citra mata ikan Nila segar yang digunakan dalam penelitian ini:



Gambar 3. Citra mata ikan nila segar



Gambar 4. Citra mata ikan nila kurang segar

Tahapan berikutnya yaitu *preprocessing* dataset dalam penelitian ini melibatkan beberapa tahapan, mulai dari pengumpulan dataset, *preprocessing* data[16]. Untuk menghasilkan model CNN Langkah

pertama yang dilakukan adalah mengimpor pustaka-pustaka yang diperlukan untuk pemrosesan gambar, analisis data, visualisasi, serta pembangunan dan evaluasi model pembelajaran mesin menggunakan *TensorFlow* dan *Keras*. Selain itu, pustaka tambahan seperti *os*, *shutil*, dan *sklearn* juga digunakan untuk manajemen file dan pembagian dataset[8]. Dataset gambar ikan Nila yang digunakan dalam penelitian ini terdiri dari dua kategori utama:

1. Gambar ikan Nila dengan kondisi segar (lihat Gambar 3).
2. Gambar ikan Nila dengan kondisi tidak segar (lihat Gambar 4).

Dataset disimpan di *Google Drive* dan diakses menggunakan *Google Collab* untuk mempermudah integrasi serta pemrosesan berbasis cloud. Struktur direktori dataset kemudian diatur ulang menjadi tiga folder utama, yaitu: *Training*, *Validation*, dan *Testing*.

Langkah berikutnya adalah CNN model training, di mana seluruh gambar diproses agar memiliki ukuran seragam dan nilai piksel dinormalisasi ke dalam rentang (0, 1). Proses ini dilakukan menggunakan pustaka *TensorFlow* untuk memastikan data siap digunakan dalam pelatihan model[4]. Empat lapisan konvolusi, masing-masing menggunakan fungsi aktivasi *ReLU*, diikuti dengan operasi *max pooling* untuk mengekstraksi fitur visual utama dari citra lapisan *fully connected* (dense).

Setelah model dilatih dan dievaluasi, tahap selanjutnya adalah perancangan antarmuka pengguna (*interface system*) menggunakan *framework Flask* untuk:

1. Mengunggah gambar ikan Nila melalui antarmuka web.
2. Melihat hasil prediksi tingkat kesegaran secara langsung.

Struktur proyek aplikasi *Flask* terdiri dari:

1. Direktori *templates/*: menyimpan file *HTML* yang digunakan untuk membangun tampilan antarmuka pengguna.
2. Direktori *static/*: menyimpan file statis seperti gambar, file *CSS*, dan *JavaScript* yang mendukung tampilan web.

3. Hasil dan Pembahasan

3.1. Hasil perancangan model

Arsitektur model CNN yang dirancang terdiri dari beberapa lapisan yang disusun secara hierarkis untuk mengekstraksi fitur-fitur penting dari citra mata ikan Nila. Tabel 1. di bawah ini menunjukkan arsitektur model CNN yang dibangun menggunakan pendekatan *Sequential*.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d (MaxPooling2D)	(None, 111, 111, 32)	0
conv2d_1 (Conv2D)	(None, 109, 109, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 64)	0
conv2d_2 (Conv2D)	(None, 52, 52, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 128)	0
conv2d_3 (Conv2D)	(None, 24, 24, 256)	295,168
max_pooling2d_3 (MaxPooling2D)	(None, 12, 12, 256)	0
flatten (Flatten)	(None, 36864)	0
dense (Dense)	(None, 128)	4,718,720
dense_1 (Dense)	(None, 1)	129

Total params: 5,107,265 (19.48 MB)
Trainable params: 5,107,265 (19.48 MB)
Non-trainable params: 0 (0.00 MB)

Gambar 5. Output model CNN sequential

Hasil Analisis Arsitektur Model CNN (Gambar 5) yaitu pada, Lapisan Pertama (Conv2D) Menggunakan 32 filter kernel (3×3). Output shape: (None, 222, 222, 32) menunjukkan bahwa dimensi citra berkurang karena padding. Jumlah parameter yang dilatih: 896. *Max Pooling 2D*: Pooling dengan ukuran (2×2) untuk mengurangi dimensi citra menjadi (None, 111, 111, 32). Lapisan Kedua (Conv2D_1) Menggunakan 64 filter dengan ukuran kernel (3×3). Output shape: (None, 109, 109, 64). Jumlah parameter yang dilatih: 18.496. *Max Pooling 2D*: Pooling dengan ukuran (2×2), menghasilkan dimensi (None, 54, 54, 64). Lapisan Ketiga (Conv2D_2) Menggunakan 128 filter dengan ukuran kernel (3×3). Output shape: (None, 52, 52, 128). Jumlah parameter yang dilatih: 73.856. *Max Pooling 2D*: Pooling dengan ukuran (2×2), menghasilkan dimensi (None, 26, 26, 128). Lapisan Keempat (Conv2D_4) Menggunakan 256 filter dengan ukuran kernel (3×3). Output shape: (None, 24, 24, 256). Jumlah parameter yang dilatih: 295.168. *Max Pooling 2D*: Pooling dengan ukuran (2×2), menghasilkan dimensi (None, 12, 12, 256). Analisis layer Fully Connected (Dense Layer)

1. Dense Pertama
Lapisan ini terdiri dari 128 neuron dengan fungsi aktivasi *ReLU*. Jumlah parameter yang dilatih: 4.718.720.
2. Dense Kedua (Output Layer)
Lapisan ini terdiri dari 1 neuron dengan fungsi aktivasi sigmoid, yang digunakan untuk klasifikasi biner (Segar atau Tidak Segar). Jumlah parameter yang dilatih: 129.

3.2. Hasil Pengujian Model

Penjelasan hasil pengujian model secara detail disajikan seperti gambar 6

1/1 — 8s 8s/step - accuracy: 1.0000 - loss: 6.4688e-08
Test Loss : 6.468822988381362e-08
Test Accuracy : 1.0


Gambar 6. Output loss test dan akurasi

Setelah pelatihan selesai. Dua metrik utama digunakan dalam tahap ini, yaitu *test loss* dan *test accuracy*.

Test Loss: $6.468822988381362 \times 10^{-8}$ Nilai ini sangat mendekati nol, yang menunjukkan bahwa kesalahan prediksi model terhadap data uji sangat kecil. Artinya, model telah belajar dengan sangat baik dari data pelatihan dan mampu mengeneralisasi secara efektif pada data baru.


Test Accuracy: 1.0 (100%) Nilai ini menunjukkan bahwa model berhasil memprediksi seluruh data pengujian dengan benar, tanpa adanya kesalahan klasifikasi. Hasil ini menegaskan bahwa model sangat efektif dalam memahami dan mengklasifikasikan citra mata ikan Nila ke dalam kategori "Segar" dan "Tidak Segar".

3.3. Analisis Loss dan akurasi



Gambar 7. Grafik Loss

Grafik visualisasi testing loss pada Gambar 7. Pada awal pelatihan, nilai *train loss* 1,0 berada pada tingkat yang tinggi, karena model masih dalam tahap awal pembelajaran dan belum mampu mengenali pola dengan baik. Namun, seiring bertambahnya jumlah iterasi 50 *epoch*, nilai validasi *loss* terus mengalami penurunan sebesar 0,7 secara signifikan. Hal ini menunjukkan bahwa model semakin mampu meminimalkan kesalahan dalam melakukan prediksi. Namun pengurangan jumlah iterasi dari 5 hingga 15 *epoch* akan membuat penurunan akurasi *validation loss* di kondisi 0,13 berdampak keseimbangan layer konvolusi neuron.



Gambar 8. Grafik accuracy


Visualisasi akurasi *benchmark* pada gambar 8. Proses testing *validation accuracy* dengan jumlah iterasi mulai 18 sampai 50 *epoch* serta nilai validasi akurasi 1,0 ini menunjukkan kestabilan proses deteksi menggunakan data real, sedangkan proses testing *train accuracy* menggunakan data latih berada di kondisi iterasi 15 *epoch* dengan nilai validasi akurasi 0,97 belum memperlihatkan kestabilan deteksi.

Proses validasi *accuracy* meningkat secara signifikan, hingga mencapai nilai 1,0. Hal ini menunjukkan bahwa performa model CNN semakin mampu melakukan klasifikasi dengan benar terhadap data yang diberikan, baik untuk kategori “Segar” maupun “Tidak Segar”.

Yang menarik dari grafik ini adalah bahwa akurasi pada data validasi yang merepresentasikan data baru yang belum pernah terlihat sebagai model sebelumnya, mempunyai tren yang hampir linier dengan keakuratan pada data pelatihan. Hal ini menandakan bahwa model tidak hanya menghafal data pelatihan (*overfitting*), tetapi juga memiliki kemampuan generalisasi yang sangat baik terhadap data baru.


Dengan kesalahan yang hampir nol dan akurasi yang tinggi secara konsisten, model menunjukkan performa yang sangat baik dalam tugas klasifikasi citra mata ikan Nila berdasarkan tingkat kesegaran.

3.4 Proses deteksi citra



Gambar 9. Prediksi citra baru

Hasil deteksi citra pada gambar 9. Menunjukkan prediksi model terhadap citra ikan Nila guna menentukan tingkat kesegarannya. Gambar ikan Nila digunakan sebagai data uji dan diberikan sebagai input ke dalam model yang telah dilatih dengan hanya memerlukan waktu sekitar 68 milidetik per langkah (68 ms/step). Berdasarkan analisis terhadap pola visual, seperti warna mata, tekstur kulit, serta kondisi fisik lainnya, model mengkategorikan ikan tersebut sebagai “Tidak Segar”.



Gambar 10. interface antar muka sistem deteksi

Interface antar muka sistem deteksi berbasis web pada gambar 10. Dirancang untuk menjalankan model CNN dalam memprediksi kesegaran ikan nila berdasarkan citra yang diunggah dan dianalisis prediksinya.

4. Kesimpulan

Sistem yang dirancang menunjukkan performa yang sangat baik, sebagaimana dibuktikan oleh hasil evaluasi berikut, *test loss* yang sangat kecil, yaitu $6.468822998381362 \times 10^{-8}$, menunjukkan kesalahan prediksi yang hampir tidak ada. Akurasi pengujian mencapai 100%, yang berarti seluruh data uji berhasil diklasifikasikan dengan benar oleh model. Confusion matrix memperkuat hasil ini, dengan distribusi klasifikasi yang sempurna pada kedua kategori, yaitu "Segar" dan "Tidak Segar". Sistem juga efisien dalam hal kecepatan, dengan waktu rata-rata prediksi hanya 68 milidetik per gambar. Hasil uji performa ini memungkinkan penerapan deteksi citra mata ikan nila secara *real-time* untuk membantu konsumen melalui integrasi smartphone. Hasil ini menunjukkan potensi besar penerapan teknologi berbasis kecerdasan buatan di bidang perikanan, khususnya dalam membantu proses penilaian kualitas ikan secara objektif, cepat, dan akurat.

Ucapan Terimakasih

Terimakasih kepada Fakultas Teknik Universitas Muhammadiyah Ponorogo melalui pendanaan hibah riset penelitian Internal.

Daftar Rujukan

- [1] H. Khamilah and M. Hardjianto, “PENGKLASIFIKASIAN KUALITAS IKAN NILA BERBASIS MATA IKAN DENGAN METODE K-NEAREST NEIGHBORS (K-NN),” *Pros. Semin. Nas. Mhs. Fak. Teknol. Inf. SENAFTI*, vol. 3, no. 2, pp. 539–546, Sep. 2024.
- [2] “(PDF) Identifikasi Kesegaran Ikan Nila menggunakan Teknik Citra Digital,” *ResearchGate*, doi: 10.53842/juki.v2i1.23.
- [3] D. Rustandi, S. H. Wijaya, Mushthofa, and R. Damayanti, “Anatomy Identification of Bamboo Stems with The Convolutional Neural Networks (CNN) Method,” *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 8, no. 1, Art. no. 1, Jan. 2024, doi: 10.29207/resti.v8i1.5370.

- [4] N. Helmawati and E. Utami, "Analysis for Detecting Banana Leaf Disease Using the CNN Method," *JUITA J. Inform.*, pp. 29–36, Mar. 2025, doi: 10.30595/juita.v13i1.24514.
- [5] T. B. Sasongko, H. Haryoko, and A. Amrullah, "Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN)," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 10, no. 4, pp. 763–768, 2024, doi: 10.25126/jtiik.2024106583.
- [6] "Hybrid deep learning for detecting lung diseases from X-ray images," ResearchGate. Accessed: Jun. 02, 2025. [Online]. Available: https://www.researchgate.net/publication/342695564_Hybrid_deep_learning_for_detecting_lung_diseases_from_X-ray_images
- [7] W. N. Waluyo, R. R. Isnanto, and A. F. Rochim, "Comparison of Mycobacterium Tuberculosis Image Detection Accuracy Using CNN and Combination CNN-KNN," *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 7, no. 1, Art. no. 1, Feb. 2023, doi: 10.29207/resti.v7i1.4626.
- [8] H. O. Velesaca, R. Mira, P. L. Suárez, C. X. Larrea, and A. D. Sappa, "Deep Learning based Corn Kernel Classification," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Jun. 2020, pp. 294–302. doi: 10.1109/CVPRW50498.2020.00041.
- [9] R. Shen, T. Zhen, and Z. Li, "Segmentation of Unsound Wheat Kernels Based on Improved Mask RCNN," *Sensors*, vol. 23, no. 7, Art. no. 7, Jan. 2023, doi: 10.3390/s23073379.
- [10] "DeepCorn: A semi-supervised deep learning method for high-throughput image-based corn kernel counting and yield estimation," ResearchGate. Accessed: Jun. 02, 2025. [Online]. Available: https://www.researchgate.net/publication/349501212_DeepCorn_A_semi-supervised_deep_learning_method_for_high-throughput_image-based_corn_kernel_counting_and_yield_estimation
- [11] "(PDF) Peran Teknologi Pertanian Cerdas (Smart Farming) untuk Generasi Pertanian Indonesia," *ResearchGate*, doi: 10.53863/kst.v6i02.1226.
- [12] "Plant Leaf Disease Detection using Computer Vision and Machine Learning Algorithms," ResearchGate. Accessed: Jun. 02, 2025. [Online]. Available: https://www.researchgate.net/publication/359690037_Plant_Leaf_Disease_Detection_using_Computer_Vision_and_Machine_Learning_Algorithms
- [13] T. B. Sasongko, H. Haryoko, and A. Amrullah, "Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN)," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 10, no. 4, pp. 763–768, 2024, doi: 10.25126/jtiik.2024106583.
- [14] "Analysis for Detecting Banana Leaf Disease Using the CNN Method | JUITA: Jurnal Informatika." Accessed: Jun. 02, 2025. [Online]. Available: <https://jurnalnasional.ump.ac.id/index.php/JUITA/article/view/24514>
- [15] "Cari | Jurnal Teknologi Informasi dan Ilmu Komputer." Accessed: Jun. 02, 2025. [Online]. Available: <https://jtiik.ub.ac.id/index.php/jtiik/search/index?query=cnn&dateFromYear=&dateFromMonth=&dateFromDay=&dateToYear=&dateToMonth=&dateToDay=&authors=>
- [16] L. Fitriani, D. Tresnawati, and M. B. Sukriyansah, "Image Classification On Garutan Batik Using Convolutional Neural Network with Data Augmentation," *JUITA J. Inform.*, pp. 107–115, May 2023, doi: 10.30595/juita.v11i1.16166.
- [17] A. TiaraSari and E. Haryatmi, "Penerapan Convolutional Neural Network Deep Learning dalam Pendeteksian Citra Biji Jagung Kering," *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 5, no. 2, Art. no. 2, Apr. 2021, doi: 10.29207/resti.v5i2.3040.
- [18] Y. AUFAR, M. H. Abdillah, and J. Romadoni, "Web-based CNN Application for Arabica Coffee Leaf Disease Prediction in Smart Agriculture," *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 7, no. 1, Art. no. 1, Feb. 2023, doi: 10.29207/resti.v7i1.4622.