

Deteksi dan Klasifikasi Jenis Kacang-Kacangan Menggunakan CNN Berbasis ESP32-Cam

¹Andi Widya Mufila Gaffar, ²Dewi Widyawati, ³Fahmi, ⁴Sri Ulfiani

¹ Fakultas Ilmu Komputer Universitas Muslim Indonesia, Indonesia

widya.mufila@umi.ac.id, dewiwidyawati@umi.ac.id, fahmi.fikom@umi.ac.id,

sriuluppi14@gmail.com

Submit : 22 Sept 25 | Diterima : 08 Okt 2025 | Terbit : 13 Okt 2025

ABSTRAK

Kacang-kacangan merupakan sumber pangan padat energi yang kaya nutrisi bioaktif, berperan penting dalam menjaga kesehatan serta menurunkan risiko penyakit kronis yang dimana kacang-kacangan memiliki jenis dan varietas yang sangat beragam dengan ciri-ciri seperti warna, bantuk dan karakteristik yang berbeda beda. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis jenis kacang-kacangan menggunakan metode *Convolutional Neural Network* (CNN) berbasis arsitektur *Faster Objects, More Objects* (FOMO) yang diintegrasikan dengan perangkat berbiaya rendah *ESP32-Cam* melalui platform *Edge Impulse*. Empat jenis kacang yang digunakan sebagai objek penelitian meliputi kacang hijau, kacang kedelai, kacang merah, dan kacang tanah, dengan total 530 citra hasil akuisisi data. Proses penelitian meliputi tahapan akuisisi data, pre-processing berupa pelabelan, normalisasi, dan resize, pembagian dataset, pelatihan model dengan 60 epoch dan learning rate 0,001, hingga evaluasi kinerja model. Hasil evaluasi menunjukkan bahwa model mencapai F1 Score rata-rata 90,4%, yang termasuk kategori sangat baik, dengan keseimbangan optimal antara *precision* dan *recall*. Pada tingkat per kelas, kacang merah berhasil dikenali sempurna dengan akurasi 100%, kacang hijau memperoleh akurasi 94,4%, sedangkan kacang kedelai dan kacang tanah masing-masing mencapai 88% dan 88,9%. Analisis *feature explorer* menunjukkan adanya tumpang tindih pada distribusi kacang kedelai dan kacang tanah akibat kemiripan tekstur dan morfologi, sehingga berpotensi menimbulkan kesalahan klasifikasi. Secara keseluruhan, hasil penelitian ini membuktikan bahwa CNN dengan menggunakan *ESP32-Cam* mampu mendeteksi jenis kacang-kacangan dengan akurasi yang sangat baik.

Kata Kunci: *Convolutional Neural Network, ESP32-Cam, FOMO, kacang-kacangan.*

PENDAHULUAN

Kacang merupakan makanan padat energi yang kaya nutrisi bermanfaat seperti lemak sehat, protein, serat, dan antioksidan. Mereka secara positif mempengaruhi Kesehatan kardiovaskular, menurunkan risiko kanker, meningkatkan fungsi kognitif, dan membantu dalam manajemen berat badan, menjadikannya nutrisi alami yang berharga (Ros et al., 2021). Kacang - kacang kaya akan nutrisi bioaktif dan memiliki potensi untuk mengurangi peradangan dan stres oksidatif, sehingga menurunkan risiko penyakit kronis (Rajaram et al., 2023). Beragam jenis kacang- kacang telah dikenal luas dimana setiap jenis kacang-kacangan ini dapat dibedakan berdasarkan varietas serta ciri-ciri seperti warna, bantuk dan karakteristik lainnya (Al Rivian et al., 2020).

Perkembangan teknologi image processing dan artificial intelligence, khususnya *Convolutional Neural Network* (CNN), membuka peluang untuk mengotomatisasi proses identifikasi berbagai objek (Rahardika et al., 2024). termasuk bahan pangan. Salah satu bagian dari CNN Adalah arsitektur *Faster Objects, More Objects* (FOMO) yang memiliki metode deteksi objek berbasis CNN yang dikembangkan oleh *Edge Impulse* untuk perangkat terbatas seperti microcontroller dan IoT. Alih-alih menggunakan bounding box, FOMO mendeteksi objek lewat grid sel sehingga mampu mengenali banyak objek secara real-time dengan memori <200 KB (Revormasi Ziliwu et al., 2024). Proses pengklasifikasian kacang-kacangan masih memerlukan biaya besar, khususnya pada aspek perangkat keras, pengembangan model, dan pemrosesan data.

Dengan demikian, diperlukan teknologi yang mampu melakukan klasifikasi gambar kacang-kacangan secara lebih murah, efektif, dan efisien.

Penelitian terbaru menunjukkan keberhasilan implementasi CNN dalam mengklasifikasikan citra daun untuk deteksi penyakit daun padi dengan tingkat akurasi yang tinggi (Novantara et al., 2025). Di sisi lain, penggunaan perangkat mikrokontroler berbiaya rendah seperti *ESP32-Cam* telah terbukti efektif dalam aplikasi deteksi objek dengan kemampuan mencapai akurasi hingga 73% pada kondisi optimal (Herwandi et al., 2025). Penelitian lainnya yaitu Pengelolaan limbah medis, khususnya limbah infeksius, memerlukan pemisahan dan penanganan yang tepat berdasarkan pengolahan citra limbah medis untuk mencegah risiko penularan penyakit. Untuk itu, peneliti mengembangkan prototipe tempat sampah otomatis berbasis CNN dan *ESP32-Cam* yang mampu mengklasifikasikan limbah infeksius secara cepat dan akurat menggunakan data citra dari *Edge Impulse* (Firdaus et al., 2025).

Berdasarkan permasalahan sebelumnya, pendeteksi kacang-kacangan memerlukan teknologi yang mampu melakukan klasifikasi gambar kacang-kacangan secara lebih murah, efektif, dan efisien. Sehingga penelitian ini diharapkan mampu mengidentifikasi dan mengklasifikasi kacang-kacangan secara spesifik dan efisien, terutama yang mengintegrasikan perangkat berbiaya rendah seperti *ESP32-Cam* dengan model CNN menggunakan platform *Edge Impulse* dan melakukan eksperimen terkait. Dengan cara tersebut, model yang dilatih dalam penelitian ini dapat mengklasifikasikan dataset secara efektif dan menghasilkan tingkat akurasi yang memuaskan. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem deteksi kacang-kacangan berbasis image processing menggunakan *ESP32-Cam* yang dapat mengidentifikasi dan mengklasifikasikan jenis kacang secara otomatis, akurat, dan real-time.

TINJAUAN PUSTAKA

Kacang - Kacangan

Indonesia memiliki beragam potensi pangan lokal dari kacang-kacangan yang dapat meningkatkan asupan gizi dalam menu sehari-hari. Kacang-kacangan merupakan sumber protein bernilai tinggi (20–25 g/100 g), kaya vitamin B (tiamin, riboflavin, niasin, asam folat), mineral (Ca, Fe, P, K, Zn, Mg, dan lainnya), serta serat. Selain bergizi, kacang-kacangan juga relatif murah, mengandung lemak sehat, dan kaya mineral. Saat ini pasar masih didominasi oleh kedelai yang sebagian besar diimpor, sementara kacang lokal seperti kacang hijau, kacang tanah, dan kacang merah juga memiliki potensi besar (Ekafitri & Isworo, 2014).

Deep Learning

Deep Learning adalah metode pembelajaran yang menggunakan *artificial neural network* berlapis-lapis (multi-layer). Jaringan saraf tiruan ini dirancang menyerupai otak manusia, di mana neuron-neuron saling terhubung membentuk struktur yang kompleks. Dikenal juga sebagai *deep structured learning*, *hierarchical learning*, atau *deep neural learning*, metode ini memanfaatkan transformasi non-linear berlapis sehingga dapat dipandang sebagai kombinasi antara *machine learning* dan *artificial neural network* (Nugroho et al., 2020). Beberapa algoritma yang digunakan dalam *Deep Learning* antara lain *Convolutional Neural Network* (CNN), *Long Short-Term Memory* (LSTM), *Recurrent Neural Network* (RNN), dan *Self-Organizing Maps* (SOM) (Alfarizi et al., 2023).

Convolutional Neural Network

Algoritma *Convolutional Neural Network* (CNN) adalah model jaringan saraf berlapis yang terinspirasi dari sistem visual makhluk hidup dan terbukti efektif dalam menyelesaikan permasalahan *computer vision*, khususnya pada tugas klasifikasi citra (Hidayat et al., 2024). *Convolutional Neural Network* (CNN) merupakan jaringan saraf tiruan yang dirancang untuk menganalisis data berpola dan bertekstur dengan mengekstraksi fitur penting melalui lapisan konvolusi (Ali et al., 2023). CNN pun dapat mengenali dan mengambil fitur kompleks secara otomatis tanpa keterlibatan rekayasa fitur manual (Al Tawil et al., 2024). *Convolutional Neural Network* (CNN) dikenal juga sebagai arsitektur deep learning dengan lapisan khusus yang efektif

untuk analisis data visual dan, melalui transfer learning, terbukti lebih unggul dalam klasifikasi citra dibandingkan model *machine learning* (Adzкия & Arifin, 2025).

Edge Impulse

Platform *Edge Impulse* digunakan untuk melatih dan menerapkan algoritma *machine learning* pada sistem tertanam. Model yang dihasilkan dijalankan dalam bentuk pustaka C++, baik dengan representasi floating point 32-bit maupun representasi integer tetap 8-bit (Diab & Rodriguez-Villegas, 2022). *Edge Impulse* merupakan platform AI berbasis cloud yang membantu dalam melatih model sesuai kebutuhan. Alur kerja pada platform ini dibagi menjadi tiga tahap utama: pengumpulan data, pemrosesan data, dan pelatihan model. Model dapat dilatih dengan cara mengunggah data ke platform *Edge Impulse* serta merancang impulse (Huang, 2023).

METODE PENELITIAN

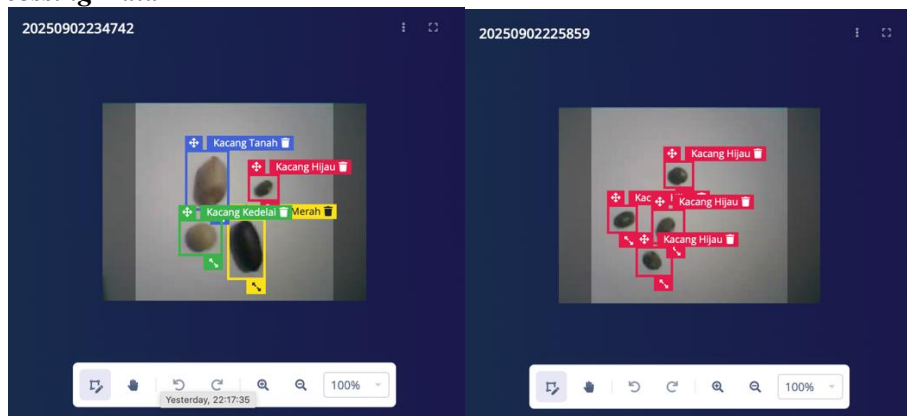
Akuisisi Data

Dalam penelitian ini, proses akuisisi data dapat dilihat pada Gambar 1 dilakukan dengan menggunakan *ESP32-Cam* untuk mengambil citra kacang-kacangan yang menjadi objek penelitian, yaitu kacang tanah, kacang kedelai, kacang hijau, dan kacang merah. Setiap jenis kacang diambil sebanyak 130 citra, sehingga total dataset yang terkumpul berjumlah 530 citra. Pengambilan citra dilakukan dengan beberapa skenario, yaitu satu gambar berisi 1, 2, 3, dan 4 kacang dengan jenis yang sama, gambar berisi 4 kacang dari 2 jenis berbeda, serta gambar berisi 4 kacang dari 4 jenis berbeda. Seluruh citra hasil tangkapan *ESP32-Cam* kemudian diunggah ke platform *Edge Impulse* untuk diproses lebih lanjut.



Gambar 1. Akuisisi data citra kacang -kacangan menggunakan *ESP32Cam*

Pre-processing Data



Gambar 2. Pelabelan data citra

Pada tahap *pre-processing data*, beberapa langkah penting dilakukan untuk menyiapkan dataset agar siap digunakan dalam pelatihan model. Pertama, dilakukan pelabelan citra sesuai dengan kategori objek, yaitu kacang tanah, kacang kedelai, kacang hijau, dan kacang merah, sehingga setiap citra memiliki kelas yang jelas dapat dilihat pada Gambar 2. Selanjutnya, dilakukan normalisasi citra, yaitu mengubah nilai asli piksel RGB yang berada pada rentang 0–255 menjadi rentang 0–1, dengan tujuan agar model dapat belajar lebih stabil dan akurat. Tahap berikutnya adalah *resize*, yaitu proses mengubah ukuran citra ke dimensi seragam 96×96 piksel, sehingga

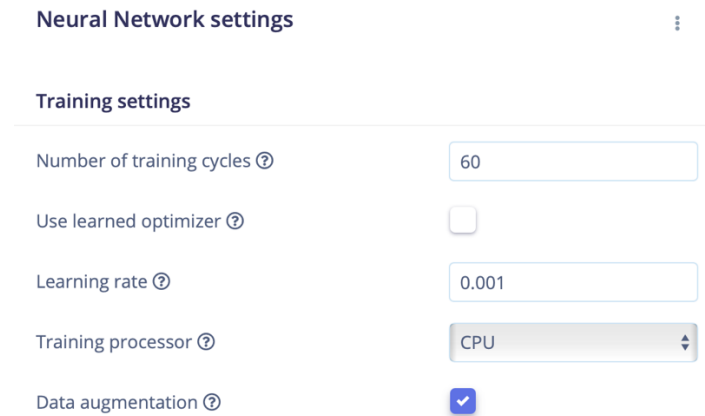
seluruh data gambar memiliki ukuran yang konsisten sesuai kebutuhan input pada model CNN. Dengan tahapan pre-processing ini, dataset menjadi lebih terstruktur, seragam, dan optimal untuk proses pelatihan maupun pengujian model machine learning.

Pembagian Data

Setelah melalui tahap *pre-processing*, dataset kemudian dibagi menjadi dua bagian, yaitu data training dan data testing. Pembagian dilakukan dengan perbandingan 80:20, di mana 80% dari total dataset digunakan sebagai data training untuk melatih model agar mampu mengenali pola dari setiap kategori kacang, sedangkan 20% sisanya digunakan sebagai data testing untuk menguji kinerja dan tingkat akurasi model.

Membangun Model

Membangun Model FOMO (*Faster Objects, More Objects*) berbasis *Convolutional Neural Network* dilatih dan diuji pada lingkungan simulasi menggunakan dataset yang telah diproses sebelumnya. Pelatihan dilakukan dengan jumlah epoch sebanyak 60 dan learning rate 0,001 untuk mengoptimalkan proses pembelajaran dilihat Gambar 3. Melalui tahapan ini, model tidak hanya menghasilkan output klasifikasi, tetapi juga diuji kemampuannya dalam mengenali serta membedakan jenis kacang secara akurat, sehingga dapat memastikan performa model dalam melakukan deteksi dan klasifikasi objek dengan baik.



Gambar 3. Pengaturan Epoch dan Learning Rate

Evaluasi Model

Evaluasi dilakukan dengan mengukur tingkat keakuratan model melalui perbandingan hasil klasifikasi dengan data yang jenisnya sudah diketahui sebelumnya. Untuk menilai keandalan model, digunakan beberapa metrik performa seperti akurasi, *precision*, *recall*, dan *F1-score* dapat dilihat pada Gambar 4.

Kinerja model dalam mengklasifikasikan kacang menunjukkan variasi antar kelas. Untuk kelas kacang hijau, tingkat akurasi mencapai 94,4% dengan kesalahan sekitar 5,6% yang teridentifikasi sebagai background. Hasil ini menggambarkan performa yang cukup konsisten, meskipun masih terdapat sebagian kecil objek yang tidak dikenali secara sempurna. Pada kacang kedelai, akurasi tercatat sebesar 88% dengan tingkat kesalahan relatif tinggi, yaitu sekitar 12% sampel yang salah masuk ke kategori background. Hal ini sesuai dengan temuan pada feature explorer yang menunjukkan adanya pola visual yang mirip dengan kelas lain. Sementara itu, kacang merah memperoleh hasil sempurna dengan akurasi 100% tanpa adanya kesalahan klasifikasi, menandakan bahwa ciri visual pada kelas ini sangat jelas dan mudah dipelajari oleh model. Adapun kacang tanah mencapai akurasi 88,9% dengan sekitar 11,1% data yang salah dikenali sebagai background, menunjukkan bahwa kelas ini, sama halnya dengan kacang kedelai, masih cukup menantang untuk dipisahkan secara konsisten.

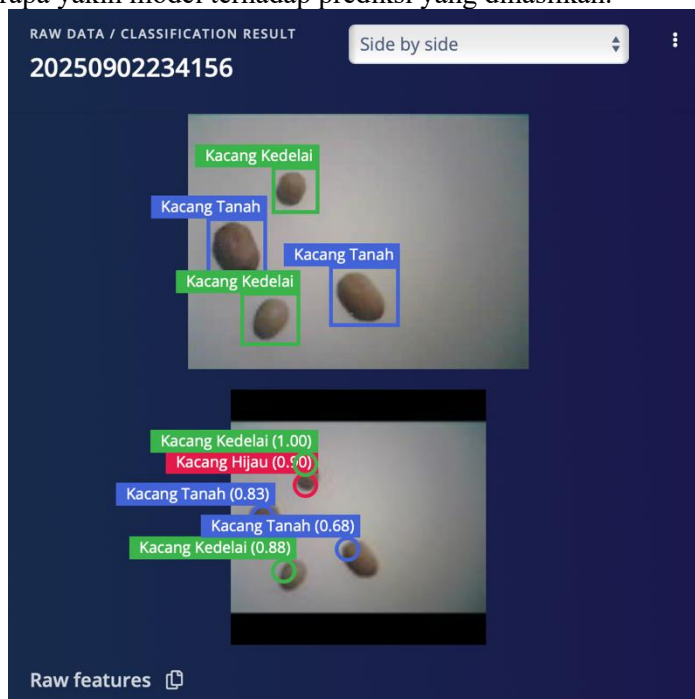


Gambar 4. Kinerja Model

HASIL DAN PEMBAHASAN

Hasil Deteksi

Gambar 5 memperlihatkan hasil prediksi model CNN terhadap citra yang berisi beberapa jenis kacang. Setiap objek diberi label kelas dengan tingkat keyakinan (*confidence score*) yang menunjukkan seberapa yakin model terhadap prediksi yang dihasilkan.



Gambar 5. Hasil Deteksi Kacang - Kacangan

Hasil pengujian menunjukkan bahwa kacang kedelai teridentifikasi dengan sangat baik. Prediksi pertama memperoleh skor 1.00 atau 100% yang menandakan keyakinan penuh dari model, sementara prediksi kedua menghasilkan skor 0.88 atau 88% yang juga cukup tinggi. Hal ini sejalan dengan hasil *confusion matrix* sebelumnya yang menempatkan kacang kedelai sebagai salah satu kelas yang mudah dikenali meskipun tetap ada sedikit kesalahan. Berbeda dengan itu, kacang tanah terdeteksi dua kali dengan skor 0.83 dan 0.68. Meskipun keduanya benar dikenali sebagai kacang tanah, tingkat keyakinannya relatif lebih rendah dibanding kacang kedelai. Kondisi ini memperlihatkan bahwa model masih memiliki keraguan dalam membedakan kacang tanah, sesuai

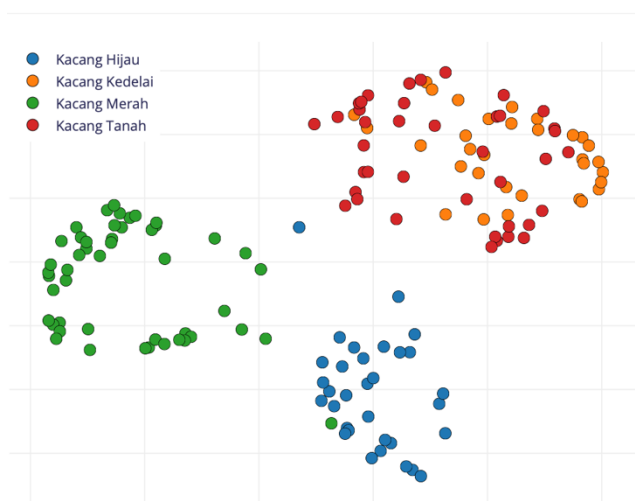
analisis sebelumnya yang menyebutkan kelas ini cukup menantang.

Sementara itu, kacang hijau justru menampilkan satu prediksi dengan skor 0.0 atau 0%, yang berarti terjadi kesalahan klasifikasi berupa *false positive*, di mana model keliru menganggap ada kacang hijau pada area tertentu padahal tidak ada. Secara umum, dapat disimpulkan bahwa prediksi kacang kedelai sangat akurat dan konsisten, kacang tanah dikenali cukup baik meskipun masih menimbulkan ketidakpastian, sedangkan kacang hijau mengalami kesalahan deteksi yang sesuai dengan pola sebelumnya, yakni kacang kedelai lebih mudah dipelajari sedangkan kacang tanah cenderung rawan tumpang tindih dengan kelas lain.

Representasi Fitur

Gambar 6 merupakan feature explorer yang memperlihatkan pemetaan distribusi empat jenis kacang—Kacang Hijau (biru), Kacang Kedelai (oranye), Kacang Merah (hijau), dan Kacang Tanah (merah)—dalam ruang dua dimensi hasil reduksi dari representasi fitur model *deep learning*. Visualisasi ini memberikan gambaran tentang bagaimana model membedakan karakteristik masing-masing kelas berdasarkan fitur yang dipelajari. Kacang Hijau membentuk kluster yang rapat dan terpisah di bagian bawah, menunjukkan konsistensi model dalam mengenali cirinya. Hal serupa terlihat pada Kacang Merah yang terkonsentrasi di sisi kiri bawah dengan pemisahan yang jelas, menandakan kualitas representasi yang baik. Sebaliknya, distribusi Kacang Kedelai dan Kacang Tanah tampak berdekatan di sisi kanan atas, bahkan sebagian saling beririsan. Tumpang tindih ini mengindikasikan adanya kemiripan fitur, kemungkinan dipengaruhi oleh kesamaan morfologi atau tekstur, sehingga berpotensi menimbulkan kesalahan klasifikasi.

Feature explorer




Gambar 6. Hasil Deteksi Kacang - Kacangan




Meski demikian, secara keseluruhan proyeksi menunjukkan bahwa model mampu menghasilkan representasi fitur yang cukup diskriminatif, dengan sebagian besar kelas terpetakan secara jelas, kecuali pada kasus tumpang tindih antara Kedelai dan Tanah. Temuan ini memperkuat dugaan bahwa model memiliki kapasitas generalisasi yang baik terhadap data pelatihan, meskipun masih memerlukan strategi tambahan untuk meningkatkan akurasi pada kelas yang mirip.

Pembahasan

Berdasarkan hasil evaluasi pada validation set, diperoleh nilai precision sebesar 0,89, recall sebesar 0,91, dan F1 Score sebesar 0,90. Nilai precision yang mendekati 0,9 menunjukkan bahwa sebagian besar prediksi model terhadap objek kacang sesuai dengan kelas yang benar. Sementara itu, nilai recall sebesar 0,91 menandakan kemampuan model yang sangat baik dalam mengenali hampir semua objek kacang yang ada dalam data uji. Kombinasi kedua metrik tersebut menghasilkan F1 Score sebesar 0,90, yang menggambarkan keseimbangan optimal antara akurasi prediksi positif dan tingkat deteksi objek. Secara keseluruhan, hasil ini menunjukkan bahwa model

mampu mengklasifikasikan jenis kacang dengan performa yang sangat baik tanpa terpengaruh oleh kategori background.

Metrics (validation set) 

METRIC	VALUE
Precision (non-background) 	0.89
Recall (non-background) 	0.91
F1 Score (non-background) 	0.90

Gambar 7. Validation set

KESIMPULAN

Hasil penelitian, dapat disimpulkan bahwa model FOMO berbasis CNN dengan dukungan *ESP32-Cam* dan *Edge Impulse* mampu mengklasifikasikan empat jenis kacang—kacang hijau, kacang kedelai, kacang merah, dan kacang tanah—dengan performa yang sangat baik. Evaluasi pada validation set menunjukkan nilai *F1 Score* rata-rata 90,4%, yang menandakan keseimbangan optimal antara precision dan recall. Hasil per kelas memperlihatkan bahwa kacang merah dan background dikenali sempurna dengan akurasi 100%, sedangkan kacang hijau (94,4%) menunjukkan stabilitas tinggi meski masih ada sedikit kesalahan deteksi. Untuk kacang kedelai (88%) dan kacang tanah (88,9%), akurasi relatif lebih rendah karena adanya kemiripan fitur yang menimbulkan tumpang tindih, sebagaimana terlihat pada analisis feature explorer. Sehingga, CNN yang pengambilan data menggunakan *ESP32-Cam* mampu mendeteksi jenis kacang-kacangan dengan hasil akurasi yang sangat baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengembangan Sumberdaya (LP2S) Universitas Muslim Indonesia atas dukungan pendanaan yang telah diberikan sehingga penelitian ini dapat terlaksana dengan baik.

REFERENSI

- Adzkia, S. A., & Arifin, T. (2025). Perbandingan Arsitektur CNN Berbasis Transfer Learning untuk Klasifikasi pada BreastMNIST. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 11(2), 192–200. <https://doi.org/10.25077/TEKNOSI.v11i2.2025.192-200>
- Al Rivan, M. E., Rachmat, N., & Ayustin, M. R. (2020). Klasifikasi Jenis Kacang-Kacangan Berdasarkan Tekstur Menggunakan Jaringan Syaraf Tiruan. *Jurnal Komputer Terapan*, 6(1), 89–98. <https://doi.org/10.35143/jkt.v6i1.3546>
- Al Tawil, A., Shaban, A., & Almazaydeh, L. (2024). A comparative analysis of convolutional neural networks for breast cancer prediction. *International Journal of Electrical and Computer Engineering (IJECE)*, 14(3), 3406. <https://doi.org/10.11591/ijece.v14i3.pp3406-3414>
- Alfarizi, M. R. sirfatullah, Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). PENGGUNAAN PYTHON SEBAGAI BAHASA PEMROGRAMAN UNTUK MACHINE LEARNING DAN DEEP LEARNING. *Karimah Tauhid*, 2(1), 1–6.
- Ali, M. D., Saleem, A., Elahi, H., Khan, M. A., Khan, M. I., Yaqoob, M. M., Farooq Khattak, U., & Al-Rasheed, A. (2023). Breast Cancer Classification through Meta-Learning Ensemble Technique Using Convolution Neural Networks. *Diagnostics*, 13(13), 2242. <https://doi.org/10.3390/diagnostics13132242>
- Diab, M. S., & Rodriguez-Villegas, E. (2022). Performance Evaluation of Embedded Image Classification Models Using Edge Impulse for Application on Medical Images. *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2639–2642. <https://doi.org/10.1109/EMBC48229.2022.9871108>

- Ekafitri, R., & Isworo, A. R. (2014). Pemanfaatan Kacang-Kacangan sebagai Bahan Baku Sumber Protein Untuk Pangan Darurat. *Jurnal Pangan*, 23(2), 134–144.
- Firdaus, R. I., Sugiharto, W. H., & Ghozali, M. I. (2025). Implementasi Convolutional Neural Network Dalam Sistem Otomatis Pemilahan Sampah Infeksius Berbasis Citra Digital. *SisInfo : Jurnal Sistem Informasi Dan Informatika*, 7(1), 11–22.
- Herwandi, A., Ramadhan, A. A., Sunggono, N. T., & Ferawati, F. (2025). Analisis Kinerja ESP32-CAM Dalam Mendeteksi Objek. *Bit-Tech*, 7(3), 1014–1021. <https://doi.org/10.32877/bt.v7i3.2296>
- Hidayat, A., Alindra, Z., & Amalya, F. (2024). KLASIFIKASI CITRA ANJING DAN SERIGALA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN). *UG JURNAL*, 18(6), 1–7.
- Huang, D. (2023). Edge impulse-based convolutional neural network for brain tumor classification. *Applied and Computational Engineering*, 18(1), 188–193. <https://doi.org/10.54254/2755-2721/18/20230989>
- Novantara, P., Risteruw Leonardo Firmansyah, & Marilyn Arismawati. (2025). Deteksi Hama Penyakit Daun Padi Dengan Menggunakan Teknik Optimasi Deep Learning Convolutional Neural Network. *Bit-Tech*, 7(3), 975–983. <https://doi.org/10.32877/bt.v7i3.2284>
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA. *Jurnal Algor*, 2(1), 12–21.
- Rahardika, F., Putra, B., Fakhri, L. J., Soekarta, R., Ika, W., & Wahid, A. (2024). *Implementasi Machine Learning Dalam Mengidentifikasi Tanaman Hias menggunakan Metode CNN* (Vol. 03, Issue 01).
- Rajaram, S., Damasceno, N. R. T., Braga, R. A. M., Martinez, R., Kris-Etherton, P., & Sala-Vila, A. (2023). Effect of Nuts on Markers of Inflammation and Oxidative Stress: A Narrative Review. *Nutrients*, 15(5), 1099. <https://doi.org/10.3390/nu15051099>
- Revormasi Ziliwu, J., Setyawan, C., & Budiati, H. (2024). Penerapan ESP32-CAM dan TinyML dalam Klasifikasi Gambar Buah dan Sayuran. *Jutisi : Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13(1), 584. www.kaggle.com
- Ros, E., Singh, A., & O’Keefe, J. H. (2021). Nuts: Natural Pleiotropic Nutraceuticals. *Nutrients*, 13(9), 3269. <https://doi.org/10.3390/nu13093269>