

DETEKSI OBJEK JAMUR PADA ROTI TAWAR SECARA REAL-TIME MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Muhammad Lazuardi Harahap, Hermawan Syahputra

Ilmu Komputer, Universitas Negeri Medan

Jalan Willem Iskandar Pasar V Medan Estate Percut Sei Tuan Deli Serdang, Indonesia

muhammadlazuardihara@mhs.unimed.ac.id

ABSTRAK

Penelitian ini mengembangkan sistem deteksi jamur pada roti secara realtime menggunakan Convolutional Neural Network (CNN) untuk mengatasi masalah cacat mikrobiologis yang umum dalam industri roti. Menggunakan metode Research and Development (R&D) dengan model CNN Transfer Learning MobileNetV2, penelitian ini mengolah 640 data primer yang diambil dari toko roti di Medan Marelana Pasar 1 menggunakan kamera 108 megapixel dengan lighting 50 watt berdiameter 18 inch. Dari pengujian 8 model dengan parameter berbeda, diperoleh hasil terbaik pada parameter 30000 num_steps dan 8 batch, menghasilkan akurasi 96.42% dan total loss 0.1181 dengan waktu training 2 jam 18 menit 36 detik. Pengujian pada 64 data (32 roti berjamur dan 32 tidak berjamur) menunjukkan model berhasil mendeteksi 30 dari 32 gambar roti berjamur dengan berbagai variasi, sementara semua gambar roti tidak berjamur terdeteksi dengan benar. Hasil ini membuktikan efektivitas implementasi CNN dalam mendeteksi jamur pada roti.

Kata kunci : Deteksi jamur pada roti, MobileNetV2, Convolutional Neural Network, Roti, Transfer Learning

1. PENDAHULUAN

Pertumbuhan jamur pada roti sangat sulit untuk dicegah. Hal ini disebabkan oleh berbagai faktor, termasuk kandungan kelembapan dan nutrisi dalam roti yang merupakan lingkungan ideal bagi pertumbuhan jamur. Menurut Food and Agriculture Organization (FAO), jamur merupakan salah satu cacat mikrobiologis yang paling umum ditemukan dalam industri roti. Roti tawar memiliki masa simpan terbatas sekitar 3-7 hari dalam kondisi normal, yang sangat bergantung pada suhu penyimpanan dan kelembapan lingkungan[1].

Spora jamur mudah tersebar melalui udara dan dapat dengan cepat berkembang biak pada permukaan roti, terutama jika disimpan pada suhu ruang. Pada umumnya, roti hanya dapat bertahan hingga 4 hari. Jika tempat penyimpanan tidak steril dan metode penyimpanannya tidak tepat, roti akan lebih cepat terkontaminasi oleh mikroorganisme[2].

Kontaminasi jamur pada roti bukan hanya masalah kualitas produk tetapi juga merupakan masalah kesehatan masyarakat yang serius. Jamur yang tumbuh pada roti dapat menghasilkan berbagai jenis toksin yang dapat menyebabkan berbagai gangguan kesehatan, mulai dari keracunan makanan hingga reaksi alergi yang parah[3]. Oleh karena itu, mendeteksi dan mencegah kontaminasi jamur pada roti menjadi perhatian utama dalam industri makanan.

Dalam upaya untuk meningkatkan keamanan pangan dan mencegah kontaminasi jamur pada roti, penerapan Deep Learning dalam dunia Machine Learning. Dalam pengenalan citra, Convolutional Neural Network (CNN) telah menjadi fokus penelitian. CNN adalah jenis jaringan saraf tiruan yang mampu memproses data gambar dan memiliki kemampuan untuk mengenali pola kompleks dalam gambar[4].

Pada era digital yang canggih ini, memungkinkan adanya komputasi yang mampu memproses informasi dari gambar atau citra secara otomatis untuk mengenali objek. Pengolahan citra atau *image processing* adalah pengolahan gambar baik berupa gambar bergerak atau diam untuk memperoleh informasi dari gambar – gambar tersebut[5].

Pendeteksian objek (*Object Detection*) merupakan salah satu bidang paling menarik dalam computer vision dan kecerdasan buatan. Teknologi ini berkaitan dengan computer vision dan pemrosesan citra, yang bertujuan untuk mendeteksi objek dalam gambar digital berdasarkan warna dan bentuknya[6].

Pengimplementasian metode Convolutional Neural Network (CNN) sendiri akan mencakup pemahaman mendalam tentang pengolahan citra dan pengenalan objek yang dimana akan mencakup konsep – konsep Deep Learning terkait dalam penelitian ini. Untuk proses deteksi objek meliputi beberapa tahapan, yaitu pengambilan citra, praprocessing citra, pelatihan model CNN, dan pengujian model CNN[7].

Struktur deep learning juga mulai dibuat seiring dengan waktu. TensorFlow adalah salah satu framework deep learning yang dapat Anda gunakan untuk membuat berbagai program AI. Dengan menggunakan framework seperti itu, Anda dapat membuat sistem deteksi objek[8].

2. TINJAUAN PUSTAKA

2.1. Mikroorganisme pada Roti

Jamur adalah salah satu cacat mikrobiologis yang paling umum, yang ditemukan dalam industri roti. Mengacu pada roti, jamur kontaminasi tidak hanya menentukan perubahan warna, rasa, tetapi juga hilangnya kualitas makanan sebagai akibat dari kemungkinan pembentukan mikotoksin. Jamur disebabkan oleh kontaminasi eksternal pada roti

setelah dipanggang, karena spora yang ada dalam tepung selama proses teknologi normal tidak memiliki kondisi perkembangbiakan, dan selama pemangangan, spora-spora tersebut dihancurkan[9].

Kontaminasi oleh jamur dalam produksi roti menjadi perhatian karena dapat mengurangi masa simpan produk sehingga menimbulkan kerugian ekonomi dan ketidakpuasan konsumen. Bulatan hitam yang disebut sporangium akan tumbuh pada roti, dan dapat menghasilkan sekitar 50.000 spora[10].

2.2. Mutu Pangan

Pangan adalah segala sesuatu dari sumber hayati dan air, baik yang diolah maupun tidak, yang menjadi kebutuhan dasar dan hak asasi rakyat Indonesia. Pangan harus tersedia dalam jumlah cukup, aman, bermutu, bergizi, beragam, serta terjangkau. Sistem pangan yang aman dan sesuai dengan kepercayaan masyarakat diperlukan dalam penyediaan dan pengolahannya. Pemerintah berperan melalui pengaturan, pelatihan, dan pengawasan untuk mencapai tujuan tersebut[11].

Kontaminasi jamur pada roti dapat menimbulkan ancaman terhadap kesehatan. Beberapa faktor yang dapat meningkatkan risiko kontaminasi jamur termasuk kadar air tinggi dalam roti, suhu penyimpanan yang hangat, dan tingkat keasaman yang sesuai. Tindakan pencegahan dan kontrol seperti penggunaan bahan baku yang berkualitas, proses pengolahan yang hati-hati, dan penyimpanan yang sesuai menjadi sangat penting untuk memastikan keselamatan pangan roti.

2.3. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang dapat digunakan untuk mendeteksi dan objek dalam citra digital. CNN didasarkan pada konsep konvolusi, yang merupakan operasi matematis untuk menggabungkan dua set data menjadi satu[12].

2.4. MobileNetV2

Model transfer learning yang digunakan pada penelitian ini adalah model MobileNet. Model MobileNetV2 pertama kali dikembangkan pada tahun 2012 (Yoss, 2020). Dalam kompetisi ImageNet Large-Scale Visual Recognition Challenge (ILSVRC), model ini telah diuji menggunakan 1,2 juta gambar dari dataset ImageNet yang terdiri dari 1000 kelas[13].

Model *MobileNet* terdiri dari delapan lapisan ekstraksi fitur dalam arsitekturnya, yang mencakup lima lapisan konvolusi dan tiga lapisan *pooling*. Di bagian klasifikasinya, *MobileNet* memiliki tiga lapisan *fully connected*. Setiap lapisan dalam model ini menggunakan fungsi aktivasi *ReLU*, kecuali pada lapisan *fully connected* terakhir yang menggunakan fungsi *softmax*.

2.5. Tensorflow


TensorFlow adalah library open source yang bertujuan untuk membuat dan menggunakan model machine learning. Platform ini mengimplementasikan banyak algoritma dan pola umum yang diperlukan untuk machine learning, sehingga menghemat waktu dalam mempelajari semua matematika dan logika dasarnya, dan memungkinkan fokus pada skenario yang ingin dituju.

2.6. Teknologi Real-time

Teknologi real-time object detection adalah area penting dalam visi komputer yang berfokus pada identifikasi dan menemukan objek dalam aliran video atau gambar saat diambil. Tugas ini membutuhkan algoritma untuk memproses data dengan cepat sambil mempertahankan tingkat akurasi yang dapat diterima. Dengan menggunakan framework deep learning seperti TensorFlow Lite, real-time object detection dapat diimplementasikan pada berbagai perangkat embedded[14].

3. METODE PENELITIAN

Tahapan penelitian ini akan digambarkan melalui Tahapan dalam Mendeteksi Jamur pada Roti.




Gambar 1. Tahapan dalam mendeteksi jamur pada Roti

Penelitian ini menggunakan data primer berupa gambar roti tawar yang teridentifikasi jamur. Data tersebut diperoleh penulis dari toko roti di sekitar Medan Marelan Pasar 1. Pengambilan gambar dilakukan menggunakan kamera beresolusi 108 megapiksel dengan latar belakang putih, dibantu cahaya lampu lighting berdiameter 18 inci (45 cm) dengan daya 50 Watt, dan jarak pengambilan gambar 20 sentimeter.

Tabel 1. Judul tabel

Keterangan	Roti Berjamur	Roti Tidak Berjamur
Citra:		
Deskripsi	Memiliki bintik-bintik atau area dengan warna berbeda (hijau, biru, hitam) dan pola yang tidak beraturan	Memiliki warna konsisten (putih, coklat, dll.) dengan pola seragam atau sesuai yang diharapkan.

Pada penelitian ini, dilakukan preprocessing data (menghapus background gambar, anotasi dengan LabelImg-master, dan konversi file XML ke CSV), pelatihan model menggunakan Transfer Learning MobileNetV2 dengan dataset berlabel "mold_bread" yang terdiri dari 640 gambar melalui Google Colab, ekspor model dalam format kuantisasi (FP32 dan INT8), pengujian performa pada 64 gambar uji dari dua kelas (mold_bread dan clean_bread) untuk mengevaluasi generalisasi model, serta optimasi akurasi hingga mencapai IoU lebih dari 50% melalui konfigurasi ulang parameter pelatihan jika diperlukan.



Gambar 2. Sequence Diagram

Untuk Sequence diagram yang dibuat pada Gambar 2. Menjelaskan bagaimana interaksi dan tahapan sistem dalam mendeteksi objek, Dimana Dalam membuat Sequence Diagram ini memakai metode programming MVC (Model-View-Controller) atau dalam istilah lain Model = Entity, View = Boundary, dan Controller = Control.

4. HASIL DAN PEMBAHASAN


Dalam penelitian ini penulis membangun pelatihan model dengan menggunakan bahasa Python. Model ini dirancang untuk mendeteksi objek jamur pada roti secara real-time dengan memanfaatkan teknologi deep learning.

4.1. Pengumpulan Data

Pengumpulan data adalah tahapan awal penelitian ini, di mana data berupa 640 gambar roti tawar yang teridentifikasi jamur diperoleh dari toko roti di sekitar Medan Marelan Pasar 1. Gambar diambil menggunakan kamera beresolusi 108 megapiksel dengan latar belakang putih, cahaya lampu lighting berdiameter 18 inci (45 cm) dengan daya 50 Watt, dan jarak 20 cm sesuai tinggi tripod, menghasilkan gambar berformat PNG.

Tabel 2. Class dan Jenis Dataset yang digunakan

Class	Jeni File	
	Gambar	annotasi
clean_bread	320 gambar	320 xml
Mold_bread	320 gambar	320 xml
TOTAL	640 gambar + xml	




Gambar 3. Dataset roti berjamur

Berikut pada gambar 3 ada 2 format data yaitu png didapatkan dari hasil jepretan kamera smartphone dan xml dimana didapatkan dari labellmg dengan format PASCAL VOC dengan hasil file berbentuk xml. Pada penelitian ini juga mencantumkan fitur dan parameter dari kedua class yang digunakan yaitu "mold_bread" untuk roti berjamur dan "clean_bread" untuk roti tidak berjamur.

4.2. Standart Deviation

Melakukan standar deviasi untuk mengukur variasi atau sebaran data dalam dua kelas, yaitu roti berjamur (mold_bread) dan roti tidak berjamur (clean_bread), guna menganalisis karakteristik unik setiap kelompok. Eksplorasi warna RGB dilakukan dengan memanfaatkan standar deviasi pada setiap lapisan RGB dalam data sampel.



Gambar 3. Grafik perbandingan Standart Deviasi RGB

Standar deviasi RGB mold_bread menunjukkan fluktuasi lebih besar di setiap kanal warna dibandingkan clean_bread yang lebih stabil dengan penyebaran data kecil, sehingga grafik memberikan gambaran visual tentang konsistensi dan variasi warna pada kedua jenis roti. berikut perhitungan standart deviai:

a. Perhitungan Standart Deviasi mold_bread

Nilai RGB = [98.24, 92.40, 75.74]

Hitung rata-rata (μ)

$$\frac{98.24 + 92.40 + 75.74}{3} = \frac{266.38}{3} = 88.79$$

Hitung selisih setiap nilai dari rata-rata ($x_i - \mu$)

x_i	$x_i - \mu$	$(x_i - \mu)^2$
98.24	$98.24 - 88.79 = 9.45$	$(9.45)^2 = 89.23$
92.40	$92.40 - 88.79 = 3.61$	$(3.61)^2 = 13.01$
75.74	$75.74 - 88.79 = -13.05$	$(-13.05)^2 = 170.39$

Menjumlahkan kuadrat selisih

$$\sum (x_i - \mu)^2 = 89.23 + 13.01 + 170.39 = 272.64$$

Menhitung Variasi

$$\text{variasi} = \frac{\sum (x_i - \mu)^2}{n}$$

$$\text{variasi} = \frac{272.66}{3} = 90.87$$

Menghitung simpangan baku (σ)

$$\sigma = \sqrt{\text{variasi}} = \sqrt{90.87} = 9.53$$

b. Perhitungan Standart Deviasi clean_bread

Nilai RGB = [82.92, 76.20, 66.57]

Hitung rata-rata (μ)

$$\mu = \frac{82.92 + 76.20 + 66.57}{3} = \frac{225.69}{3} = 75.23$$

Hitung selisih setiap nilai dari rata-rata ($x_i - \mu$)

x_i	$x_i - \mu$	$(x_i - \mu)^2$
82.92	$83.06 - 75.23 = 7.69$	$(7.69)^2 = 59.13$
76.20	$77.71 - 75.23 = 0.97$	$(0.97)^2 = 0.94$
66.57	$66.06 - 75.23 = -8.66$	$(-8.66)^2 = 74.99$

Menjumlahkan kuadrat selisih

$$\sum (x_i - \mu)^2 = 59.13 + 0.94 + 74.99 = 135.07$$

Menhitung Variasi

$$\text{variasi} = \frac{\sum (x_i - \mu)^2}{n}$$

$$\text{variasi} = \frac{135.07}{3} = 45.02$$

Menghitung simpangan baku (σ)

$$\sigma = \sqrt{\text{variasi}} = \sqrt{45.02} = 6.71$$

4.3. Praproses Data

Setelah pengumpulan data, dilakukan tahapan praproses untuk memastikan data dapat dipahami oleh model. Praproses meliputi pemisahan data dengan rasio 80% data latih, 10% validasi, dan 10% uji menggunakan library TensorFlow, serta penghilangan latar belakang gambar dengan library rembg dan Pillow untuk memperjelas objek. Setiap gambar dilabeli secara manual menggunakan labelImg, menghasilkan file XML dalam format PASCAL VOC yang kemudian dikonversi ke CSV dan TFRecord. Dataset dilengkapi label map berformat ".pbt.txt" sesuai class "mold_bread." Model dilatih menggunakan konfigurasi pipeline dengan num_steps (1.500–3.500) dan batch size (4, 8, 16) untuk mencari konfigurasi terbaik dengan hasil training.

Tabel 2. Hasil Training

Num_steps	Batch	Akurasi	Loss	Durasi
15000	16	94.81	0.16	2 jam 13 min
17000	16	93.27	0.16	2 jam 27 min
20000	8	92.00	0.17	1 jam 36 min
25000	8	91.37	0.17	1 jam 50 min
25000	4	93.00	0.19	58 min
30000	8	96.42	0.11	2 jam 18 min
30000	4	95.22	0.17	1 jam 20 min
35000	8	93.67	0.15	2 jam 35 min

Dapat dilihat pada tabel 4.3 bahwa hasil training dengan parameter 30000 num_steps dan 8 batch memiliki akurasi tertinggi dengan memiliki akurasi 96.42% walaupun dengan durasi training selama 2 jam 18 menit. Sedangkan hasil training terendah adalah parameter 25000 num_steps dan 8 batch dengan hasil training sebesar 91.37% dengan durasi training selama 1 jam 50 menit, kemudian untuk hasil testing.


Tabel 4. Hasil Testing

No.	Metriks	mold_bread	clean_bread
1.	Jumlah Sampel	32	32
2.	True Positive (TP)	30	32
3.	False Positive (FP)	2	0
4.	True Negative (TN)	32	32
5.	False Negative (FN)	0	2
6.	Akurasi	96.42%	96.42%
7.	Presisi	93.75%	100%
8.	Recall	93.75%	100%
9.	F1-score	93.75%	100%

Pada tabel 4, terlihat bahwa dari 32 sampel class mold_bread, terdeteksi 30 objek jamur, dengan variasi jumlah objek dan persentase IoU yang beragam. Sementara itu, class clean_bread divalidasi langsung jika tidak ada jamur pada roti. Akurasi keseluruhan untuk kedua kelas, mold_bread dan clean_bread, mencapai 96,42%.


4.4. Hasil Deteksi

Hasil deteksi pada gambar 4.17 diperoleh setelah proses pelatihan dan pengujian data selesai. Bounding box muncul jika nilai minimal Confidence Threshold mencapai 0.5 (50%) untuk kedua kelas. Seperti terlihat pada gambar 4 dan 5, bounding box muncul pada objek yang sesuai dengan label di labelmap.txt. Hasil deteksi mencakup objek jamur pada roti dan roti tanpa jamur.



Gambar 4. Hasil Deteksi jamur pada roti tawar

Evaluasi model menggunakan dataset 640 gambar untuk pelatihan dan 64 gambar untuk pengujian. Dataset pelatihan hanya mencakup satu kelas, yaitu "mold_bread," dengan hasil pengujian menunjukkan akurasi deteksi objek sebesar 96,42%.



Gambar 5. Hasil Deteksi pada roti tawar yang tidak berjamur

4.5. Implementasi Deteksi Objek secara Real-time

Hasil akhir dari penelitian ini adalah pengecekan deteksi secara real-time. Dimana model yang sudah dibuat akan diekspor ke TF-lite dan akan di cek model tersebut pada webcam yang terhubung pada perangkat PC atau laptop.



Gambar 6. Hasil Deteksi pada roti tawar yang tidak berjamur

Untuk mendeteksi objek secara real-time model dimasukkan ke dalam folder yang berisi setidaknya file detect.tflite dan labelmap.txt. Setelah itu model akan dieksekusi dan akan dijalankan dengan skrip deteksi dan diarahkan ke folder model yang sudah dibuat kemudian aktifkan enviroment tflite maka akan muncul deteksi objek secara real-time menggunakan webcam.



Gambar 7. Proses real-time testing deteksi pada roti tawar yang berjamur



Gambar 8. Proses real-time testing deteksi pada roti tawar yang berjamur

5. KESIMPULAN DAN SARAN

Kesimpulan dari Penelitian ini menunjukkan bahwa model CNN yang dikembangkan berhasil mendeteksi jamur pada roti secara real-time dengan akurasi tinggi. Pengujian terhadap 8 perubahan model dari transfer learning MobileNetV2 menghasilkan performa terbaik pada parameter 30.000 *num_steps* dan 8 *batch*, dengan akurasi 96,42%, total loss 0,1181, dan durasi pelatihan 2 jam 18 menit 36 detik. Dari 64 data uji, model berhasil mendeteksi 30 dari 32 gambar roti berjamur (*mold_bread*), meskipun pada setiap gambar terdeteksi lebih dari satu objek dengan variasi bentuk, ukuran, dan nilai IoU. Untuk 32 gambar roti tanpa jamur (*clean_bread*), semua berhasil diklasifikasikan dengan benar. Dengan akurasi keseluruhan 96,42%, penelitian ini membuktikan bahwa implementasi CNN efektif dan dapat diandalkan untuk mendeteksi keberadaan jamur pada roti.

Berdasarkan proses dan hasil penelitian ini, terdapat beberapa aspek yang perlu ditingkatkan. Pertama, untuk meningkatkan akurasi model dan menghindari overfitting, disarankan untuk memperbesar dan memperkaya dataset dengan menambahkan lebih banyak gambar berkualitas tinggi yang beragam, mengingat penelitian ini hanya menggunakan 640 gambar untuk datasetnya. Kedua, langkah selanjutnya adalah mengembangkan dan mengintegrasikan model deteksi real-time ke dalam platform digital, seperti website atau aplikasi mobile, agar sistem ini lebih mudah diakses dan memiliki kegunaan praktis yang lebih luas. Ketiga, guna meningkatkan kegunaan model, disarankan untuk memperluas kemampuan deteksi jamur secara real-time pada berbagai jenis roti, tidak hanya terbatas pada roti tawar, sehingga dapat diterapkan secara lebih luas dalam industri roti.

DAFTAR PUSTAKA

- [1] J. Gustavsson, C. Cederberg, U. Sonesson, R. Van Otterdijk, and A. Meybeck, "Causes and prevention of food losses and waste," *Glob. Food Losses Food Waste*, FAO, 2011, pp. 1–8, 2011.

- [2] Ayu Dinda Lestari, Elfrida, and Indriyati, "IDENTIFIKASI JAMUR PADA ROTI YANG DIJUAL DI KOTA LANGSA BERDASARKAN LAMA PENYIMPANAN," vol. 6, no. 2, pp. 2–3, 2019.
- [3] I. Alli, *Principles and Practices Food Quality Assurance*. CRC Press LLC, 2004.
- [4] M. Abbasi, A. Shahraki, and A. Taherkordi, "Deep Learning for Network Traffic Monitoring and Analysis (NTMA): A Survey," *Comput. Commun.*, vol. 170, no. February, pp. 19–41, 2021, doi: 10.1016/j.comcom.2021.01.021.
- [5] N. E. Helwig, S. Hong, and E. T. Hsiao-wecksler, *Buku Ajar Pengolahan Citra Digital*. UMSIDA Press, 2023.
- [6] S. R. Dewi, "Deep Learning Object Detection Pada Video," *Deep Learn. Object Detect. Pada Video Menggunakan Tensorflow Dan Convolutional Neural Netw.*, pp. 1–60, 2018, [Online]. Available: https://dspace.uui.ac.id/bitstream/handle/123456789/7762/14611242_SyarifahRositaDewi_Statistika.pdf?sequence=1
- [7] A. F. H. Dhiya Mahdi Asriny, Septia Rani, "Implementasi Deep Learning Menggunakan Convolutional Neural Network Untuk Klasifikasi Citra Mikroskopis Stomata Tanaman Herbal Curcuma," pp. 1–5, 2019, [Online]. Available: <https://repositori.usu.ac.id/handle/123456789/24599>
- [8] A. J. Dufan J. P. Manajang, Sherwin R.U.A. Sompie, "Implementasi Framework Tensorflow Object Detection Dalam Mengklasifikasi Jenis Kendaraan Bermotor Dufan," *J. Tek. Inform.*, vol. 15, no. 4, pp. 171–178, 2020, doi: 10.35957/jatisi.v8i4.1269.
- [9] I. Vagelas, N. Gougoulas, E. D. Nedesca, and G. Liviu, "Bread contamination with fungus," *Carpathian J. Food Sci. Technol.*, vol. 3, no. 2, pp. 1–6, 2011.
- [10] T. Suryani, Y., & Cahyanto, *Pengantar jamur mikroskopis*, no. 112. Gunung Djati Publishing, 2022.
- [11] M. M. . Margaretha Fiani S. dan Edwin Japariato, S.E., "ANALISA PENGARUH FOOD QUALITY DAN BRAND IMAGE TERHADAP KEPUTUSAN PEMBELIAN ROTI KECIK TOKO ROTI GANEP'S DI KOTA SOLO," *J. Manaj. Pemasar.*, vol. 1, no. 1, pp. 1–6, 2012, doi: 10.1103/PhysRevB.47.334.
- [12] D. R. R. Putra and R. A. Saputra, "Implementasi Convolutional Neural Network (Cnn) Untuk Mendeteksi Penggunaan Masker Pada Gambar," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 710–714, 2023, doi: 10.23960/jitet.v11i3.3286.
- [13] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network _ Ilahiyah _ JUSTINDO (Jurnal Sistem dan Teknologi Informasi Indonesia)," *JUSTINDO(Jurnal Sist. Teknol. Inf. Indones.*, vol. 3, no. 2, pp. 49–56, 2018.
- [14] R. Fajri and F. Fitria, "KLIK: Kajian Ilmiah Informatika dan Komputer Pengembangan Real-Time Object Detection System pada Perangkat Single-Board Computer," *Media Online*, vol. 4, no. 2, pp. 1154–1162, 2023, doi: 10.30865/klik.v4i2.1224.