



Implementasi *Quality Management System* pada Baterai *Lithium* dengan Metode *Convolutional Neural Network* (CNN)

Desiana Elsa Emilia¹, Aji Setiawan^{2*}

^{1,2}Program Studi Teknologi Informasi Fakultas Teknik, Universitas Darma Persada
Jl. Taman Malaka Selatan No.22, Pondok Kelapa, Duren Sawit, DKI Jakarta, Indonesia 13450

*aji_setiawan@ft.unsada.ac.id

Abstrak — Baterai *lithium-ion* adalah termasuk dalam jenis baterai sekunder (jenis baterai yang dapat diisi ulang) yang berfungsi untuk menyimpan dan mengalirkan energi secara elektrokimia. Baterai *lithium-Ion* umumnya digunakan dalam berbagai perangkat elektronik portabel seperti *smartphone*, laptop, tablet, kamera digital, dan perangkat elektronik lainnya. Baterai *Li-Ion* terdiri dari sel-sel individu yang memiliki elektroda positif (anoda) dari lithium dan elektroda negatif (katoda) yang biasanya terbuat dari grafit. Penggunaan metode *Convolutional Neural Network* berguna untuk deteksi kecacatan produk yang digabungkan dengan beberapa model seperti *ResNet*, *MobileNet*, dan *Inception*. Penggunaan kombinasi ini telah terbukti menghasilkan tingkat akurasi yang signifikan dalam mengidentifikasi cacat pada produk baterai. Model dilatih dengan dataset yang cukup besar dan memiliki arsitektur yang mampu untuk mendeteksi kecacatan baterai dengan lebih baik, dan canggih. Model CNN yang telah dikembangkan mampu mengklasifikasikan jenis baterai menggunakan 3 model berbeda dan menghasilkan tingkat akurasi yang cukup tinggi. Hasil pengujian dengan 100 *epoch* menggunakan *optimizer* Adam menghasilkan tingkat akurasi sebesar 96% untuk model *Inception*, model *ResNet* menghasilkan akurasi sebesar 94% dan model *MobileNet* yang menghasilkan tingkat akurasi sebesar 92%. Dalam hal ini, model *ResNet* direkomendasikan untuk klasifikasi karena dapat memprediksi hasil dengan lebih akurat dibanding model *MobileNet* dan *Inception*.

Kata kunci – Baterai *Lithium-ion*, *Convolutional Neural Network*, *ResNet*, *MobileNet*, *Inception*

Copyright © 2024 JURNAL TIFDA
All rights reserved.

I. PENDAHULUAN

Di antara sekian banyaknya sumber energi yang tersedia, baterai memiliki peranan yang sangat signifikan dalam memenuhi kebutuhan manusia. Baterai menjadi salah satu sumber utama energi listrik yang sangat diperlukan untuk mengoperasikan perangkat elektronik yang mudah dibawa atau portabel [1]. Baterai *lithium-ion* adalah termasuk dalam jenis baterai sekunder (jenis baterai yang dapat diisi ulang) yang berfungsi untuk menyimpan dan mengalirkan energi secara elektrokimia. Baterai *lithium-ion* umumnya digunakan dalam berbagai perangkat elektronik portabel seperti *smartphone*, laptop, tablet, kamera digital, dan perangkat elektronik lainnya. Baterai *lithium-ion* terdiri dari sel-sel individu yang

memiliki elektroda positif (anoda) dari *lithium* dan elektroda negatif (katoda) yang biasanya terbuat dari grafit [2].

Namun, selain keunggulan yang dimiliki oleh baterai *lithium-ion*, terdapat beberapa masalah yang perlu diperhatikan. Dilansir dari CBS News, pada bulan Maret tahun 2024, kebakaran hebat terjadi di lingkungan Marble Hill, New York, akibat baterai *lithium-ion* pada sepeda listrik. Hal ini mengakibatkan 10 orang terluka, termasuk 6 petugas pemadam kebakaran, serta lebih dari 24 orang kehilangan tempat tinggal karena kerusakan bangunan apartemen. Penyebab kebakaran adalah baterai *lithium-ion* pada sepeda listrik yang ditemukan di lantai pertama gedung. Kebakaran ini memaksa sebagian penghuni melarikan diri melalui tangga darurat. Sejumlah

penghuni berusaha menyelamatkan hewan peliharaan dan barang berharga, sementara petugas pemadam kebakaran berjuang memadamkan api dan menyelamatkan barang penting.

Sebelumnya, pada bulan Juni tahun 2023, kebakaran di toko *e-bike* di New York menewaskan 4 orang dan melukai 2 orang lainnya. Insiden serupa terus meningkat di kota besar seperti New York dan San Fransisco. Setidaknya sejak tahun 2019, pemadam kebakaran di kedua kota tersebut mengatakan bahwa mereka telah merespon setidaknya 669 total dari seluruh insiden yang terjadi. Pada tahun 2022, lebih dari 200 kebakaran akibat baterai *lithium-ion* terjadi di New York. Sejak tahun 2019, terjadi kebakaran serupa yang menyebabkan 326 korban luka di New York dan 7 orang korban luka di San Fransisco pada periode waktu yang sama [3].

Berdasarkan latar belakang tersebut, penelitian ini berfokus terhadap upaya peningkatan kualitas baterai minim cacat menggunakan metode CNN, agar dapat meningkatkan efisiensi dan akurasi dalam mengidentifikasi kualitas pada produk baterai yang diproduksi di PT. Panasonic Gobel Energy Indonesia. Dengan menerapkan metode CNN, diharapkan proses inspeksi kualitas dapat dilakukan secara otomatis dan lebih cepat, sehingga mengurangi risiko kesalahan serta mempercepat proses produksi secara keseluruhan.


Rumusan masalah penelitian ini adalah bagaimana meningkatkan efisiensi dan akurasi dalam proses identifikasi pada baterai yang diproduksi di PT. Panasonic Gobel Energy Indonesia dan bagaimana menerapkan metode CNN untuk melakukan identifikasi kualitas pada baterai. Tujuan penelitian ini adalah menerapkan teknologi CNN dalam proses identifikasi baterai untuk meningkatkan efisiensi dalam proses inspeksi kualitas dan membangun sistem dengan model CNN yang mampu mengenali dan mengklasifikasikan baterai berdasarkan kualitasnya untuk memastikan bahwa setiap baterai yang diproduksi memenuhi standar kualitas yang ditetapkan oleh perusahaan.

II. METODOLOGI

Metode pengumpulan data yang digunakan adalah metode wawancara dengan melakukan studi awal untuk mengidentifikasi masalah yang akan diteliti, agar mendapat pemahaman yang lebih mendalam dari responden dengan jumlah yang terbatas. Metode ini bergantung pada *self-report*, atau setidaknya pada pengetahuan dan keyakinan pribadi [4].

Pada penelitian ini, wawancara dilakukan secara *online* melalui *Microsoft Teams* untuk mendapat informasi secara spesifik terkait *defect* baterai seperti apa yang sering terjadi. *Platform* ini dipilih karena kemampuannya untuk menyediakan komunikasi yang lancar melalui video, audio, dan *chat*, serta fitur-fitur tambahan lainnya yang dapat mendukung proses wawancara menjadi lebih efektif.

Prosedur wawancara dirancang untuk memastikan pengumpulan data yang valid dan reliabel. Sebelum wawancara, peneliti mengirimkan undangan kepada narasumber yang berisi informasi tentang tujuan penelitian, jadwal wawancara, serta tautan untuk mengakses sesi *Microsoft Teams*. Tahapan proses penelitian dapat dilihat pada Gambar 1, dibawah ini:



Gambar 1. *Flowchart* Diagram Proses Penelitian

Dengan menggunakan metode CRISP-DM, sebagai berikut:

1. *Business Understanding*
Memahami bagaimana identifikasi baterai atau mendeteksi baterai yang *defect*.
2. *Data Understanding*
Mengumpulkan data gambar baterai *defect* dan *non-defect*.
3. *Data Preparation*
Mengolah *raw* data untuk proses *modelling* dan mengubah data dalam format yang sesuai.
4. *Modelling*
Menerapkan algoritma CNN untuk proses klasifikasi data gambar.
5. *Evaluation*
Mengevaluasi model untuk mengukur tingkat efektivitas dan akurasi yang diperoleh.
6. *Deployment*
Implementasi model kedalam sistem untuk mengklasifikasikan baterai.

III. LANDASAN TEORI

3.1 *Quality Management System*

Statistical Quality Control (SQC) merupakan penerapan penting dari teknik statistik dalam industri manufaktur. Umumnya, industri manufaktur mendapatkan bahan baku dari vendor.

Untuk memastikan kualitasnya, penting untuk memeriksa bahan baku sebelum mengambil keputusan untuk menerima atau menolaknya [5].

3.2 ISO 9000

Definisi dari Standar ISO 9000 untuk sistem manajemen kualitas (*Quality Management System, QMS*) adalah sebuah kerangka kerja yang mencakup struktur organisasi, tanggung jawab, prosedur, proses, dan sumber daya yang digunakan untuk menerapkan praktik-praktik manajemen kualitas. QMS terdiri dari serangkaian prosedur terdokumentasi dan standar praktik yang bertujuan memastikan bahwa proses atau produk (baik barang maupun jasa) sesuai dengan kebutuhan atau persyaratan yang telah ditetapkan oleh pelanggan dan organisasi [6].

3.3 Machine Learning

Machine Learning adalah bagian dari *Artificial Intelligence (AI)* yang memungkinkan komputer untuk mengasimilasi informasi dari data tanpa memerlukan program yang spesifik. Artinya, tujuan dari *Artificial Intelligence* adalah untuk mengembangkan metode yang secara otomatis melakukan observasi terhadap dunia nyata atau biasa disebut "*training data*", tanpa kebutuhan aturan atau logika eksplisit yang didefinisikan oleh manusia (pengajar/*supervisor*). Dalam hal ini, *Machine Learning* dapat dianggap sebagai proses pemrograman berdasarkan sampel data. Secara keseluruhan, *Machine Learning* membahas tentang bagaimana belajar untuk meningkatkan kinerja di masa mendatang berdasarkan pengalaman di masa lalu [7].

3.4 Deep Learning

Deep Learning merupakan cabang dari *Artificial Intelligence* yang berfokus pada pembuatan model *neural network* yang besar dan mampu mengambil keputusan yang akurat berdasarkan data [8]. *Deep Learning* sangat sesuai untuk digunakan dalam situasi di mana data yang dihadapi bersifat kompleks dan terdapat kumpulan data dalam jumlah yang besar. *Deep Learning* berfungsi untuk membuat prediksi sesuai dengan *input* yang masuk ke dalam sistem. Cara kerja *Deep Learning* mirip sekali dengan cara kerja otak manusia. Terdapat *hidden layer* yang berfungsi seperti hubungan antar saraf otak. Lapisan ini berguna untuk pembelajaran pada mesin, *Deep Learning* memiliki dua jenis algoritma seperti algoritma ANN (*Artificial Neural Network*) dan algoritma DNN (*Deep Neural Network*) [9].

3.5 Visi Komputer (*Computer Vision*)

Visi Komputer (*Computer Vision*) adalah bidang penelitian yang mempelajari cara komputer memproses gambar dan memahami apa yang ada di dalamnya. Ini mencakup penggunaan jaringan saraf komputer untuk melakukan berbagai tugas seperti mengklasifikasikan objek, segmentasi, mendeteksi objek di dalam gambar, dan pemahaman *scene*. Sebagian besar arsitektur *Convolutional Neural Network (CNN)* sering digunakan dalam visi komputer untuk masalah-masalah seperti mengidentifikasi wajah atau objek dalam gambar, menandai objek dalam gambar dengan kotak pembatas di sekitar setiap objek, segmentasi (misalnya, memberi label pada *pixel* gambar masukan), dan generasi gambar (misalnya, mengubah gambar beresolusi rendah menjadi yang beresolusi tinggi) [7].

3.6 Object Detection

Deteksi Objek (*Object Detection*) adalah tugas utama dalam bidang visi komputer (*Computer Vision*) yang menangani identifikasi lokasi objek di dalam sebuah gambar. Sebagian besar tugas visi komputer, termasuk pelacakan objek otomatis, segmentasi instan, penjelasan gambar, dan deteksi anomali dan lain sebagainya, sangat bergantung pada deteksi objek. Sementara itu, pengenalan objek fokus pada identifikasi objek yang ada dalam sebuah gambar, sementara deteksi objek juga bertujuan untuk menemukan lokasi objek tersebut [10].

3.7 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah satu jenis jaringan saraf yang paling populer, terutama untuk data yang memiliki dimensi tinggi seperti gambar dan video. Meskipun cara kerja CNN mirip dengan jaringan saraf biasa, perbedaan utamanya terletak pada setiap unit dalam lapisan CNN yang berfungsi sebagai *filter* 2D atau berdimensi tinggi yang mengalami konvolusi dengan *input* dari lapisan tersebut [7].

3.8 Arsitektur Convolutional Neural Network (CNN)

Beberapa tahapan utama dalam proses pengolahan data pada *Convolutional Neural Network* adalah *Input Layer* yang bertindak sebagai titik awal di mana data gambar dimasukkan ke dalam jaringan, *Convolutional Layers* yang berperan dalam mengekstraksi fitur-fitur penting dari gambar melalui proses konvolusi, *Fully Connected Layers* yang berperan untuk menyatukan fitur-fitur yang diekstraksi ke dalam

representasi yang lebih abstrak, dan *Output Prediction Layer* yang berperan untuk memproduksi hasil berupa prediksi kelas atau nilai yang diinginkan berdasarkan *input* yang diberikan [11].

3.9 Sigmoid

Sigmoid adalah fungsi aktivasi yang digunakan dalam jaringan saraf tiruan, termasuk *Convolutional Neural Network (CNN)*. Fungsi ini mengubah nilai *input* menjadi nilai antara 0 dan 1, membuatnya sangat cocok untuk tugas klasifikasi biner.

3.10 Binary Cross Entropy (BCE)

Binary Cross Entropy (BCE) adalah fungsi *loss* yang umum digunakan dalam tugas klasifikasi biner, termasuk klasifikasi gambar dengan *Convolutional Neural Networks (CNN)*. BCE mengukur perbedaan antara distribusi probabilitas yang diprediksi dan distribusi aktual. Fungsi ini sangat cocok untuk melatih model dalam menyelesaikan banyak masalah klasifikasi sekaligus, jika setiap klasifikasi dapat direduksi menjadi pilihan biner.

3.11 Akurasi

Akurasi adalah ukuran kinerja yang sering digunakan dalam evaluasi model klasifikasi. Akurasi menunjukkan seberapa sering model klasifikasi membuat prediksi yang benar dibandingkan dengan total prediksi yang dilakukan. Secara matematis, akurasi dihitung sebagai rasio jumlah prediksi benar terhadap jumlah total sampel yang diuji.

3.12 Residual Network (ResNet)

Residual Network (ResNet) adalah tipe jaringan saraf tiruan yang dirancang berdasarkan struktur sel piramidal yang terdapat di korteks serebral [12]. *ResNet* adalah model yang telah dilatih sebelumnya sehingga tidak memerlukan konfigurasi untuk pengaturan *layer* nya. Prinsip kerja *ResNet* adalah membangun jaringan yang lebih dalam dibandingkan jaringan konvensional, sambil menemukan jumlah lapisan optimal untuk mengatasi masalah gradien yang menghilang [13].

3.13 MobileNet

MobileNet adalah model dengan latensi rendah dan konsumsi daya minimal, yang dirancang untuk mengatasi keterbatasan sumber daya dalam berbagai skenario penggunaan [14]. *MobileNet*

menggunakan *depthwise separable convolutions*, yang membagi *convolutions* standar menjadi *depthwise convolution* (satu *filter* per saluran *input*) dan *pointwise convolution* (*convolutions* 1×1 untuk penggabungan hasil). Ini memisahkan proses penyaringan dan penggabungan yang biasanya dilakukan dalam satu langkah pada *convolutions* standar [15].

3.14 Inception

Inception V3 adalah jenis jaringan saraf konvolusi yang dikembangkan oleh tim peneliti Google pada tahun 2015. Model ini merupakan pengembangan dari versi sebelumnya, yaitu *Inception V1* dan *Inception V2*, dengan tujuan untuk meningkatkan kecepatan komputasi dan kinerja dalam mengenali gambar [16].

IV. HASIL DAN PEMBAHASAN

4.1 Pengumpulan Data

Metode pengumpulan *dataset* dilakukan dengan mengambil gambar menggunakan *handphone* dan dibantu dengan pencahayaan dari *Mini Studio Box* yang memiliki pencahayaan yang cukup terang yang hampir setara dengan standar untuk pengecekan *defect* baterai yang sebesar 300 lux. Pengambilan foto dilakukan dengan lensa kamera makro pada jarak sekitar 7 cm dari baterai, memungkinkan pengambilan *detail* baterai dengan jelas pada resolusi 3120 x 4160 piksel. Baterai yang digunakan untuk penelitian adalah baterai *lithium* tipe AAA jenis *Manganese* dari merk Panasonic. Seperti yang dapat dilihat pada Gambar 6.

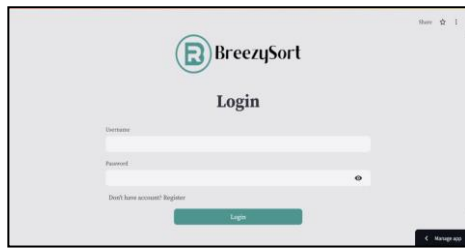


Gambar 6. Dokumentasi Pengambilan *Dataset* Gambar

4.2 Alat yang Digunakan


1. *Mini Studio Photo Box*
2. Lensa Kamera Makro
3. Baterai *Lithium* AAA Merk Panasonic
4. *Handphone*

4.3 Tampilan *Interface* Hasil Deploy




Gambar 7. Halaman *Login*

Pada Gambar 7 diatas adalah Halaman *Login* untuk masuk ke *dashboard* sistem prediksi baterai dengan memasukkan *username* dan *email* terlebih dahulu.




Gambar 8. Halaman *Register*

Pada Gambar 8 diatas adalah Halaman *Register* untuk mendaftar akun sebelum melakukan *Login* untuk masuk ke *dashboard* sistem prediksi baterai.



Gambar 9. Halaman *Upload Image Single Predict*

Pada Gambar 9 diatas adalah Halaman *Upload Image Single Predict* untuk melakukan prediksi gambar baterai dengan *upload* gambar secara satu persatu.



Gambar 10. Halaman *Upload Image Batch Predict*

Pada Gambar 10 diatas adalah Halaman *Upload Image Batch Predict* untuk melakukan prediksi gambar baterai yang bisa dilakukan menggunakan banyak gambar sekaligus.

4.4 Testing Hasil

Untuk menguji kemampuan sistem klasifikasi, telah dilatih menggunakan dataset baterai *defect* sebanyak 150 gambar dan dataset *non-defect* sebanyak 150 gambar, digunakan 2 macam metrik yaitu *loss* dan akurasi. Berikut adalah tabel hasil akurasi dan *loss* model yang telah dilatih:

Tabel 4.1 Hasil Akurasi dan *Loss*

Model	Akurasi		Loss	
	Train	Validation	Train	Validation
Resnet	94%	94%	2.01	2.07
MobileNet	92%	92%	3.28	3.29
Inception	92%	96%	2.85	2.85

Hasil akurasi dan *loss* pada Tabel 4.1 menunjukkan hasil dari ketiga model yang telah dilatih dengan 100 *epoch* menggunakan *optimizer* Adam yang menghasilkan akurasi sebesar 94% untuk *Resnet*, 92% untuk *MobileNet*, dan 96% untuk *Inception*. Hasil akurasi menunjukkan bahwa *Inception* menghasilkan akurasi yang paling tinggi dan disusul oleh *ResNet*, sedangkan *MobileNet* menghasilkan akurasi yang paling rendah, namun dapat menghasilkan performa yang akurat dan stabil. Akurasi yang lebih tinggi pada *Inception* seringkali membuat *Inception* kurang akurat dalam memprediksi gambar karena tidak seimbangny hasil akurasi *train* dan *validation*.

Hasil *computing cost* dari ketiga model setelah dilatih menggunakan 100 *epoch* adalah sebagai berikut:

Tabel 4.2 Hasil perbandingan *Computing Cost*

Model	Computing Cost
Resnet	42 Menit
MobileNet	37 Menit
Inception	1 Jam

4.5 Perbandingan Inspeksi Pengecekan

Setelah dilakukan pengecekan baterai menggunakan sistem yang telah dibuat, pengecekan terhadap baterai secara langsung oleh tim *quality control* juga telah dilakukan dan menghasilkan perbandingan akurasi yang cukup tinggi.



Gambar 11. Hasil Inspeksi Tim QC vs Sistem

V. KESIMPULAN

Penelitian dan pengembangan sistem klasifikasi baterai dengan metode *Convolutional Neural Network (CNN)* menghasilkan beberapa kesimpulan penting. Model CNN yang dikembangkan mampu mengklasifikasikan jenis baterai dengan akurasi tinggi, di mana *Inception* mencapai akurasi 96%, *ResNet* 94%, dan *MobileNet* 92%. Meskipun proses pelatihan model memakan waktu lama, efisiensi dapat ditingkatkan dengan teknik optimasi seperti augmentasi data dan penggunaan GPU. Ketergantungan pada kualitas gambar *input* dan variasi data *train* mempengaruhi performa model. Sistem klasifikasi ini memiliki potensi besar untuk diimplementasikan di industri elektronik, meningkatkan efisiensi operasional dan mengurangi risiko kesalahan manual.

DAFTAR PUSTAKA

- [1] M. Nasution, "Karakteristik Baterai Sebagai Penyimpan Energi Listrik Secara Spesifik," *Cetak J. Electr. Technol.*, vol. 6, no. 1, pp. 35–40, 2021.
- [2] D. Iestari Dewi, S. Susilo, and B. Widodo, "Analisa Ketahanan Baterai Lithium Ion pada Sepeda Listrik Roda Tiga," *Lektrokom J. Ilm. Tek. Elektro*, vol. 5, no. 1, pp. 24–37, 2022, doi: 10.33541/lektrokom.v5i1.5243.
- [3] A. Quraishi, A. Zalani, R. Beard, and D. Mercedes, "Lithium-ion battery fires from electric cars, bikes and scooters are on the rise. Are firefighters ready?" 2023.
- [4] D. Sugiyono, *Metode Penelitian Kuantitatif, Kualitatif, dan Tindakan*. 2013.
- [5] D. Selvamuthu and D. Das, *Introduction to statistical methods, design of experiments and*

- statistical quality control*. 2018. doi: 10.1007/978-981-13-1736-1.
- [6] V. Gaspersz, *ISO 9001 : 2000 and continual quality improvement*. Jakarta SE - vii, 189 pages : illustrations ; 23 cm: Gramedia Pustaka Utama, 2001. doi: LK - https://worldcat.org/title/968513053.
- [7] S. Khan, H. Rahmani, S. A. A. Shah, and M. Bennamoun, *A Guide to Convolutional Neural Networks for Computer Vision*, vol. 8, no. 1. 2018. doi: 10.2200/s00822ed1v01y201712cov015.
- [8] J. D. Kelleher, *Deep learning*. Cambridge, Massachusetts SE - x, 280 pages : illustrations ; 18 cm.: The MIT Press, 2019. doi: LK - https://worldcat.org/title/1081370294.
- [9] F. Naufal Ihsan Dhuha, A. Prasasti Luhur, and M. Saputra Adhi, "Sistem Inspeksi Visual Kecacatan Pada Sel Baterai Lithium Menggunakan Cnn 2 Dimensi," vol. 8, no. 5, p. 6694, 2021, [Online]. Available: https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/16489
- [10] S. Poonkuntran, R. K. Dhanraj, and B. Balusamy, *Object Detection with Deep Learning Models: Principles and Applications*. 2022. doi: 10.1201/9781003206736.
- [11] M. Elgendy, *Deep Learning for Vision Systems*. 2020.
- [12] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 70–77, 2022, doi: 10.29207/resti.v6i1.3373.
- [13] A. Ridhovan and A. Suharso, "Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jupi.v7i1.2410.
- [14] A. R. Fahcuroji, Madona Yunita Wijaya, and Irma Fauziah, "Implementasi Algoritma Cnn Mobilenet Untuk Klasifikasi Gambar Sampah Di Bank Sampah," *PROSISKO J. Pengemb. Ris. dan Obs. Sist. Komput.*, vol. 11, no. 1, pp. 45–51, 2024, doi: 10.30656/prosisko.v11i1.8101.
- [15] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, [Online]. Available: http://arxiv.org/abs/1704.04861
- [16] A. W. Kosman, Y. Wahyuningsih, and F. Mahendrasusila, "Penguujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit," *J. Teknol. Inform. dan Komput.*, vol. 10, no. 1, pp. 132–142, 2024, doi: 10.37012/jtik.v10i1.1940.