

Analisis Komparatif Arsitektur CNN dan VGG16 pada Klasifikasi Genre Musik

Komang Indra Pradnya^{a1}, Made Agung Raharja^{a2}

Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana

Jalan Raya Kampus Udayana, Bukit Jimbaran, Kuta Selatan, Badung, Bali Indonesia

¹pradnya.2308561114@student.unud.ac.id

²made.agung@unud.ac.id

Abstract

Music genre classification based on spectrogram images is an important task in music information retrieval. This study compares the performance of a custom Convolutional Neural Network (CNN) architecture and VGG-16 for classifying five music genres from the GTZAN dataset: blues, classical, hiphop, metal, and reggae. A total of 500 audio files were converted into spectrogram images for training and testing. Custom CNN were designed and trained from scratch, while VGG-16 utilized pretrained weights with fine-tuning applied to the fully connected layers. Experimental results show that the custom CNN achieved 75% test accuracy and a macro F1-score of 0.74, outperforming VGG-16 which achieved 68.75% accuracy and a macro F1-score of 0.67. These findings demonstrate the advantage of using tailored architecture for spectrogram-based music genre classification and provide directions for future research, including full fine-tuning of pretrained models, hybrid architectures, and integration of temporal features.

Keywords: Music Genre Classification, Spectrogram, CNN, VGG-16, Information Retrieval


1. Pendahuluan

Musik menjadi seni universal yang selalu menemani seseorang kemanapun kita pergi [1]. Hingga saat ini, musik telah menghadirkan beragam genre yang membantu pendengar menemukan musik yang disukai. Pengelompokan genre musik dilakukan dengan mengelompokkan musik sesuai dengan kemiripan gaya, tema, dan teknik musik satu sama lain. Klasifikasi genre musik adalah langkah penting dalam mengorganisir keanekaragaman musik yang ada. Hal ini tidak hanya membantu mengelola dan mengkategorikan musik, tapi juga membantu merekomendasikan musik secara efektif dan otomatis kepada pendengar sesuai preferensi. Seiring dengan meningkatnya volume musik digital, pendekatan komputasional untuk klasifikasi musik menjadi semakin penting. Pendekatan awal untuk klasifikasi genre musik mengandalkan algoritma *machine learning*. Klasifikasi musik dilakukan dengan membuat ekstraksi fitur setiap musik untuk mengubah nilai musik ke dalam bentuk numerik, ini karena komputasi hanya mampu memproses input dalam bentuk numerik [2]. Beberapa penelitian terkait klasifikasi genre telah dilakukan demi mendapatkan akurasi komputasi yang baik. Penelitian yang dilakukan [3] memanfaatkan arsitektur CNN untuk mengatasi kelemahan metode klasik dengan kemampuan komputasi untuk belajar dan mengekstrak fitur relevan secara otomatis langsung dari representasi visual sinyal audio, yaitu spektogram. Hasilnya akurasi tes yang didapat sebesar 81.33% pada dataset lagu Indonesia. Penelitian lain dilakukan oleh [4] yang menggunakan pendekatan *transfer learning* dengan mengadaptasi arsitektur VGG-16 pada dataset GTZAN yang menunjukkan akurasi sebesar 60%. Meskipun arsitektur canggih terus berkembang. Analisis perbandingan fundamental antara beberapa metode komputasi perlu dilakukan. Hal ini dilakukan untuk peningkatan performa dari hasil penelitian sebelumnya dan kebutuhan untuk memahami kompleksitas dan efektivitas pada dataset yang sama. Oleh karena itu, penelitian ini mengusulkan sebuah analisis komparatif untuk mengevaluasi secara langsung kinerja arsitektur CNN kustom dan VGG-16 guna memberikan wawasan praktis bagi pengembangan sistem klasifikasi genre musik. Pemilihan arsitektur CNN kustom dalam penelitian ini didasari oleh fleksibilitas untuk dilatih dari awal agar menyesuaikan pola domain spektrogram musik, tanpa

bergantung pada bobot awal dari domain lain [3]. Sementara itu, VGG-16 dipertimbangkan sebagai pembanding karena telah terbukti stabil dalam berbagai tugas transfer learning [4]. Dengan demikian, analisis komparatif ini diharapkan mampu memberikan wawasan praktis terkait performa arsitektur yang dirancang khusus dibandingkan dengan model pretrained pada klasifikasi genre musik berbasis spektrogram.

2. Metode Penelitian

Dalam penelitian ini, terdapat alur prosedur penelitian dalam mengklasifikasikan genre musik. Dimulai dari pengumpulan data hingga evaluasi model dan analisis komparatif kedua model. Alur prosedur ditunjukkan pada Gambar 1.



Gambar 1. Flowchart Alur Penelitian

2.1 Pengumpulan Dataset

Penelitian ini menggunakan dataset sekunder yang dikenal sebagai “*GTZAN Dataset - Music Genre Classification*” yang diunduh dari situs www.kaggle.com. Dataset GTZAN menghadirkan 1000 klip musik, terdiri dari 10 genre yaitu *pop*, *blues*, *classical*, *country*, *disco*, *hiphop*, *jazz*, *metal*, *reggae*, dan *rock* dengan masing-masing genre terdiri dari 100 klip musik. Tiap klip musik memiliki Panjang durasi 30 detik, dengan format musik *.wav*. Pada penelitian ini, jumlah dataset yang digunakan hanya 500 klip music, terdiri dari 5 genre yang dipilih yaitu *blues*, *classical*, *hiphop*, *metal*, dan *reggae* dengan masing-masing genre terdiri dari 100 klip musik.

Tabel 1. Jumlah dan Pembagian Dataset Musik

Genre Musik	Jumlah Klip
Blues	100
Classical	100
Hiphop	100
Metal	100
Reggae	100

2.2 Preprocessing

Tahap *preprocessing* dilakukan untuk mempersiapkan data mentah yaitu spektrogram, agar menjadi format yang optimal dan siap diproses oleh model *machine learning*. Preprocessing terdiri dari tiga tahapan utama dimulai dari pemuatan spektrogram, normalisasi, dan pembagian dataset. Langkah pertama yaitu pemuatan spektrogram. Spektrogram merupakan representasi visual dari spektrum frekuensi sinyal audio [4]. Dataset GTZAN telah memuat spektrogram yang dihasilkan dan disimpan dalam folder genre masing-masing.


Program akan membaca file spektrogram sebagai sebuah matriks piksel. Kemudian ukuran gambar akan diseragamkan, ini dikarenakan model arsitektur CNN mengharuskan input data memiliki dimensi yang sama persis satu sama lain [4]. Matriks piksel dimasukkan ke daftar bersamaan dengan label genre yang sesuai pada daftar terpisah. Daftar akan dikonversi menjadi dua buah array, satu array berisi data semua gambar spektrogram yang siap pakai, dan satu array lagi berisi label yang sesuai dengan setiap gambar. Tahap normalisasi dilakukan untuk memastikan skala nilai piksel gambar seragam, sehingga mempercepat proses pelatihan dan meningkatkan stabilitas model [5]. Pembagian dataset yang digunakan dalam penelitian ini terbagi menjadi 3 bagian yaitu data *training*, data validasi, dan data *testing* dengan rincian pada Tabel 2.

Tabel 2. Pembagian Dataset yang Digunakan pada Setiap Genre

Genre Musik	Data <i>Training</i>	Data Validasi	Data <i>Testing</i>
Blues	80	10	10
Classical	80	10	10
Hiphop	80	10	10
Metal	80	10	10
Reggae	80	10	10

2.3 Customize CNN

Model pertama yang digunakan untuk metode klasifikasi adalah *Convolutional Neural Network* (CNN) kustom yang dibangun dari awal. Pendekatan ini memungkinkan perancangan model yang spesifik untuk tugas klasifikasi genre musik berbasis spektrogram. CNN merupakan salah satu metode *deep learning* yang sangat efektif untuk memproses data citra karena kemampuannya dalam melakukan ekstraksi fitur secara otomatis [3].



Gambar 2. Diagram Visualisasi Model CNN

Struktur model yang dibangun terdiri dari dua bagian utama yaitu lapisan ekstraksi fitur dan lapisan klasifikasi [6]. Blok ekstraksi fitur pada model ini terdiri dari tiga blok konvolusi yang ditumpuk. Setiap blok berisi sebuah lapisan konvolusi (*Conv2D*) yang berfungsi sebagai inti dari CNN untuk mengekstraksi fitur menggunakan serangkaian filter yang dapat dipelajari, diikuti oleh sebuah lapisan *MaxPooling2D* yang bertugas untuk mereduksi dimensi spasial dari peta fitur sehingga mengurangi beban komputasi. Setelah fitur diekstraksi, hasilnya diratakan menggunakan lapisan *flatten* dan dimasukkan ke blok klasifikasi. Blok ini terdiri dari lapisan *fully connected* (*Dense*) yang mengambil fitur-fitur tingkat tinggi yang telah diekstraksi untuk menghasilkan keputusan klasifikasi akhir. Sebuah lapisan *dropout* juga disisipkan untuk regularisasi guna mencegah *overfitting*. Struktur dasar yang terdiri dari lapisan konvolusi, lapisan *pooling*, dan *fully connected* ini merupakan arsitektur fundamental dalam CNN. Lapisan output terakhir menggunakan aktivasi *softmax* untuk menghasilkan probabilitas untuk setiap dari 5 kelas genre.

2.4 VGG-16

Model kedua yang digunakan untuk metode klasifikasi memanfaatkan arsitektur VGG-16 yang sudah teruji. Arsitektur VGG-16 digunakan dalam teknik klasifikasi gambar *deep learning* karena memiliki kinerja baik dan kemudahan implementasi [6]. Arsitektur ini dikenal karena kesederhanaannya yang menggunakan tumpukan filter konvolusi berukuran 3x3 dan memiliki kedalaman 16 lapisan. Dalam penelitian ini, VGG-16 digunakan sebagai ekstraktor fitur utama. Proses implementasinya dimulai dengan memuat model VGG-16 yang telah dilatih pada dataset *ImageNet*, dengan membuang lapisan klasifikasi aslinya. Selanjutnya, seluruh lapisan konvolusi pada *base model* VGG-16 "dibekukan" untuk mempertahankan pengetahuan fitur visual yang sudah ada. Kemudian, sebuah blok klasifikasi kustom baru, yang terdiri dari lapisan *flatten*, *dropout*, dan *dense* dengan aktivasi *softmax* untuk 5 kelas genre, ditambahkan di atas arsitektur yang telah dibekukan tersebut. Dengan demikian, hanya lapisan klasifikasi baru ini yang dilatih menggunakan dataset spektrogram genre musik, memungkinkan adaptasi model yang efisien tanpa harus melatih seluruh 16 lapisan dari awal.

2.5 Evaluasi dan Analisa

Tahap evaluasi bertujuan untuk mengukur kinerja dari kedua model yang telah dilatih, yaitu Model A (CNN Kustom) dan Model B (VGG-16), secara kuantitatif. Evaluasi ini dilakukan pada data uji, yaitu data yang belum pernah dilihat oleh model selama proses pelatihan, untuk mendapatkan penilaian yang objektif terhadap kemampuan generalisasi model. Hasil pengujian kedua model akan menghasilkan nilai akurasi performa klasifikasi genre musik yang dievaluasi menggunakan *confusion matrix*. Hasil *confusion matrix* digunakan untuk menghitung metrik-metrik evaluasi diantaranya akurasi, presisi, *recall*, dan *F1-score* [7]. Metrik-metrik ini diperoleh dari nilai Total True Positive (TTP), Total True Negative (TTN), Total False Positive (TFP) dan Total False Negative (TFN) [6]. Akurasi memberikan informasi seberapa akurat sistem dapat mengklasifikasi data secara benar. Nilai akurasi didapat dari perbandingan data yang terklasifikasi benar dengan jumlah keseluruhan data. Akurasi dirumuskan dengan persamaan (1) berikut.

$$Akurasi = \frac{TTP_{all} + TTN_{all}}{\text{jumlah total pengujian}} \quad (1)$$

Presisi mengukur tingkat ketepatan prediksi positif. Prediksi mempresentasikan perbandingan antara nilai dari jumlah data kategori terklasifikasi benar dengan total keseluruhan data kategori terklasifikasi benar. Presisi dapat dicari menggunakan persamaan (2) berikut.

$$Presisi = \frac{TTP_{all}}{TTP_{all} + TFP_i} \quad (2)$$

Recall merupakan perbandingan jumlah data kategori terklasifikasi benar oleh sistem dengan jumlah data kategori terklasifikasi benar dan salah. *Recall* diperoleh melalui persamaan (3) berikut.

$$Recall = \frac{TTP_{all}}{TTP_{all} + TFN_i} \quad (3)$$

F1-Score merupakan rata-rata harmonik dari Presisi dan Recall, yang memberikan satu angka tunggal untuk menyeimbangkan kedua metrik tersebut. Nilai *F1-Score* diperoleh melalui persamaan (4) berikut.

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

Setelah semua metrik untuk kedua model dihitung, analisis komparatif akan dilakukan. Hasil kinerja dari Model CNN kustom dan Model VGG-16 akan disajikan berdampingan dalam bentuk tabel untuk memudahkan perbandingan. Analisis tidak hanya akan berfokus pada penentuan model mana yang memiliki akurasi lebih tinggi, tetapi juga pada pembahasan mengenai kekuatan dan kelemahan masing-masing model dalam mengenali genre-genre tertentu berdasarkan hasil dari *Confusion Matrix*.

3. Hasil dan Diskusi

Penelitian ini bertujuan untuk membandingkan performa arsitektur *Convolutional Neural Network* (CNN) kustom dengan VGG-16 dalam mengklasifikasikan genre musik berbasis spektrogram pada subset dataset GTZAN. Dataset yang digunakan terdiri dari lima genre musik, yaitu *blues*, *classical*, *hiphop*, *metal*, dan *reggae*, dengan masing-masing genre berisi 100 file audio berdurasi 30 detik. File audio dikonversi ke dalam bentuk gambar spektrogram dan diproses menggunakan dua arsitektur model yang berbeda. Implementasi penelitian ini menggunakan bahasa pemrograman *Python* dalam lingkungan *Google Colaboratory* guna memanfaatkan akselerasi GPU. Pembangunan model *deep learning* dilakukan dengan *library* utama *TensorFlow* dan antarmuka *Keras API*, sementara *library* pendukung seperti *Scikit-learn*, *NumPy*, dan *Matplotlib* digunakan untuk proses preprocessing, evaluasi metrik, dan visualisasi hasil.

3.1 Hasil Pelatihan Model CNN Kustom

Model CNN kustom dirancang dengan arsitektur beberapa lapisan konvolusi, *pooling*, *dropout*, dan *fully connected* yang disesuaikan dengan karakteristik dataset spektrogram. Output model CNN yang dihasilkan ditunjukkan pada Gambar 4.


Model: "sequential"

Layer (type)	Output Shape	Param #
data_augmentation (Sequential)	(None, 224, 224, 3)	0
rescaling (Rescaling)	(None, 224, 224, 3)	0
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
flatten (Flatten)	(None, 86528)	0
dense (Dense)	(None, 256)	22,151,424
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 5)	1,285

Total params: 22,245,957 (84.86 MB)
Trainable params: 22,245,957 (84.86 MB)
Non-trainable params: 0 (0.00 B)

Gambar 3. Definisi Arsitektur Model CNN Kustom

Pelatihan dilakukan selama sejumlah *epoch* yang telah diatur hingga mencapai konvergensi, dengan memantau nilai *loss* dan akurasi pada data latih serta validasi. Gambar kurva *loss* dan akurasi pelatihan kedua model disajikan pada Gambar 5. Kurva hasil pelatihan menunjukkan bahwa model CNN kustom mengalami penurunan *loss* dan peningkatan akurasi secara stabil seiring bertambahnya *epoch*.



Gambar 4. Kurva Loss dan Akurasi Pelatihan Model CNN Kustom


Hasil akhir dari pelatihan menunjukkan bahwa model CNN kustom memiliki akurasi pengujian sebesar 75%, dengan nilai *F1-score* rata-rata (*macro average*) sebesar 0,74. Performa per genre pada CNN kustom cukup stabil, dengan nilai *F1-score* tertinggi pada genre metal sebesar 0,88, diikuti genre classical sebesar 0,84, blues sebesar 0,78, hiphop sebesar 0,73, dan terendah pada genre reggae sebesar 0,48.

--- Laporan Klasifikasi per Genre ---

	precision	recall	f1-score	support
blues	0.75	0.82	0.78	11
classical	0.80	0.89	0.84	9
hiphop	0.60	0.92	0.73	13
metal	0.93	0.82	0.88	17
reggae	0.71	0.36	0.48	14
accuracy			0.75	64
macro avg	0.76	0.76	0.74	64
weighted avg	0.77	0.75	0.74	64

Gambar 5. Laporan Klasifikasi per Genre

Confusion matrix untuk CNN kustom memperlihatkan pola kesalahan klasifikasi, terutama pada genre reggae yang sering tertukar dengan genre blues dan hiphop.



Gambar 6. Confusion Matrix Model CNN Kustom

3.2 Hasil Pelatihan Model VGG-16

Sedangkan model VGG-16 menggunakan arsitektur pralatih dari *ImageNet* dengan *frozen convolutional base* dan *fine-tuning* pada bagian *fully connected layer*. Output model VGG-16 ditunjukkan pada Gambar 8.

Model: "sequential_1"

Layer (type)	Output Shape	Param #
data_augmentation (Sequential)	(None, 224, 224, 3)	0
vgg16 (Functional)	(None, 7, 7, 512)	14,714,688
global_average_pooling2d (GlobalAveragePooling2D)	(None, 512)	0
dense_2 (Dense)	(None, 256)	131,328
dropout_1 (Dropout)	(None, 256)	0
dense_3 (Dense)	(None, 5)	1,285

Total params: 14,847,301 (56.64 MB)
Trainable params: 132,613 (518.02 KB)
Non-trainable params: 14,714,688 (56.13 MB)

Gambar 7. Definisi Arsitektur Model VGG-16

Sementara itu, model VGG-16 menggunakan arsitektur pralatih dari *ImageNet* dengan *frozen convolutional base* dan *fine-tuning* pada bagian *fully connected layer*. Kurva loss dan akurasi VGG-16 memperlihatkan tren yang cenderung fluktuatif dan konvergensi yang tidak sebaik model CNN kustom.



Gambar 8. Kurva Loss dan Akurasi Model VGG-16


Hasil pengujian model VGG-16 menunjukkan akurasi sebesar 68,75% dan nilai *F1-score* rata-rata (*macro average*) sebesar 0,67. Nilai *F1-score* per genre untuk model ini adalah metal sebesar 0,84, hiphop sebesar 0,79, classical sebesar 0,56, reggae sebesar 0,55, dan blues sebesar 0,64.

--- Laporan Klasifikasi per Genre ---

	precision	recall	f1-score	support
blues	0.64	0.64	0.64	11
classical	0.56	0.56	0.56	9
hiphop	0.73	0.85	0.79	13
metal	0.93	0.76	0.84	17
reggae	0.53	0.57	0.55	14
accuracy			0.69	64
macro avg	0.68	0.67	0.67	64
weighted avg	0.70	0.69	0.69	64

Gambar 9. Laporan Klasifikasi per Genre

Confusion matrix menunjukkan genre classical dan reggae adalah dua genre yang paling sering salah diklasifikasikan, dapat dilihat pada Gambar 11.



Gambar 10. *Confusion Matrix* Model VGG-16

3.3 Analisa Perbandingan Model

Analisa komparasi model CNN kustom dan VGG-16 selanjutnya akan ditunjukkan dalam sebuah Tabel 3. Terlihat bahwa model CNN kustom menunjukkan performa yang lebih baik dibandingkan dengan VGG-16 dalam seluruh metrik evaluasi. Akurasi pengujian CNN kustom mencapai 75%, lebih tinggi dibandingkan akurasi VGG-16 sebesar 68,75%. Nilai *macro precision* dan *macro recall* dari CNN kustom masing-masing sebesar 0,76, sementara VGG-16 hanya mencapai 0,68 untuk *macro precision* dan 0,67 untuk *macro recall*. Begitu pula pada nilai *macro F1-score*, CNN kustom unggul dengan 0,74 dibandingkan VGG-16 yang hanya 0,67.

Tabel 3. Ringkasan Komparasi Performa Model CNN Kustom dan VGG-16

Metrik	CNN Kustom	VGG-16
Akurasi Uji (%)	75.00	68.75
<i>Macro Precision</i>	0.76	0.68
<i>Macro Recall</i>	0.76	0.67
<i>Macro F1-Score</i>	0.74	0.67
<i>Weighted Precision</i>	0.77	0.70
<i>Weighted Recall</i>	0.75	0.69
<i>Weighted F1-Score</i>	0.74	0.69

Dari tabel tersebut terlihat bahwa CNN kustom unggul dalam seluruh metrik evaluasi dibandingkan VGG-16. Hal ini menegaskan bahwa arsitektur CNN kustom yang dilatih penuh dari awal lebih mampu beradaptasi dengan pola spektrogram musik, sedangkan model VGG-16 dengan pembekuan convolutional base hanya optimal di genre tertentu seperti metal, tetapi tidak memadai untuk genre lain.

4. Kesimpulan

Penelitian ini telah membandingkan performa arsitektur CNN kustom dan VGG-16 pada klasifikasi genre musik berbasis spektrogram dengan subset dataset GTZAN yang terdiri dari lima

genre. Hasil menunjukkan bahwa CNN kustom menghasilkan akurasi pengujian sebesar 75% dan *macro F1-score* sebesar 0,74, lebih tinggi dibandingkan VGG-16 yang memperoleh akurasi 68,75% dan *macro F1-score* 0,67. Temuan ini menegaskan bahwa arsitektur CNN kustom yang dilatih dari awal lebih adaptif terhadap pola data spektrogram musik dibandingkan arsitektur pralatih VGG-16 yang hanya dilakukan *fine-tuning* pada bagian *fully connected*. Kontribusi utama dari penelitian ini adalah memberikan analisis komparatif sistematis antara CNN kustom dan VGG-16 pada domain klasifikasi genre musik berbasis spektrogram. Selain itu, penelitian ini memetakan kelemahan model dalam mengklasifikasikan genre tertentu, terutama *reggae*, sehingga dapat menjadi acuan dalam pengembangan sistem klasifikasi musik di masa mendatang. Sebagai arah penelitian selanjutnya, disarankan untuk mengeksplorasi *fine-tuning* penuh pada layer konvolusi model pralatih seperti VGG-16 atau ResNet, mengombinasikan spektrogram dengan fitur temporal atau harmonik, serta memperkaya dataset yang lebih bervariasi. Penerapan arsitektur hybrid seperti CNN-RNN dan teknik augmentasi berbasis audio transformasi juga menjadi potensi untuk meningkatkan akurasi pada genre yang sulit diklasifikasikan.

Daftar Pustaka

- [1] Gst. A. V. M. Giri, M. L. Radhitya, M. A. Raharja, and I. W. Supriana, "Sistem Rekomendasi Musik Berdasarkan Data Konteks Pada Listening History Musik dan Keterkaitan Artis Indonesia," *Jurnal Resistor*, vol. 5, no. 1, pp. 86–93, Apr. 2022, doi: <https://doi.org/10.31598>.
- [2] I.G.A.N.D.Wiraguna and L. A. A. R. Putri, "Klasifikasi Genre Musik Menggunakan Support Vector Machine Berdasarkan Spectral Features," *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 1, no. 3, pp. 933–940, Mar. 2023.
- [3] C. R. Wairata, E. R. Swedia, and M. Cahyanti, "Pengklasifikasian Genre Musik Indonesia Menggunakan Convolutional Neural Network," *Sebatik*, vol. 25, no. 1, pp. 255–261, Jun. 2021, doi: 10.46984/sebatik.v25i1.1286.
- [4] I. N. Purnama, "Music Genre Recommendations Based on Spectrogram Analysis Using Convolutional Neural Network Algorithm with RESNET-50 and VGG-16 Architecture," *JISA (Jurnal Informatika dan Sains)*, vol. 5, no. 1, pp. 69–74, Jun. 2022.
- [5] M. S. Ubaidillah, R. D. Indrarto, D. Rolliawati, and A. Yusuf, "Classification of Fresh and Rotten Fruits and Vegetables Using a Customized Convolutional Neural Network," *MIND Journal*, vol. 10, no. 1, pp. 34–47, Jun. 2025, doi: 10.26760/mindjournal.v10i1.34-47.
- [6] R. AGUSTINA, R. MAGDALENA, and N. K. C. PRATIWI, "Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 2, p. 446, Apr. 2022, doi: 10.26760/elkomika.v10i2.446.
- [7] Y. V. Via, I. Y. Purbasari, and A. P. Pratama, "Analisa Algoritma Convolution Neural Network (Cnn) Pada Klasifikasi Genre Musik Berdasar Durasi Waktu," *SCAN*, vol. 1, no. 1, pp. 35–41, Feb. 2022.

Halaman ini sengaja dibiarkan kosong