

Optimalisasi Model CNN Untuk Klasifikasi Citra Cifar-10 Dengan Variasi Rasio Data Latih Dan Uji

Muhammad Syawaluddin¹, Susandri Susandri², Ahmad Zamsuri³

^{1,2,3}Program Studi Magister Ilmu Komputer, Fakultas Ilmu Komputer Universitas Lancang Kuning

^{1,2,3}Jl. Yos Sudarso KM. 8 Rumbai, Pekanbaru, Riau, telp. 0811 753 2015

e-mail: ¹m.syawaluddin46@gmail.com, ²susandri@unilak.ac.id, ³ahmadzamsuri@unilak.ac.id

Abstrak

Klasifikasi citra adalah area penelitian yang penting dalam bidang Computer Vision. Seiring dengan kemajuan teknologi dan ketersediaan data, deep learning, khususnya model Convolutional Neural Network (CNN), telah menunjukkan kinerja yang luar biasa dalam tugas ini. Namun, performa model CNN sangat bergantung pada cara data dibagi menjadi himpunan data latih dan data uji. Penelitian ini menganalisis dan membandingkan kinerja model CNN dalam klasifikasi citra pada dataset CIFAR-10 menggunakan dua variasi rasio pembagian data: 80:20 dan 60:40. Hasil dari kedua skenario ini dievaluasi menggunakan metrik akurasi, classification report, dan confusion matrix. Model CNN yang digunakan memiliki arsitektur sekuensial dengan tiga lapisan konvolusi, diikuti oleh lapisan dense. Hasil penelitian menunjukkan bahwa rasio pembagian data 60:40 menghasilkan akurasi keseluruhan yang sama dengan rasio 80:20, yaitu 74%. Meskipun jumlah data latih pada skenario 60:40 lebih sedikit (30.000 gambar), model tetap mampu mempelajari fitur-fitur penting dari dataset, didukung oleh teknik augmentasi data yang diterapkan. Temuan ini memberikan wawasan bahwa menggunakan data latih yang lebih sedikit tidak selalu mengorbankan akurasi, yang dapat bermanfaat untuk menghemat sumber daya komputasi dan waktu pelatihan.

Kata Kunci: Optimalisasi CNN, Klasifikasi Citra, CIFAR-10, Rasio Data, Augmentasi Data.

Abstract

Image classification is a crucial research area in the field of Computer Vision. With advancements in technology and data availability, deep learning models, specifically Convolutional Neural Networks (CNNs), have demonstrated outstanding performance in this task. However, a CNN model's performance is highly dependent on how the data is split into training and testing datasets. This study analyzes and compares the performance of a CNN model for image classification on the CIFAR-10 dataset using two different data split ratios: 80:20 and 60:40. The results from both scenarios were evaluated using accuracy metrics, a classification report, and a confusion matrix. The research findings indicate that the 60:40 data split ratio yields the same overall accuracy as the 80:20 ratio, both at 74%. Although the amount of training data in the 60:40 scenario is smaller (30,000 images), the model was still able to learn important features from the dataset, a result supported by the applied data augmentation techniques. This finding suggests that using less training data does not always sacrifice accuracy, which can be beneficial for saving computational resources and training time.

Keywords: Optimization of CNN, Image Classification, CIFAR-10, Data Ratio, Data Augmentation.

1. PENDAHULUAN

Klasifikasi citra merupakan salah satu tantangan fundamental dan area penelitian yang dinamis dalam bidang Computer Vision. Seiring dengan perkembangan teknologi dan ketersediaan data, pendekatan berbasis deep learning telah menunjukkan performa yang signifikan dibandingkan dengan metode konvensional dalam berbagai tugas, termasuk pengenalan objek dan klasifikasi gambar [1]. Salah satu arsitektur utama dalam deep learning yang sangat efektif untuk tugas ini adalah Convolutional Neural Network (CNN), yang dirancang secara khusus untuk mengekstrak fitur hierarkis dari data citra secara otomatis [2].

Meskipun CNN memiliki kemampuan yang luar biasa, performanya sangat bergantung pada berbagai faktor, salah satunya adalah cara data dibagi menjadi himpunan data latih (*training*) dan data uji (*testing*). Rasio pembagian data ini memegang peranan krusial dalam memastikan bahwa model dapat dilatih dengan baik (menggeneralisasi pola) sekaligus dievaluasi secara objektif [3]. Pembagian data yang tidak tepat dapat menyebabkan masalah *overfitting* atau *underfitting*, yang pada akhirnya menurunkan akurasi model saat dihadapkan pada data baru.

Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja model CNN dalam klasifikasi citra pada dataset CIFAR-10 dengan menerapkan dua variasi rasio pembagian data latih dan uji, yaitu 80:20 dan 60:40. Hasil perbandingan ini diharapkan dapat memberikan wawasan mengenai dampak langsung dari rasio data terhadap performa model, yang dievaluasi tidak hanya dari metrik akurasi, tetapi juga melalui *classification report* dan *confusion matrix* [4]. Penelitian ini merupakan langkah untuk memahami strategi optimalisasi model CNN dalam konteks sumber daya data yang bervariasi.

Berbagai penelitian sebelumnya telah menunjukkan bahwa performa model *deep learning* dapat ditingkatkan melalui berbagai cara, seperti penggunaan arsitektur yang lebih dalam, optimasi parameter, atau teknik regularisasi. Pant membandingkan beberapa arsitektur CNN yang berbeda untuk klasifikasi citra CIFAR-10 dan menemukan bahwa variasi dalam lapisan konvolusi dan *dense* secara signifikan memengaruhi akurasi validasi [5]. Selain itu, aziz (2025) menekankan pentingnya evaluasi model secara komprehensif menggunakan *confusion matrix* untuk memahami kinerja prediksi pada setiap kelasnya[4]. Namun, studi yang secara eksplisit fokus pada dampak sistematis dari variasi rasio data latih dan uji pada kinerja model CNN, khususnya pada dataset CIFAR-10, masih relatif terbatas dan membutuhkan eksplorasi lebih lanjut [4].

Keterbatasan data latih merupakan masalah umum dalam pengembangan model *deep learning* dan dapat berdampak langsung pada kemampuan model untuk menggeneralisasi [6]. Dengan membandingkan rasio 80:20 dan 60:40, penelitian ini secara langsung menguji hipotesis bahwa jumlah data latih yang lebih sedikit (dalam kasus 60:40) akan menghasilkan performa yang berbeda dibandingkan dengan jumlah data yang lebih banyak. Perbedaan rasio ini akan dievaluasi dari segi akurasi, *loss*, serta metrik *precision*, *recall*, dan *f1-score*. Pemahaman ini penting bagi para peneliti dan praktisi untuk membuat keputusan yang tepat dalam tahap pra-pemrosesan data, terutama ketika dataset yang tersedia ukurannya terbatas.

Oleh karena itu, penelitian ini akan menyajikan temuan dari tiga eksperimen yang telah dilakukan pada dataset CIFAR-10 dengan menggunakan model CNN, yang meliputi dua rasio data berbeda dan satu eksperimen tambahan yang menunjukkan penggunaan augmentasi data. penulis akan menganalisis secara detail hasil dari *classification report* dan *confusion matrix* untuk setiap skenario, memberikan bukti empiris tentang bagaimana variasi rasio data latih dan uji memengaruhi performa model secara keseluruhan dan per-kelas. Hasil dari penelitian ini diharapkan dapat menjadi panduan praktis bagi pengembangan model *deep learning* untuk tugas klasifikasi citra di masa depan.

2. METODE PENELITIAN

Metode penelitian ini berfokus pada pendekatan eksperimental untuk menganalisis kinerja model **Convolutional Neural Network (CNN)** dalam klasifikasi citra. Eksperimen ini dirancang untuk membandingkan pengaruh rasio pembagian data latih dan data uji terhadap performa model menggunakan dataset standar, yaitu **CIFAR-10**.

2.1. Dataset dan Pra-pemrosesan Data

Penelitian ini menggunakan dataset CIFAR-10, sebuah koleksi umum dalam komunitas riset computer vision yang terdiri dari 60.000 gambar berwarna berukuran 32x32 piksel, dibagi ke dalam 10 kelas berbeda [7]. Sebelum model dilatih, data akan melewati dua tahapan pra-pemrosesan utama:

1. Normalisasi: Nilai piksel dari setiap gambar, yang aslinya berada dalam rentang 0-255, dinormalisasi ke dalam rentang 0-1. Normalisasi ini dilakukan dengan membagi setiap nilai piksel dengan 255.0. Proses ini penting untuk mempercepat konvergensi model dan meningkatkan stabilitas pelatihan.
2. Augmentasi Data: Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*, augmentasi data diterapkan secara *real-time* pada data latih [2]. Teknik yang digunakan meliputi rotasi gambar (hingga 15 derajat), pergeseran gambar secara horizontal dan vertikal (hingga 10% dari lebar/tinggi gambar), dan pembalikan horizontal gambar (*horizontal flip*).

2.2. Arsitektur Model CNN

Model CNN yang dikembangkan untuk penelitian ini merupakan arsitektur sekuensial yang terdiri dari beberapa lapisan konvolusi dan pooling untuk ekstraksi fitur, serta lapisan dense untuk klasifikasi. Model Convolutional Neural Network (CNN) adalah pengembangan dari Multi-layer Perceptron (MLP) yang lebih efisien karena dapat bekerja dengan parameter yang lebih sedikit. Berbeda dengan model lain, CNN tidak membutuhkan tahap pra-pemrosesan seperti segmentasi dan ekstraksi fitur secara manual. Selain itu, model ini dirancang untuk mengurangi parameter bebas dan dapat menangani variasi gambar masukan seperti translasi (pergeseran), rotasi, dan skala (perubahan ukuran) [8]. Arsitektur model secara rinci adalah sebagai berikut:

- a. Tiga lapisan konvolusi (Conv2D) berturut-turut dengan filter 32, 64, dan 128, masing-masing diikuti oleh lapisan aktivasi ReLU dan lapisan MaxPooling2D untuk mengurangi dimensi spasial.
- b. Lapisan Flatten untuk mengubah *output* dari lapisan konvolusi menjadi vektor satu dimensi.
- c. Dua lapisan *dense* (Dense) atau lapisan terhubung penuh. Lapisan pertama memiliki 128 neuron, sementara lapisan terakhir memiliki 10 neuron, sesuai dengan jumlah kelas pada dataset CIFAR-10.
- d. Lapisan *output* menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi untuk setiap kelas.

Model ini dilatih selama 30 *epoch* dengan ukuran *batch* 32, menggunakan pengoptimal Adam dan fungsi *loss* SparseCategoricalCrossentropy [9].

2.3. Skenario Eksperimen

Penelitian ini membandingkan kinerja model CNN di bawah dua skenario utama yang berbeda dalam pembagian data latih dan data uji [10]:

1. Skenario Rasio 80:20: Dataset CIFAR-10 dibagi menjadi 80% data latih dan 20% data uji. Dalam kasus ini, model dilatih dengan 40.000 gambar dan dievaluasi pada 10.000 gambar.
 2. Skenario Rasio 60:40: Dataset dibagi menjadi 60% data latih dan 40% data uji. Model dilatih dengan 30.000 gambar dan diuji pada 20.000 gambar.
-

Kinerja model dievaluasi berdasarkan metrik-metrik standar seperti akurasi, nilai *loss*, dan laporan klasifikasi (*classification report*) yang mencakup *precision*, *recall*, dan *f1-score*. Analisis lebih lanjut juga dilakukan dengan menggunakan matriks kebingungan (*confusion matrix*) untuk memahami performa prediksi model pada setiap kelas secara spesifik.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari dua skenario eksperimen yang telah dilakukan, yaitu pembagian data dengan rasio 80:20 dan 60:40. Analisis performa model mencakup akurasi dan *loss* selama proses pelatihan dan validasi, serta evaluasi mendalam menggunakan *classification report* dan *confusion matrix*.

3.1 Skenario Rasio 80:20


Pada skenario ini, model dilatih dengan 40.000 gambar dan diuji pada 10.000 gambar.

```
Downloading data from https://www.cs.toronto.edu/~kriz/cifar-10-python.tar.gz
170498071/170498071 3s 0us/step
Jumlah data latih: 40000
Jumlah data uji: 10000
```

Gambar 1. Gambar Pembagian Data Latih Dan Data Uji 80:20

Proses pelatihan selama 30 epoch menunjukkan bahwa model mampu mempelajari pola data dengan efektif, yang ditunjukkan oleh peningkatan akurasi dan penurunan *loss* secara konsisten pada data latih dan validasi.

Grafik Akurasi dan Loss Grafik di bawah menunjukkan kurva akurasi dan *loss* dari proses pelatihan. Terlihat bahwa akurasi validasi mencapai titik tertinggi pada akhir epoch dan tidak menunjukkan tanda-tanda *overfitting* yang signifikan.




Gambar 2. Gambar Grafik Akurasi Dan Loss Rasio 80:20

	precision	recall	f1-score	support
pesawat	0.72	0.81	0.76	973
mobil	0.79	0.94	0.86	979
burung	0.78	0.55	0.65	1030
kucing	0.66	0.49	0.56	1023
rusa	0.78	0.63	0.70	933
anjing	0.76	0.54	0.63	1015
katak	0.62	0.91	0.74	996
kuda	0.67	0.86	0.75	994
kapal	0.83	0.85	0.84	1017
truk	0.84	0.80	0.82	1040
accuracy			0.74	10000
macro avg	0.74	0.74	0.73	10000
weighted avg	0.75	0.74	0.73	10000

Gambar 3. Gambar Classification Report Skenario 80:20

Berdasarkan *classification report*, model pada skenario 80:20 mencapai akurasi keseluruhan sebesar 74%. Kinerja model cukup baik, dengan akurasi tertinggi untuk kelas mobil (*recall* 0.94) dan kapal (*precision* 0.83, *recall* 0.85). Namun, model menunjukkan performa yang kurang optimal dalam mengklasifikasikan kelas kucing dan anjing, yang memiliki nilai *recall* dan *f1-score* yang lebih rendah.



Gambar 4. Gambar Confusion Matrix Classification Report Skenario 80:20


Matriks kebingungan (Confusion Matrix) memberikan gambaran detail tentang kesalahan prediksi. Dari matriks tersebut, terlihat bahwa sebagian besar kesalahan prediksi terjadi pada kelas-kelas yang memiliki kemiripan visual, seperti burung yang sering salah diklasifikasikan sebagai pesawat, dan kucing yang sering salah diklasifikasikan sebagai anjing.

3.2 Skenario Rasio 60:40

Dalam skenario ini, model dilatih dengan 30.000 gambar dan diuji pada 20.000 gambar. Meskipun jumlah data latih lebih sedikit, model tetap menunjukkan performa yang stabil.

```
Downloading data from https://www.cs.toronto.edu/~kriz/cifar-10-python.tar.gz
170498071/170498071 ————— 4s 0us/step
Jumlah data latih: 30000
Jumlah data uji: 20000
```

Gambar 5. Gambar Pembagian Data Latih Dan Data Uji 60:40



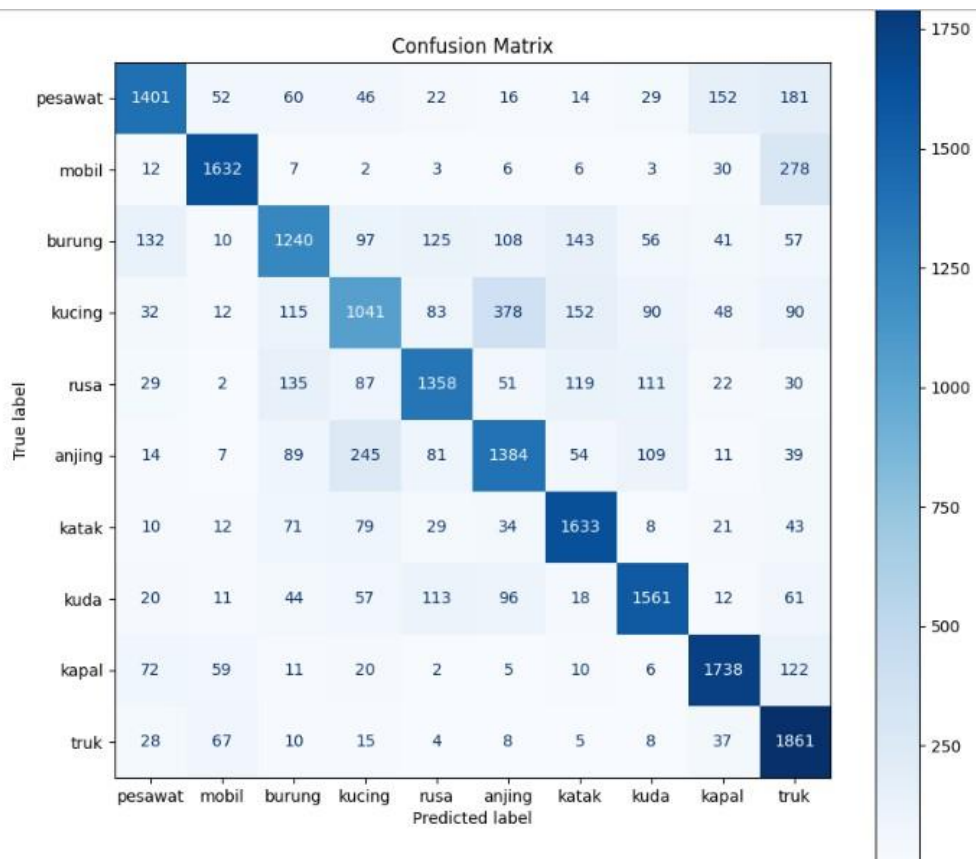
Gambar 6. Gambar Grafik Akurasi Dan Loss Rasio 60:40

Grafik menunjukkan bahwa kurva akurasi pada skenario ini juga meningkat seiring dengan bertambahnya epoch, tetapi dengan fluktuasi yang sedikit lebih besar dibandingkan skenario 80:20.

	precision	recall	f1-score	support
pesawat	0.80	0.71	0.75	1973
mobil	0.88	0.82	0.85	1979
burung	0.70	0.62	0.65	2009
kucing	0.62	0.51	0.56	2041
rusa	0.75	0.70	0.72	1944
anjing	0.66	0.68	0.67	2033
katak	0.76	0.84	0.80	1940
kuda	0.79	0.78	0.79	1993
kapal	0.82	0.85	0.84	2045
truk	0.67	0.91	0.77	2043
accuracy			0.74	20000
macro avg	0.74	0.74	0.74	20000
weighted avg	0.74	0.74	0.74	20000

Gambar 7. Gambar Classification Report Skenario 60:40

Pada skenario 60:40, model mencapai akurasi keseluruhan sebesar 74%, sama dengan skenario 80:20. Kelas mobil, katak, dan kapal tetap menjadi kelas dengan performa terbaik. Kelas kucing masih menjadi tantangan utama, meskipun nilai *recall* untuk kelas anjing sedikit lebih baik dibandingkan skenario sebelumnya.



Gambar 8. Gambar Confusion Matrix Classification Report Skenario 60:40

Analisis matriks kebingungan menunjukkan pola kesalahan prediksi yang serupa. Meskipun jumlah data uji lebih besar, pola misklasifikasi pada kelas-kelas yang mirip, seperti burung yang sering salah diklasifikasikan sebagai pesawat dan rusa, tetap konsisten.

3.3 Perbandingan Hasil dan Pembahasan

Hasil dari kedua skenario menunjukkan temuan yang menarik. Meskipun rasio pembagian data latih dan uji berbeda secara signifikan (80:20 vs. 60:40), akurasi keseluruhan yang dicapai oleh model adalah identik, yaitu **74%**.

- a. Dampak Ukuran Data Latih, Meskipun jumlah data latih pada skenario 60:40 lebih sedikit (30.000 vs. 40.000), performa model tidak mengalami penurunan. Hal ini dapat diinterpretasikan bahwa dengan arsitektur CNN yang digunakan dan penerapan augmentasi data, model sudah mampu mempelajari fitur-fitur penting dari dataset CIFAR-10 meskipun dengan jumlah data latih yang lebih sedikit. Kuantitas data latih sebesar 30.000 gambar tampaknya sudah cukup untuk mencapai performa optimal model.
- b. Dampak Ukuran Data Uji, Pada skenario 60:40, jumlah data uji dua kali lebih besar (20.000 vs. 10.000). Akurasi yang konsisten pada kedua skenario menunjukkan bahwa akurasi model cukup stabil dan valid. Hal ini menegaskan bahwa hasil yang diperoleh tidak bergantung pada ukuran data uji, melainkan pada kemampuan generalisasi model itu sendiri.
- c. Performa Per-kelas, Analisis *f1-score* menunjukkan bahwa ada beberapa perbedaan minor dalam performa per-kelas. Kelas truk dan pesawat memiliki *precision* yang lebih tinggi pada skenario 60:40, sedangkan kelas mobil dan kapal memiliki *f1-score* yang sedikit lebih rendah. Hal ini menunjukkan bahwa perubahan rasio data dapat memengaruhi seberapa baik model mengidentifikasi pola untuk kelas-kelas tertentu. Namun, secara umum, kelas yang sulit dikenali seperti kucing dan burung tetap menjadi tantangan pada kedua skenario.

4. KESIMPULAN

Kesimpulannya, hasil penelitian ini menunjukkan bahwa untuk dataset CIFAR-10 dengan arsitektur CNN yang dirancang, rasio pembagian data 60:40 menghasilkan performa yang sebanding dengan rasio 80:20. Temuan ini memberikan wawasan bahwa peneliti dapat menggunakan rasio data yang lebih kecil untuk pelatihan tanpa mengorbankan akurasi, yang sangat bermanfaat dalam situasi di mana sumber daya komputasi atau waktu pelatihan terbatas.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada bapak Dr. Susandri, M.Kom dan bapak Assoc. Prof. Dr. Ahmad Zamsuri, M.Kom., MTA., MCF atas bimbingan, arahan, dan saran konstruktif selama penelitian ini.

Penulis juga berterima kasih kepada seluruh dosen pengajar di Program Studi Magister Ilmu Komputer serta rekan-rekan mahasiswa pascasarjana yang telah memberikan dukungan dan motivasi.

DAFTAR PUSTAKA

- [1] A. Peryanto, A. Yudhana, and R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Format J. Ilm. Tek. Inform.*, vol. 8, no. 2, p. 138, 2020, doi: 10.22441/format.2019.v8.i2.007.
- [2] L. S. Harahap and M. F. H. Kembaren, "Klasifikasi Objek Menggunakan Convolutional Neural Network pada Citra Satelit," *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 2, pp. 4663–4667, 2025, doi: 10.31004/riggs.v4i2.1306.
- [3] A. M. Tama and R. C. N. Santi, "Klasifikasi Jenis Tanaman Hias Menggunakan Metode Convolutional Neural Network (CNN)," *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, pp. 764–770, 2023, doi: 10.31539/intecom.v6i2.7002.
- [4] A. Nurhidayat, W. Ahmad Arrosyid, and R. Samsinar, "Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network," *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 17, no. 1, p. 48, 2023, doi: 10.30872/jim.v17i1.5246.
- [5] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [6] Anggay Luri Pramana, "Analisis Perbandingan Evaluasi Metode Deep Learning pada Klasifikasi Jenis Kendaraan," *J. Comput. Sci. Vis. Commun. Des.*, vol. 9, no. 1, pp. 451–465, 2024, doi: 10.55732/jikdiskomvis.v9i1.1252.
- [7] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 2, p. 466, 2023, doi: 10.26760/elkomika.v11i2.466.
- [8] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021, doi: 10.30591/jpit.v6i2.2802.
- [9] Y. Pant, G. Shah, R. Ojha, R. Thapa, and B. Bhatta, "Comparison of CNN Architecture of Image Classification Using CIFAR10 Datasets," *Int. J. Eng. Technol.*, vol. 1, no. 1, pp. 37–52, 2023, doi: 10.3126/injet.v1i1.60898.
- [10] T. Turahman, E. Hasmin, and K. Aryasa, "Analisis Perbandingan Metode Convolutional Neural Network," *(Jurnal Teknol. Inf. dan Komunikasi)*, vol. 9, no. March, pp. 368–377, 2025.



Prosiding- SEMASTER: Seminar Nasional Teknologi Informasi & Ilmu Komputer is licensed under a [Creative Commons Attribution International \(CC BY-SA 4.0\)](https://creativecommons.org/licenses/by-sa/4.0/)