

# Analisis Pengaruh *Dropout Layer* pada *Convolutional Neural Networks* untuk Klasifikasi Gambar *Sticky notes*

Arsya Yan Duribta<sup>a1</sup>, Ninuk Wiliani<sup>a2</sup>

<sup>a</sup>Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pancasila  
Jagakarsa, Kota Jakarta Selatan, Jakarta, Indonesia

<sup>1</sup>4522210117@univpancasila.ac.id

<sup>2</sup>ninuk.wiliani@univpancasila.ac.id

## Abstract

*Sticky notes are often used as a tool for recording and organising information. Document digitisation requires an accurate image classification system for sticky notes, but the main challenge in this task is the variety of colours, shapes and handwriting on sticky notes, which can affect the performance of the classification model. This research aims to analyse the effect of using a dropout layer on the Convolutional Neural Networks (CNN) in the sticky note image classification task. Three CNN models with different dropout layers configurations (no dropout, 10% dropout and 20% dropout) were tested on a prepared dataset. Evaluation was performed by measuring loss and accuracy values on the test data, as well as using the classification report and the confusion matrix. The results showed that all three models achieved 100% test accuracy, but there were significant differences in the loss values. The model with no dropouts showed signs of overfitting with a very low test loss (0.00011). The 10% dropout model had the best balance between accuracy and model generalisation, with a more stable loss pattern (0.00117). Meanwhile, 20% dropout causes a degradation in complex pattern learning performance with the largest test loss (0.08739). Therefore, using a 10% loss is the optimal strategy for improving CNN generalisation in post-it note image classification.*

*Translated with DeepL.com (free version)*

**Keywords:** *dropout layer, CNN, overfitting, image classification*

## 1. Pendahuluan

Dalam dunia kerja dan pendidikan, *sticky notes* sering digunakan sebagai alat bantu pencatatan dan pengorganisasian informasi. Seiring dengan meningkatnya kebutuhan digitalisasi dokumen, klasifikasi gambar *sticky notes* menjadi penting dalam pengelolaan dokumen otomatis dan sistem pencatatan berbasis komputer. Namun, proses klasifikasi gambar *sticky notes* menghadapi berbagai tantangan. Variasi warna, bentuk, dan tulisan tangan yang terdapat pada *sticky notes* membuat klasifikasi menjadi lebih kompleks dibandingkan dengan objek yang lebih seragam. Selain itu, pencahayaan dan sudut pengambilan gambar yang berbeda juga dapat mempengaruhi hasil klasifikasi.

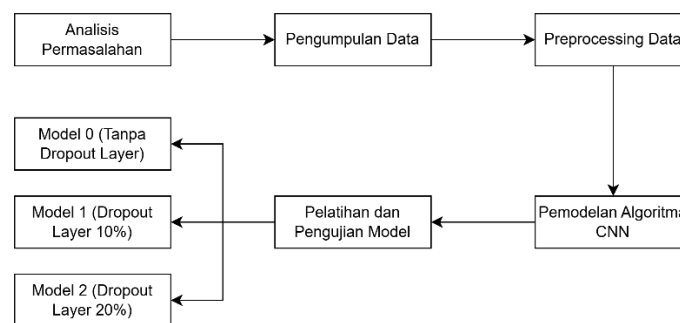
Untuk menyelesaikan tugas klasifikasi gambar, pendekatan berbasis deep learning seperti *Convolutional Neural Networks* (CNN) banyak digunakan. CNN memiliki kemampuan untuk mengekstrak fitur secara otomatis dari data gambar melalui lapisan konvolusi yang terstruktur dengan baik [1]. Pendekatan ini telah diterapkan dalam berbagai bidang, seperti pengenalan wajah [2], deteksi objek [3], dan pengklasifikasian citra medis [4]. Namun, dalam pelatihan CNN, salah satu tantangan utama yang dihadapi adalah *overfitting* [5]. *Overfitting* terjadi ketika model terlalu menyesuaikan diri dengan data pelatihan, sehingga performanya menurun saat diuji dengan data baru [5]. Hal ini menjadi kendala dalam berbagai aplikasi praktis, terutama ketika dataset yang digunakan memiliki jumlah data yang terbatas atau distribusinya tidak seimbang. Dalam konteks klasifikasi gambar *sticky notes*, tantangan ini semakin kompleks karena keterbatasan dataset yang tersedia. Oleh karena itu, diperlukan strategi khusus untuk meningkatkan generalisasi model agar dapat bekerja dengan baik pada data baru.

Salah satu teknik yang digunakan untuk mengatasi *overfitting* adalah *dropout* [6]. *Dropout* merupakan metode regulasi yang bekerja dengan cara menonaktifkan unit neuron secara acak selama proses pelatihan untuk mencegah ketergantungan berlebihan terhadap fitur tertentu [7]. Beberapa penelitian menunjukkan bahwa penggunaan *dropout* dapat meningkatkan akurasi dan generalisasi model CNN [8]. Namun, dampaknya terhadap kinerja CNN masih bervariasi tergantung pada konfigurasi yang digunakan dan jenis data yang diproses [9], [10].

Hingga saat ini, belum banyak penelitian yang secara spesifik mengeksplorasi pengaruh konfigurasi *dropout* dalam CNN untuk tugas klasifikasi gambar *sticky notes*. Oleh karena itu, penelitian ini bertujuan untuk menganalisis sejauh mana *dropout* dapat mempengaruhi kinerja CNN dalam klasifikasi gambar *sticky notes*. Dengan memahami pengaruh konfigurasi *dropout* layer yang berbeda, penelitian ini diharapkan dapat memberikan wawasan mengenai strategi terbaik dalam penggunaan *dropout* untuk meningkatkan akurasi dan generalisasi model dalam tugas klasifikasi gambar yang memiliki variasi tinggi seperti *sticky notes*.

## 2. Metodologi Penelitian

Penelitian ini dilakukan dalam beberapa tahapan yang disusun secara sistematis untuk mencapai tujuan penelitian, seperti yang diilustrasikan pada Gambar 1. Tahapan-tahapan tersebut meliputi:



**Gambar 1.** Alur Metodologi Penelitian

### 2.1. Analisis Permasalahan

Langkah awal dalam penelitian ini adalah menganalisis permasalahan yang menjadi fokus utama, yaitu bagaimana pengaruh konfigurasi *dropout* layer pada *Convolutional Neural Networks* (CNN) dalam tugas klasifikasi gambar. Masalah ini dipilih karena *dropout* berfungsi sebagai teknik regularisasi yang dapat meningkatkan kemampuan generalisasi model, namun pengaruhnya dapat berbeda pada dataset tertentu atau konfigurasi yang berbeda. Penelitian ini difokuskan pada klasifikasi gambar sederhana dengan menggunakan dataset yang berisi foto *sticky notes* berwarna kuning dan pink. Hasil dari analisis ini menjadi dasar untuk merancang metode dan eksperimen yang akan dilakukan.

### 2.2. Pengumpulan dan Preprocessing Data

Dataset yang digunakan dalam penelitian ini adalah dataset yang dibuat sendiri, terdiri dari 100 gambar *sticky notes*. Gambar-gambar tersebut terdiri dari 50 gambar *sticky notes* berwarna kuning dan 50 gambar berwarna pink. Dataset ini dikumpulkan dengan memastikan bahwa gambar memiliki resolusi dan pencahayaan yang konsisten untuk meminimalkan gangguan pada proses pelatihan model.

Langkah-langkah preprocessing data meliputi:

- a. Data dan Label  
Gambar yang dikumpulkan dimasukkan ke dalam sebuah *list*, dan label yang sesuai ditentukan berdasarkan warna gambar. Label diinisialisasi sebagai kuning dan pink.
- b. Penggantian Nama Label  
Untuk memastikan bahwa label lebih mudah dikenali oleh model, label diganti menggunakan pendekatan numerik (kuning = 0 dan pink = 1).
- c. Pembagian Dataset  
Dataset dibagi menjadi dua bagian utama, yaitu data pelatihan dan data pengujian, dengan perbandingan 80:20. Pembagian ini bertujuan untuk memastikan bahwa model dapat dievaluasi secara akurat menggunakan data yang belum pernah dilihat sebelumnya.

d. One-Hot Encoding pada Label

Label kategorikal diubah menjadi format one-hot encoding. Format ini diperlukan agar model dapat memahami label sebagai vektor biner, misalnya [1, 0] untuk kuning dan [0, 1] untuk pink.

Preprocessing ini dirancang untuk meningkatkan kualitas data dan memastikan bahwa data siap digunakan dalam proses pelatihan model.

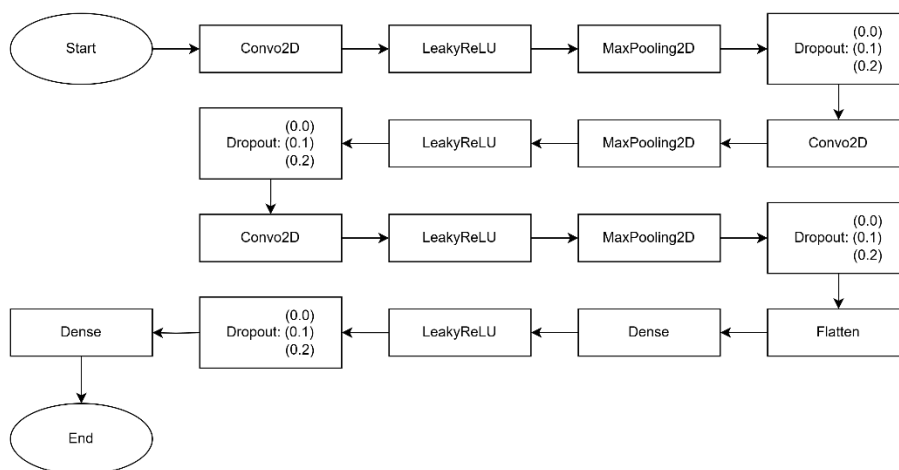
### 2.3. Perancangan Arsitektur CNN

Dataset yang digunakan dalam penelitian ini adalah dataset yang dibuat sendiri, terdiri dari 100 gambar *sticky notes*. Pada tahap ini, model *Convolutional Neural Networks* (CNN) dirancang menggunakan bahasa pemrograman Python dengan bantuan pustaka Keras. Arsitektur CNN dirancang untuk menangani tugas klasifikasi dua kelas, yaitu *sticky notes* berwarna kuning dan pink. Model CNN dirancang dengan parameter sebagai berikut:

**Tabel 1.** Parameter Pemodelan CNN

Parameter	Nilai
Batch size	64
Epochs	30
Jumlah Kelas	2

Ilustrasi flowchart model CNN yang digunakan:



**Gambar 2.** Flowchart model CNN

Model dimulai dengan lapisan konvolusi pertama yang terdiri dari 32 filter dengan ukuran kernel 3x3 dan fungsi aktivasi linear. Lapisan ini dilengkapi dengan *LeakyReLU* ( $\alpha=0.1$ ) untuk menangani masalah vanishing gradient. Kemudian, dilanjutkan dengan lapisan *MaxPooling2D* untuk mengurangi dimensi data.

Model memiliki tiga lapisan konvolusi berturut-turut dengan jumlah filter yang meningkat (32, 64, dan 128) dan diikuti oleh *MaxPooling2D* pada setiap lapisan. Setelah proses ekstraksi fitur selesai, data diratakan (*Flatten*) dan diteruskan ke lapisan *Dense* dengan 128 unit neuron serta fungsi aktivasi linear. Lapisan terakhir adalah lapisan keluaran (*output layer*) dengan jumlah neuron yang sesuai dengan jumlah kelas (2 kelas) menggunakan fungsi aktivasi *softmax*.

### 2.4. Pelatihan dan Pengujian Model

Tahap pelatihan dan pengujian model dilakukan untuk mengevaluasi kinerja arsitektur *Convolutional Neural Network* (CNN) pada tiga konfigurasi berbeda. Setiap konfigurasi dirancang untuk menganalisis pengaruh penggunaan *dropout* layer terhadap performa model, baik dalam hal akurasi maupun kemampuan generalisasi. Adapun ketiga konfigurasi tersebut adalah sebagai berikut:

a. Tanpa *Dropout* Layer

Pada konfigurasi pertama, pelatihan dilakukan tanpa menyertakan lapisan *dropout* dalam arsitektur CNN. Konfigurasi ini bertujuan untuk menjadi dasar pembandingan dalam menilai dampak penambahan *dropout* layer.

b. *Dropout* Layer 10%

Pada konfigurasi kedua, lapisan *dropout* dengan tingkat penonaktifan neuron sebesar 10% diterapkan setelah setiap lapisan MaxPooling2D. Penambahan ini bertujuan untuk mengurangi risiko *overfitting* dengan menonaktifkan secara acak sebagian kecil neuron selama pelatihan.

c. *Dropout* Layer 20%

Konfigurasi ketiga serupa dengan konfigurasi sebelumnya, namun dengan tingkat *dropout* yang lebih tinggi, yaitu 20%. Hal ini dimaksudkan untuk mengevaluasi efek penggunaan *dropout* yang lebih agresif terhadap kemampuan generalisasi model.

Pada setiap konfigurasi, model dilatih menggunakan dataset sama yang telah melalui tahap preprocessing. Dataset ini dibagi menjadi tiga subset, yaitu data pelatihan, validasi, dan pengujian, dengan tujuan untuk memisahkan data yang digunakan selama pelatihan dan data yang digunakan untuk mengevaluasi kinerja akhir model. Pelatihan dilakukan selama 30 epoch dengan ukuran batch sebesar 64.

Setelah proses pelatihan selesai, evaluasi dilakukan terhadap data pengujian untuk mengukur kinerja model menggunakan metrik akurasi dan *loss*. Hasil dari ketiga konfigurasi ini kemudian dibandingkan secara menyeluruh untuk menentukan pengaruh penambahan *dropout* layer terhadap kinerja CNN, serta mengidentifikasi konfigurasi yang memberikan hasil terbaik dalam tugas klasifikasi gambar.

### 3. Hasil dan Pembahasan

#### 3.1. Evaluasi Model

Pada bagian ini, hasil evaluasi dari ketiga model yang telah dilatih akan disajikan. Model-model tersebut diuji menggunakan dataset pengujian yang telah disiapkan sebelumnya. Proses evaluasi dilakukan dengan menggunakan fungsi `evaluate()` dari Keras, yang memberikan nilai *loss* dan akurasi dari model pada data pengujian. Berikut adalah hasil evaluasi untuk ketiga model:

**Tabel 2.** Hasil Evaluasi Ketiga Model


Model	Test Loss	Test Accuracy
Tanpa <i>Dropout</i>	0.00011016496864613146	100%
<i>Dropout</i> 10%	0.0011738778557628393	100%
<i>Dropout</i> 20%	0.08739311993122101	100%

Selain hasil evaluasi berupa nilai *loss* dan akurasi, analisis lebih lanjut juga dilakukan dengan menggunakan classification report dan confusion matrix untuk ketiga model. Berikut adalah hasil classification report untuk masing-masing model:

Model 0 - Classification Report:					Model 1 - Classification Report:				
	precision	recall	f1-score	support		precision	recall	f1-score	support
Kuning	1.00	1.00	1.00	8	Kuning	1.00	1.00	1.00	8
Pink	1.00	1.00	1.00	12	Pink	1.00	1.00	1.00	12
accuracy			1.00	20	accuracy			1.00	20
macro avg	1.00	1.00	1.00	20	macro avg	1.00	1.00	1.00	20
weighted avg	1.00	1.00	1.00	20	weighted avg	1.00	1.00	1.00	20
Model 2 - Classification Report:									
	precision	recall	f1-score	support					
Kuning	1.00	1.00	1.00	8					
Pink	1.00	1.00	1.00	12					
accuracy			1.00	20					
macro avg	1.00	1.00	1.00	20					
weighted avg	1.00	1.00	1.00	20					

**Gambar 3.** Classification Report Ketiga Model

Hasil analisis confusion matrix menunjukkan bahwa ketiga model mampu mengklasifikasikan semua data pengujian dengan sempurna. Berikut adalah *confusion matrix* yang sama untuk ketiga model:

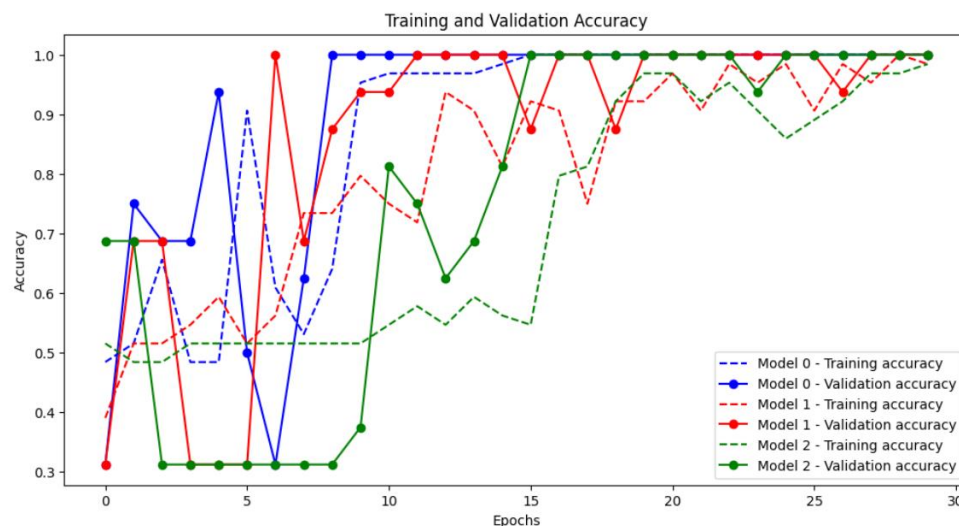


Gambar 4. Confusion Matrix Ketiga Model

### 3.2. Pembahasan Hasil

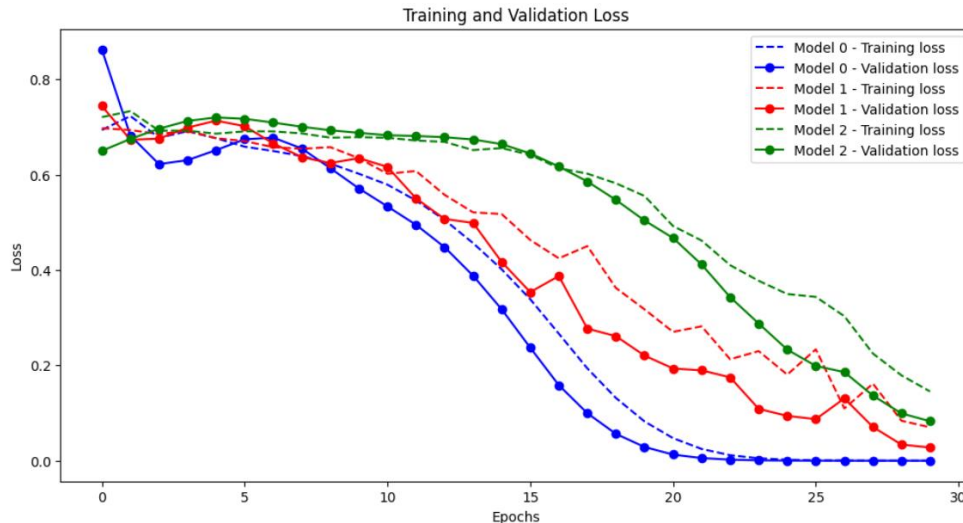
Hasil evaluasi menunjukkan bahwa ketiga model mencapai akurasi pengujian yang sangat tinggi, yaitu 100%, yang menunjukkan bahwa ketiga model berhasil mengklasifikasikan gambar dengan sempurna pada dataset yang digunakan. Namun, meskipun akurasi pada ketiga model sama, terdapat perbedaan yang cukup signifikan dalam nilai *loss* pada masing-masing model, yang dapat memberikan wawasan mengenai pengaruh penggunaan *dropout* layer terhadap proses pelatihan dan generalisasi model.

Hasil analisis confusion matrix menunjukkan bahwa ketiga model mampu mengklasifikasikan semua data pengujian dengan sempurna. Berikut adalah grafik perbandingan akurasi untuk ketiga model:



Gambar 5. Grafik Perbandingan Akurasi *Training* dan *Validasi*

Pada Gambar 5 terlihat perbedaan pola di antara ketiga model yang diuji. Model 0 (tanpa *dropout* layer) mencapai akurasi pelatihan maksimum dengan sangat cepat, tetapi akurasi validasinya menunjukkan fluktuasi signifikan pada awal pelatihan, mengindikasikan adanya potensi *overfitting* akibat ketiadaan mekanisme regularisasi. Sementara itu, Model 1 (dengan *dropout* 10%) menunjukkan peningkatan akurasi pelatihan dan validasi yang lebih stabil, dengan akurasi validasi yang lebih konsisten, menandakan bahwa *dropout* 10% dapat membantu meningkatkan generalisasi model. Sebaliknya, Model 2 (dengan *dropout* 20%) memperlihatkan peningkatan akurasi pelatihan yang lebih lambat dengan akurasi validasi yang lebih stabil. Namun, tingkat *dropout* yang terlalu tinggi ini tampaknya menghambat kemampuan model dalam mempelajari pola kompleks pada data pelatihan.



Gambar 6. Grafik Perbandingan Loss Training dan Validasi

Pada grafik Gambar 6, terlihat perbedaan pola *loss* yang signifikan antara ketiga model. Model 0 (tanpa *dropout* layer) menunjukkan penurunan *training loss* yang sangat cepat, tetapi nilai *validation loss*-nya lebih tinggi, mendukung indikasi adanya *overfitting*. Model 1, dengan *dropout* layer 10%, menunjukkan pola penurunan *training loss* dan *validation loss* yang lebih konsisten, dengan perbedaan nilai yang kecil. Hal ini mencerminkan keseimbangan antara pembelajaran dan kemampuan generalisasi model. Sebaliknya, Model 2 dengan *dropout* layer 20% mengalami penurunan *training loss* yang lebih lambat dan *validation loss* yang lebih tinggi dibandingkan Model 1. Tingkat *dropout* yang terlalu agresif ini mengurangi kapasitas model dalam mempelajari pola penting dari data pelatihan.

Secara keseluruhan, Model 1 dengan *dropout* 10% dapat dianggap sebagai model terbaik karena berhasil mencapai keseimbangan optimal antara akurasi yang tinggi dan kemampuan generalisasi yang kuat. Model ini menunjukkan akurasi pengujian yang sempurna (100%) sambil mempertahankan nilai *loss* yang relatif rendah dan pola pelatihan yang stabil. *Dropout* sebesar 10% berhasil mengurangi risiko *overfitting* yang terlihat pada Model 0, tanpa mengorbankan kemampuan model untuk mempelajari pola penting dalam data. Selain itu, performa stabil pada grafik "*Training and Validation Loss*" menunjukkan bahwa Model 1 mampu menangkap esensi data secara efektif sekaligus menjaga akurasi pada data yang tidak terlihat, menjadikannya pilihan yang tepat untuk implementasi praktis.

#### 4. Kesimpulan

Berdasarkan hasil evaluasi dan analisis, ketiga model (Model 0 tanpa *dropout*, Model 1 dengan *dropout* 10%, dan Model 2 dengan *dropout* 20%) mencapai akurasi sempurna (100%) pada data pengujian. Namun, nilai *loss* menunjukkan perbedaan kemampuan generalisasi. Model 0 memiliki *loss* terendah (0.00011) tetapi menunjukkan indikasi *overfitting*. Model 1, dengan *dropout* 10%, menawarkan keseimbangan terbaik antara performa dan generalisasi, dengan *loss* rendah (0.00117) dan stabilitas grafik pelatihan yang baik. Sebaliknya, Model 2, dengan *dropout* 20%, memiliki *loss* tertinggi (0.08739), mengindikasikan bahwa tingkat *dropout* yang terlalu tinggi dapat mengurangi kemampuan model mempelajari pola data. Berdasarkan grafik, *classification report*, dan *confusion matrix*, Model 1 menunjukkan performa optimal, mampu mempertahankan akurasi tinggi sekaligus mengurangi risiko *overfitting*. Dengan demikian, penggunaan *dropout* layer 10% terbukti efektif untuk meningkatkan generalisasi model tanpa mengorbankan performa, menjadikan Model 1 pilihan terbaik untuk implementasi.

#### Daftar Pustaka

- [1] W. Vidiadivani and I. K. G. Suhartana, "Klasifikasi Jenis Sampah Menggunakan Metode Transfer Learning Pada Convolutional Neural Network (CNN)," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 12, no. 3, pp. 1-10, Feb. 2024.

- [2] J. Choe and H. Shim, "Attention-based *dropout* layer for weakly supervised object localization," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019, pp. 2219–2228.
- [3] Z. Li, W. Yang, S. Peng, and F. Liu, "A survey of *Convolutional Neural Networks*: analysis, applications, and prospects," *Journal of Software Engineering Ampera*, vol. 1, no. 2, pp. ---, Jun. 2020.
- [4] F. M. Qotrunnada and P. H. Utomo, "Metode convolutional neural network untuk klasifikasi wajah bermasker," *PRISMA*, vol. 5, pp. 799–807, 2022.
- [5] D. R. Nallea, L. G. Astutia, I. G. S. Astawaa, L. A. A. R. Putra, A. A. I. N. E. Karyawatia, and I. W. Suprianaa, "Implementasi Metode Convolutional Neural Network Untuk Pengenalan Pola Motif Kain Tenun Rote Ndao Berbasis Android," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 11, no. 1, pp. 1-10, Aug. 2022.
- [6] S. Shedriko and M. Firdaus, "Perbandingan optimizer Adagrad, Adadelta dan Adam dalam klasifikasi gambar menggunakan deep learning," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 8, no. 1, pp. ---, Aug. 2023.
- [7] M. Khoiruddin, A. Junaidi, and W. A. Saputra, "Klasifikasi penyakit daun padi menggunakan convolutional neural network," *Journal of Dinda*, vol. 2, no. 1, pp. 37–45, 2022.
- [8] G. G. Sastrawan, I. P. G. H. Suputra, I. B. G. Dwidasmaraa, and I. A. G. S. P. Putra, "Sales forecasting menggunakan random forest regression dengan particle swarm optimization pada penjualan superstore," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 13, no. 2, pp. ---, Nov. 2024.
- [9] T. S. Girsanga, I. D. M. B. A. Darmawana, N. A. S. ERa, A. A. I. N. E. Karyawatia, I. P. G. H. Suputraa, and C. R. A. Pramarthaa, "Pengembangan Sistem Pengenalan Karakter Aksara Suku Simalungun Berbasis Android," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 11, no. 3, pp. 1-10, Feb. 2023.
- [10] I. G. T. Permana, I. B. G. Dwidasmaraa, M. A. Raharjab, and I. W. Santiyasab, "Ekstraksi Fitur Dengan Convolutional Neural Network Dan Rekomendasi Fashion Menggunakan Algoritma K Nearest Neighbours," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 12, no. 4, pp. 1-10, May 2024.

*This page is intentionally left blank.*