

KLASIFIKASI MOTIF BATIK MENGGUNAKAN RESNET-18 DENGAN SQUEEZE-AND-EXCITATION DAN OPTIMIZER ADAM

Abd Rosyiid Se, Nur Rachmat

Informatika, Universitas Multi Data Palembang
Jalan Rajawali No. 14 Palembang, Indonesia
abdrosyiids@gmail.com

ABSTRAK

Batik merupakan warisan budaya UNESCO yang memiliki keragaman motif unik, namun tingginya kompleksitas visual sering kali menyulitkan identifikasi secara manual. Penelitian ini bertujuan untuk mengimplementasikan serta mengevaluasi performa model ResNet-18 dengan integrasi *Squeeze-and-Excitation* (SE) block untuk klasifikasi tiga motif batik, yaitu Kawung, Parang, dan Truntum. Metode penelitian ini menggunakan dataset sebanyak 685 citra yang diseimbangkan dan diperbanyak menjadi 1074 data dengan teknik augmentasi (*rotation, saturation, dan jittering*). Model yang digunakan adalah ResNet-18 *pre-trained* dari ImageNet 1k, serta menggunakan *Adam Optimizer*. Hasil pengujian menunjukkan bahwa integrasi SE block pada ResNet-18 menunjukkan kecenderungan peningkatan performa klasifikasi sebesar 1% dibandingkan model baseline dengan capaian akurasi tertinggi 98%, dan model dengan SE block dengan capaian *accuracy, precision, recall*, dan *F1-score* sebesar 99%. Penambahan komponen SE block terbukti memberikan stabilitas pada proses pelatihan serta kemampuan generalisasi fitur yang lebih konsisten dibandingkan model tanpa *attention mechanism*.

Kata kunci : Klasifikasi, batik, ResNet-18, Squeeze-and-Excitation, Adam Optimizer.

1. PENDAHULUAN

Batik telah mendapatkan pengakuan internasional dari UNESCO sebagai Warisan Budaya Tak Benda Manusia sejak tanggal 2 Oktober 2009 [1].

Keanekaragaman motif batik tersebar di berbagai daerah dengan motif unik nya masing masing. Namun luasnya variasi motif batik menghadapi tantangan berupa tingginya kompleksitas dan variasi visual motif yang menyulitkan identifikasi secara manual. Karena itu, pengembangan alat atau sistem yang mampu mengklasifikasikan motif batik secara otomatis dan akurat diperlukan untuk mempermudah identifikasi budaya ini.

Beberapa tahun terakhir, pendekatan dengan deep learning terutama dengan basis *Convolutional Neural Network* (CNN) telah banyak digunakan dan menjadi standar teknologi terkini dalam bidang klasifikasi citra [2].

Salah satu arsitektur turunan CNN yang unggul adalah *Residual Network* (ResNet). ResNet menggunakan mekanisme *skip connection* atau *shortcut connection* untuk mengatasi masalah *vanishing gradient*, sehingga memungkinkan pelatihan jaringan yang lebih dalam tanpa menurunkan performa. Penggunaan *residual mapping* dan *shortcut connections* terbukti memberikan hasil yang lebih baik dibandingkan dengan *plain networks* yang sangat dalam [3].

Beberapa penelitian terdahulu telah mengeksplorasi penggunaan CNN untuk klasifikasi batik dengan hasil yang bervariasi [4] [5] [6].

Penggunaan model seperti ResNet, dan MobileNet mampu menunjukkan akurasi tinggi pada klasifikasi citra. Namun, dari beberapa penelitian tersebut masih berfokus pada fitur spasial standar

tanpa mengoptimalkan hubungan antar-channel. Untuk mengoptimalkan identifikasi karakteristik motif batik dapat dilakukan dengan kombinasi *attention mechanism* seperti *Squeeze-and-Excitation* dan ResNet-18 dalam tema klasifikasi citra motif batik.

Attention mechanism yang memungkinkan untuk memberikan bobot atau tingkat kepentingan yang berbeda secara dinamis pada berbagai bagian dari data input yang penting berdasarkan relevansinya [7].

Salah satu penelitian dengan *Squeeze-and-Excitation* ditambahkan pada model MobileNetV2, mendapatkan peningkatan akurasi dari 68% hingga 72% [7].

Selain itu, penggunaan adam optimizer dalam proses pelatihan sangat krusial karena kemampuannya dalam mengatur learning rate yang adaptif. *Adam Optimizer* berasal dari *Adaptive Moment Estimation* dan disingkat menjadi Adam. *Learning rate* akan berubah ubah saat pelatihan karena kemampuan dari *Adam Optimizer* yang membuat learning rate menjadi adaptif [8].

Pada penelitian [9], Penggunaan *Adam Optimizer* dalam model CNN terbukti efektif, model mencapai akurasi pelatihan dan validasi sebesar 99% dan dapat memprediksi dengan tepat setiap data uji.

Berdasarkan uraian tersebut, rencana penyelesaian dalam penelitian ini akan dilakukan integrasi *Squeeze-and-Excitation* (SE) block ke dalam arsitektur ResNet-18. Kombinasi ini diharapkan dapat membantu ekstraksi fitur penting pada karakteristik motif batik yang kompleks melalui pembobotan ulang channel fitur, serta dioptimalkan menggunakan *Adam Optimizer*.

Oleh karena itu, penelitian ini bertujuan untuk melakukan implementasi dan evaluasi terhadap

kombinasi model ResNet-18 dengan *Squeeze-and-Excitation* (SE) block dan model ResNet-18 tanpa *attention mechanism* sebagai perbandingan performa model dalam klasifikasi citra tiga motif batik yaitu, kawung, parang, dan truntum. Dataset dikumpulkan dari platform roboflow dengan judul BatikV2. Dengan pendekatan ini diharapkan model dapat memberikan performa yang lebih baik dalam melakukan klasifikasi motif batik.

2. TINJAUAN PUSTAKA

2.1. Kain Batik

Batik merupakan Warisan Budaya Tak Benda Manusia yang diakui oleh UNESCO sejak tanggal 2 Oktober 2009 [1]. Batik merupakan singkatan dari dua suku kata yaitu Amba dan Titik. Amba yang berarti menulis dan Titik adalah titik, jadi maknanya adalah menulis titik di atas kain [10]. Karena Indonesia memiliki banyak wilayah dan kebudayaan, masing-masing daerah memiliki keunikan motif batiknya sendiri.


2.2. Pengolahan Citra

Pengolahan citra adalah teknik pemrosesan citra untuk meningkatkan kualitas citra dan mengekstrak informasi visual yang relevan menggunakan algoritma komputer [11]. Tahapan pengolahan citra juga mencakup teknik augmentasi data dengan *image rotation*, *image zoom*, dan *brightness*. Hal ini dilakukan untuk memperkaya variasi citra di dalam dataset. Dibandingkan dengan data asli, data dengan teknik augmentasi yang tepat, dapat meningkatkan kinerja model klasifikasi secara signifikan [12].

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network adalah salah satu jenis model deep learning yang dapat melakukan identifikasi objek citra sehingga dapat mengklasifikasikan objek [13]. CNN memiliki banyak lapisan neural. Struktur CNN meliputi ekstraksi fitur yang terdiri dari *convolutional layer* yang diikuti dengan *pooling layer* dan *classifier softmax* [14].

Dengan ini model dapat mengenali fitur dari objek dan melakukan klasifikasi citra. Struktur dari convolutional neural network dapat dilihat pada Gambar 1 berikut.




Gambar 1. Arsitektur CNN

2.4. ResNet-18

Salah satu arsitektur dari CNN ialah ResNet-18. Model ini memiliki 18 layer yang terdiri dari 17 *convolution layer* dan satu *fully-connected layer* [15].

Arsitektur ini memperkenalkan konsep deep *residual learning* dan *skip connection*. Metode ini dapat mengatasi masalah *vanishing gradient* untuk memungkinkan pelatihan jaringan yang sangat dalam [16].

Struktur *skip connection* dapat dilihat pada Gambar 2.




Gambar 2. Skip connection

2.5. Squeeze-and-Excitation

Squeeze-and-Excitation adalah salah satu jenis *attention mechanism*. Mekanisme ini memungkinkan jaringan untuk melakukan rekalisasi fitur. Proses tersebut membantu jaringan untuk fokus pada fitur yang informatif dan secara bersamaan mereduksi fitur lain yang kurang berguna, sehingga meningkatkan kemampuan representasi dari model tersebut [17].

Proses mekanisme ini dapat dilihat pada gambar 3. Mekanisme ini dimulai dengan langkah *squeeze*, yang bertujuan untuk mengekstrak informasi global dari setiap feature channel. Digunakan *Global Average Pooling* (GAP) untuk mereduksi dimensi spasial menjadi sebuah deskriptor saluran tunggal [18].

Dilanjutkan dengan langkah *Excitation*, dimana channel tunggal tadi melewati ReLU *activation* di antara lapisan FC dan diakhiri dengan fungsi *sigmoid* untuk menghasilkan bobot modulasi per-channel.



Gambar 3. SE pada ResNet

2.6. Adam Optimizer

Dalam penamaannya Adam berasal dari *Adaptive Moment Estimation* yang disingkat menjadi Adam. Pada saat Adam Optimizer digunakan untuk pelatihan model, *learning rate* akan berubah ubah karena kemampuan *Adam Optimizer* yang membuat *learning rate* menjadi adaptif [8].

2.7. Penelitian Terkait


Pada penelitian terdahulu, Klasifikasi menggunakan arsitektur CNN dengan objek berupa motif batik telah banyak dilakukan beberapa penelitian [4] [5] [6].

Penelitian yang mengkombinasikan ResNet dengan *Squeeze-and-Excitation* juga telah dilakukan dengan capaian peningkatan akurasi model yang signifikan dari 68% hingga 72% [7].

Hasil tersebut menunjukkan bahwa pendekatan menggunakan *attention mechanism* efektif untuk model mengenali fitur penting dari objek citra. Pada penelitian ini SE block diterapkan pada *block residual* model ResNet-18, sehingga memungkinkan peningkatan performa model dalam mengidentifikasi fitur penting pada citra.

3. METODE PENELITIAN

Tahapan penelitian ini dilakukan secara sistematis, tahapan dimulai dengan studi literatur penelitian terdahulu, pengumpulan dataset batik, pengolahan citra melalui teknik augmentasi, sehingga implementasi model resnet-18 yang diintegrasikan dengan *squeeze-and-excitation* (SE) Block dan *Adam Optimizer*. Seluruh rangkaian proses tersebut diakhiri dengan tahap evaluasi, diagram alir secara ringkas ditunjukkan pada gambar 4 berikut.



Gambar 4. Tahapan penelitian

3.1. Studi Literatur

Tahapan ini dimulai dengan melakukan pembelajaran literatur berupa jurnal dan buku terkait topik penelitian dasar pembelajaran dalam penggunaan metode *Convolutional Neural Network*

(CNN), terutama pada arsitektur ResNet-18 yang dikombinasikan dengan mekanisme *Squeeze-and-Excitation* (SE) block serta pengguna optimasi Adam untuk klasifikasi motif batik. Literatur yang digunakan mencakup konsep masing-masing metode, serta penelitian sebelumnya yang berkaitan pada penelitian ini.

3.2. Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan dataset berupa dataset motif batik yang dipublish pada platform Universe Roboflow dengan judul Batikv2 version 2. Tiga kelas motif batik akan digunakan yaitu Kawung sebanyak 110 citra, Parang sebanyak 148 citra, dan Truntum 427 citra. Dari tiga kelas motif tersebut, dataset memiliki total 685 gambar motif batik yang dibagi menjadi tiga bagian yaitu data *training*, *validation*, dan *testing*.



Gambar 5. Sampel dataset

3.3. Perancangan Model

Pada tahap ini dirancang pendekatan deep learning dengan arsitektur ResNet-18 yang dikombinasikan dengan *Squeeze-and-Excitation* (SE) Block. Dataset yang digunakan terdiri dari 685 citra dengan tiga kelas motif batik, yaitu Kawung, Parang, dan Truntum. Data dibagi menjadi tiga bagian yaitu 80% untuk *training*, 10% untuk *validation*, dan 10% untuk *testing* guna menjamin generalisasi model. Hasil dari split dataset tersebut menghasilkan 564 data *training*, 67 data *validation*, dan 69 data *testing*.

Tahapan *preprocessing* dimulai dengan penerapan transfer learning menggunakan *bobot pre-trained ImageNet*, yang diikuti dengan *unfreeze* pada blok *residual terakhir* untuk meningkatkan kemampuan ekstraksi fitur visual kompleks. Untuk mengatasi ketidakseimbangan kelas pada data *training*, augmentasi dilakukan pada kelas minoritas meliputi *rotation* (25), *saturation* (0,8-1,2), dan *image jittering* (0,8-1,2). Augmentasi menghasilkan 1074 data *training*, 129 data *validation*, 123 data *testing* sehingga setiap kelas memiliki jumlah data yang sama.

Arsitektur model yang digunakan adalah ResNet-18 sebagai *backbone* yang memanfaatkan *shortcut connection* untuk mengatasi *vanishing gradient*. SE Block dirancang untuk ditempatkan pada setiap blok residual ResNet-18 guna melakukan rekalisasi fitur secara adaptif. Proses pelatihan model menggunakan *Adam Optimizer* dengan skema *learning rate* adaptif. *Hyperparameter* pelatihan yang digunakan meliputi: 50 *epoch*, *batch size* 32, dan *learning rate* 0,001.

3.4. Implementasi

Pada tahapan ini dilakukan implementasi dari sistem yang telah dirancang sebelumnya agar sistem dapat mengenali dan melakukan klasifikasi terhadap data motif batik. Bahasa pemrograman Python digunakan dalam pengembangan sistem karena didukung oleh berbagai *library* untuk melakukan pengolahan citra digital dan *deep learning* dalam membangun arsitektur ResNet-18 serta mekanisme *Squeeze-and-Excitation*. Implementasi sistem dilakukan sesuai dengan alur perancangan yang mencakup tahapan preprocessing seperti augmentasi data, teknik *transfer learning*, serta pembagian dataset Batiky2 menjadi data *training*, *validation*, dan *testing*. Seluruh rangkaian implementasi ini diintegrasikan secara menyeluruh untuk memastikan proses pengenalan fitur dan klasifikasi motif batik dapat berjalan dengan performa yang optimal.

3.5. Evaluasi Model

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, *accuracy*, dan *f1-score* yang dapat dilihat pada Persamaan (1), (2), (3), dan (4).

$$\text{Precision} = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (2)$$


$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3)$$

$$\text{F1 score} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4)$$

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan dan Validasi


Untuk menguji performa integrasi SE *block* pada arsitektur ResNet-18, dilakukan pengujian komparatif antara dua variasi model dengan skenario model 1 ResNet-18 base dan model 2 ResNet-18 dengan SE *block*.



Gambar 6. Kurva training model 1

Berdasarkan gambar 6 pada proses *training*. Menunjukkan *training loss* berhasil turun secara konsisten hingga mencapai nilai akhir sebesar 0.0027. Namun, *validation loss* mulai mengalami stagnasi dan tertahan di kisaran nilai 0.0047 hingga 0.088 setelah epoch ke-15. *Training accuracy* mampu mencapai grafik yang optimal hingga menyentuh 100% pada epoch ke-23. Meski demikian, kurva *validation accuracy* menunjukkan fluktuasi yang cukup tajam

terutama pada *epoch* ke-15 hingga 23 dimana akurasi menurun hingga 93.50%. Hal ini mengindikasikan bahwa model tanpa SE *block* memiliki keterbatasan dalam menggeneralisasi fitur-fitur baru pada data validasi.



Gambar 7. Kurva training model 2

Berdasarkan hasil pelatihan pada Gambar 7, model ResNet-18 yang diintegrasikan dengan SE *block* menunjukkan performa yang lebih stabil dibandingkan dengan model baseline. Training loss berhasil ditekan secara konsisten hingga mencapai nilai akhir 0,0045. Namun, terdapat kesenjangan (*gap*) dengan validation loss yang tertahan di kisaran 0,00780 hingga 0,1370 setelah epoch ke-13, yang mengindikasikan adanya gejala *overfitting* pada model. Meskipun training accuracy mencapai 100% pada epoch ke-25, kurva validation accuracy menunjukkan fluktuasi minor dengan titik terbaik sebesar 98,37%. Bobot model terbaik pada epoch ke-31 inilah yang kemudian digunakan dalam tahap testing. Hal ini menunjukkan bahwa meski terdapat indikasi *overfitting*, penambahan komponen SE *block* memberikan stabilitas pelatihan yang lebih baik dan kemampuan pengenalan fitur yang lebih konsisten dibandingkan model tanpa attention mechanism.

4.2. Hasil Pengujian


Setelah pelatihan model selesai, pengujian dilakukan menggunakan data testing yang belum pernah dilihat oleh model sebelumnya. Hasil komparasi dari kedua model dengan *macro-average* dirangkum pada Tabel 1.

Tabel 1. Perbandingan kinerja model pada data testing

Model	Accuracy	Precision	Recall	F1-Score
Model 1	98%	98%	98%	98%
Model 2	99%	99%	99%	99%


Berdasarkan hasil pengujian pada Tabel 1, terlihat bahwa integrasi SE *block* berhasil menaikkan performa klasifikasi 1%. Model 2 (ResNet + SE *block*) menunjukkan performa dengan nilai rata-rata *macro average* sebesar 99% seluruh metrik evaluasi. Hasil ini mengungguli model 1 (ResNet-18 baseline) yang mendapatkan angka 98% untuk keempat metrik tersebut.

4.3. Analisis Confusion Matrix



Gambar 8. Confusion matrix model 1

Berdasarkan Gambar 8, motif batik truntum dan parang berhasil dikenali secara sempurna dari masing masing data uji. Fokus kesalahan klasifikasi terjadi pada kelas batik kawung, dimana terdapat 3 sampel data citra yang salah prediksi sebagai kelas truntum, sehingga menurunkan nilai recall kelas batik-kawung menjadi 0,93. Hal ini dipicu oleh kemiripan karakteristik pola geometri yang berulang atau ornamen yang menyerupai struktur bintang/bunga kecil. Secara keseluruhan model masih sangat baik dengan pencapaian akurasi global sebesar 97% (dengan pembulatan macro-average 0,98).



Gambar 9. Confusion matrix model 2

Berdasarkan Gambar 9, model menunjukkan klasifikasi sempurna pada dua kelas batik yaitu truntum dan kawung dengan akurasi 100% dimana 43 data masing masing kelas berhasil ditebak. Namun pada kelas parang terdapat 1 sampel citra yang salah diprediksi sebagai kelas batik kawung. Dengan

kesalahan yang minim ini mengindikasikan bahwa model memiliki kemampuan generalisasi dan pemisahan fitur yang baik.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa integrasi *mekanisme attention* berupa *Squeeze-and-Excitation* block pada arsitektur ResNet-18 cenderung meningkatkan klasifikasi motif batik dari 98% menjadi 99%. Penggunaan *SE block* memberikan kemampuan generalisasi yang baik dan kurva pelatihan yang lebih stabil dibandingkan model ResNet-18 tanpa *attention mechanism*. Sebagai saran untuk selanjutnya, pengembangan dapat dilakukan dengan menambah jumlah kelas motif batik dan volume dataset yang lebih besar guna menguji ketangguhan model pada variasi visual yang lebih luas, serta untuk mengeksplorasi penggunaan arsitektur CNN lain yang berbeda untuk perbandingan performa yang lebih komprehensif.

DAFTAR PUSTAKA

- [1] M. Larasati, "Pelestarian Budaya Batik Nusantara sebagai Identitas Kultural melalui Pameran di Museum Batik Pekalongan pada Masa COVID-19," *J. Sustain. Tour. Res.*, vol. 3, no. 1, pp. 46–50, 2021, doi: 10.24198/tornare.v3i1.29849.
- [2] J. Lu and L. Tan, "Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification," *Agriculture*, vol. 11, no. 8, p. 707, 2021, doi: 10.3390/agriculture11080707.
- [3] D. Sarwinda, R. Hilya, A. Bustamam, and P. Anggia, "ScienceDirect ScienceDirect Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer," *Procedia Comput. Sci.*, vol. 179, no. 1, pp. 423–431, 2021, doi: 10.1016/j.procs.2021.01.025.
- [4] D. G. T. Meranggi, N. Yudistira, and Y. A. Arum, "Batik classification using convolutional neural network with data improvements," *Int. J. Informatics Vis.*, vol. 6, no. 1, pp. 6–11, 2022, doi: 10.30630/ijoiv.6.1.716.
- [5] W. S. Amurrokhman and N. Nur, "Perbandingan ResNet-50, MobileNetV2, dan MobileNetV3-Large dalam klasifikasi motif batik Indonesia berbasis transfer learning," *J. Teknol. dan Sist. Inf. Univrab*, vol. 11, no. 1, pp. 1457–1467, 2026, doi: 10.36341/rabit.v11i1.7372.
- [6] U. Muhdhor and Yohannes, "Evaluation of MobileNet-Based Deep Features for Yogyakarta Traditional Batik Motif Classification," *Sinkron*, vol. 10, no. 1, pp. 389–395, 2026, doi: 10.33395/sinkron.v10i1.15668.
- [7] R. G. Utomo and R. Mardhiyyah, "Enhancing Convolutional Neural Network Accuracy for Herbal Leaf Classification Using Squeeze and Excitation Attention," *J. Sci. Resesarch, Educ.*

- Technol.*, vol. 4, no. 4, pp. 2354–2369, 2025, doi: 10.58526/jsret.v4i4.938.
- [8] S. A. S. Y. Syifa and I. A. Dewi, “Arsitektur ResNet-152 dengan Perbandingan Optimizer Adam dan RMSProp untuk Mendeteksi Penyakit Paru – Paru,” *MIND (Multimedia Artif. Intell. Netw. Database)*, vol. 7, no. 2, pp. 139–150, 2022, doi: 10.26760/mindjournal.v7i2.
- [9] S. Bahri, A. Sunyoto, and M. P. Kurniawan, “Klasifikasi Hama Pada Daun Sawi Menggunakan Convolutional Neural Network (CNN) Dengan Algoritma Xcaption dan Optimasi Adam,” *J. Electr. Eng. Comput.*, vol. 6, no. 2, pp. 359–370, 2024, doi: 10.33650/jeecom.v4i2.
- [10] Fuadz Hasyim, Kamil Malik, Fathur Rizal, and Yudistira, “Implementasi algoritma Convolutional Neural Networks (CNN) Untuk Klasifikasi Batik,” *COREAI J. Kecerdasan Buatan, Komputasi dan Teknol. Inf.*, vol. 2, no. 2, pp. 40–47, 2021, doi: 10.33650/coreai.v2i2.3365.
- [11] J. Kalim *et al.*, “Implementasi Model EfficientNet-B5 dengan Transfer Learning untuk Klasifikasi Tingkat Roasting Biji Kopi Berbasis Citra,” *J. Mhs. Tek. Inform.*, vol. 10, no. 2, pp. 2965–2972, 2026, doi: 10.36040/jati.v10i2.17848.
- [12] D. Husen, “Evaluasi Teknik Augmentasi Data untuk Klasifikasi Tumor Otak Menggunakan CNN pada Citra MRI,” *TEKNIMEDIA*, vol. 5, no. 2, pp. 219–227, 2024, doi: 10.46764/teknimedia.v5i2.220.
- [13] I. Muslim Karo Karo, J. Arifin Karo Karo, Yunianto, Hariyanto, and M. Falah, “Klasifikasi Mutu Fisik Tempe Menggunakan Metode Convolutinal Neural Network(CNN),” *STRING (Satuan Tulisan Ris. dan Inov. Teknol.*, vol. 8, no. 2, pp. 209–216, 2023, doi: 10.30998/string.v8i2.17596.
- [14] A. Rachmatullah Pratama and A. F. Cobantoro, “Klasifikasi Citra Pneumonia Menggunakan Arsitektur Convolutional Neural Network (Cnn) Pneumonia Image Classificati on Using Convolutinal Neural Network (Cnn) Architecture,” *J. Ilm. NERO*, vol. 8, no. 2, p. 2023, 2023, doi: 10.21107/nero.v8i2.18992.
- [15] G. Thiodorus, A. Praselia, L. Afrizal, and N. Yudistira, “Klasifikasi citra makanan / nonmakanan menggunakan metode transfer learning dengan model residual network,” *Teknol. J. Ilm. Sist. Inf.*, vol. 11, no. 2, pp. 74–83, 2021, doi: 10.26594/teknologi.v11i2.2402.
- [16] M. D. A. Pranatha, M. A. Maricar, and G. H. Setiawan, “Implementasi arsitektural Resnet-34 dalam klasifikasi gambar penyakit pada daun kentang,” *J. Teknolgi Dan Sist. Inf. Bisnis*, vol. 6, no. 3, pp. 575–580, 2024, doi: 10.47233/jteksis.v6i3.1431.
- [17] L. R. Ali, S. A. Jebur, M. M. Jahefer, A. K. Nawar, and Z. S. Mahdi, “Integrating Squeeze-and-Excitation Network with Pretrained CNN Models for Accurate Plant Disease Detection,” *Int. J. Electr. Comput. Eng. Syst.*, vol. 16, no. 8, pp. 621–632, 2025, doi: 10.32985/ijeces.16.8.5.
- [18] S. Mekruksavanich and A. Jitpattanukul, “Hybrid convolution neural network with channel attention mechanism for sensor - based human activity recognition,” *Sci. Rep.*, vol. 13, no. 1, pp. 1–14, 2023, doi: 10.1038/s41598-023-39080-y.