

Implementasi Model Arsitektur VGG16 dan MobileNetV2 Untuk Klasifikasi Citra Kupu-Kupu

Desi Ramayanti, Sri Dianing Asri, Lionie Lionie

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia

desi.ramayanti@undira.ac.id, sri.dianing.asri@undira.ac.id, lionie@undira.ac.id

Article Info

Article history:

Received, 2022-01-25

Revised, 2022-06-07

Accepted, 2022-11-09

Kata Kunci:

e-butterfly

deep learning

VGG16

MobileNetV2

ABSTRAK

Untuk mengurangi populasi kupu-kupu, perlu adanya strategi untuk memantau jumlah dan spesies yang ada pada masing-masing ekosistem. Peran teknologi dapat membantu dalam proses ini, misalnya pengembangan sistem e-Butterfly untuk mengumpulkan gambar spesies kupu-kupu dari berbagai wilayah sehingga dapat diketahui jenis spesies yang masih ada dan letak wilayah hidupnya. Identifikasi spesies kupu-kupu dapat dilakukan dan dibantu oleh komputer dengan serangkaian proses lebih spesifik pada cabang ilmu machine learning dan image processing. Tujuan dari penelitian ini adalah untuk mengetahui kinerja (performance) dari model model arsitektur VGG16 dan MobileNetV2 untuk klasifikasi citra gambar kupu-kupu berdasarkan hasil ekstraksi fitur pada citra gambar tersebut. Dataset penelitian berisi 4955 gambar yang kemudian diberi label 50 butterfly species dengan ukuran 224 X 224 X 3. Akurasi terbaik diperoleh MobileNetV2 tanpa fine-tuning yaitu mencapai presentase 96%, dilanjutkan dengan VGG16 dengan fine-tuning, MobileNetV2 dengan fine-tuning, dan akurasi testing paling kecil diperoleh VGG16 tanpa fine-tuning. Untuk nilai precision, recall, F1-Score, dan Cohens Kappa lebih tinggi diperoleh model MobileNetV2 tanpa fine tuning, hal ini menunjukkan bahwa MobileNetV2 tanpa fine tuning lebih imbang dalam akurasi tiap kelasnya.

ABSTRACT

To reduce the butterfly population, a strategy is needed to monitor the number and species present in each ecosystem. The role of technology can help in this process, for example, the development of the e-Butterfly system to collect images of butterfly species from various regions so that the species that still exist and where they live can be identified. The identification of butterfly species can be carried out and assisted by computers with a series of processes more specific to the branch of machine learning and image processing. The purpose of this study was to determine the performance of the VGG16 and MobileNetV2 architectural models for the classification of butterfly images based on the results of feature extraction on these images. The research dataset contains 4955 images labeled 50 butterfly species with a size of 224 X 224 X 3. MobileNetV2 obtains the best accuracy without fine-tuning, which reaches 96%, followed by VGG16 with fine-tuning, MobileNetV2 with fine-tuning, and accuracy VGG16 obtained the most negligible testing without fine-tuning. For the higher precision, recall, F1-Score, and Cohens Kappa values, the MobileNetV2 model without fine-tuning shows that MobileNetV2 without fine-tuning is more balanced in the accuracy of each class.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Desi Ramayanti,
Program Studi Informatika,
Universitas Dian Nusantara, Indonesia
Email: desi.ramayanti@undira.ac.id

1. PENDAHULUAN

Berdasarkan data penelitian, jumlah populasi serangga secara global khususnya spesies kupu-kupu menurun dari tahun ke tahun. Banyak faktor yang menyebabkan hal ini terjadi, antara lain perubahan iklim, dampak negative pestisida dan lainnya telah mengganggu ekosistem dan habitat kupu-kupu. Faktor yang paling berpengaruh terhadap punahnya spesies kupu-kupu adalah perubahan iklim global. Jika ini terus dibiarkan maka beberapa spesies akan berkurang dan terancam punah [1]–[3].

Perubahan iklim secara tidak langsung mempengaruhi tumbuh kembang telur kupu-kupu sehingga menetas lebih cepat dan tidak berkembang dengan baik. Hal ini akan menyebabkan populasi kupu-kupu terus menurun dan menyebabkan ekosistem lain terganggu. Kupu-kupu memiliki peran cukup penting dalam ekosistem Misalnya, kupu-kupu merupakan hewan yang membantu dalam proses penyerbukan bunga pada tanaman. Selain itu, kupu-kupu juga merupakan makanan bagi hewan lain yang perlu hidup dan berkembang pada suatu ekosistem [1].

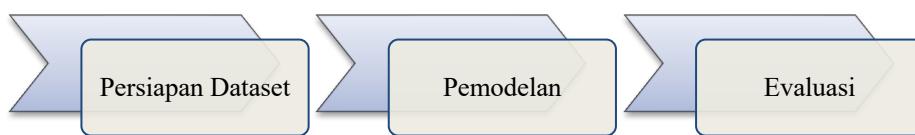
Untuk mengurangi dampak pengurangan populasi kupu-kupu, perlu adanya strategi untuk memantau jumlah dan spesies yang ada pada masing-masing ekosistem. Peran teknologi dapat membantu dalam proses ini, misalnya pengembangan sistem *e-Butterfly* untuk mengumpulkan gambar spesies kupu-kupu dari berbagai wilayah sehingga dapat diketahui jenis spesies yang masih ada dan letak wilayah hidupnya. Identifikasi spesies kupu-kupu dapat dilakukan dan dibantu oleh komputer dengan serangkaian proses lebih spesifik pada cabang ilmu *machine learning* dan *image processing* [1], [4]–[7].

Beberapa penelitian mengenai *machine learning* dan *image processing* untuk pengolahan dataset kupu-kupu telah dilakukan oleh [1], [8]–[13]. Penelitian oleh Kartika *et al.* (2018) ini menggunakan metode *color feature extraction (color quantization+ HSV color space)* dan metode *texture feature (local binary pattern)* untuk mengklasifikasi dataset kupu-kupu. Dataset yang digunakan adalah gambar kupu-kupu dengan resolusi 420x315 pixels berjumlah 890 images. Hasil klasifikasi dari penelitian ini mencapai akurasi sebesar 72% dengan precision value sebesar 76%, recall sebesar 72% dan f-measure sebesar 74%. [8]

Penelitian oleh Kaya & Kayci (2014) menggunakan metode *gray level co-occurrence matrix (GLCM)* dan *artificial neural networks (ANN)* untuk melakukan klasifikasi gambar kupu-kupu. Dataset yang digunakan adalah gambar kupu-kupu dengan jumlah 140 *butterfly images*. Penelitian ini memperoleh akurasi sebesar 92.85 % dari hasil akhir pemrosesan data [9]. Penelitian oleh Zhu & Spachos (2019) membandingkan hasil metode SVM, CNN Transfer learning VGG untuk klasifikasi gambar kupu-kupu. Penelitian ini menggunakan dataset citra kupu-kupu dengan jumlah 832 images. Hasil dari penelitian menunjukkan bahwa akurasi menggunakan SVM mencapai 52.8%, Deep learning 4-Conv CNN mencapai 98.44% dan Transfer learning VGG19 mencapai 98.53% [10]. Tujuan dari penelitian ini adalah untuk mengetahui kinerja (*performance*) dari model VGG16 dan MobileNetV2 untuk klasifikasi citra gambar kupu-kupu berdasarkan hasil ekstraksi fitur pada citra gambar tersebut.

2. METODE PENELITIAN

Penelitian ini terdiri 3 tahapan utama yang bertujuan untuk klasifikasi citra kupu-kupu berdasarkan hasil kinerja model arsitektur VGG16 dan MobileNetV2. Tahapan penelitian dalam penelitian ini dapat dilihat pada Gambar berikut.



Gambar 1 Tahapan Penelitian

Berdasarkan Gambar diatas, penelitian ini menggunakan *butterfly image dataset* yang dikumpulkan dari online resources. Dataset penelitian berisi 4955 gambar yang kemudian diberi label 50 *butterfly species* dengan ukuran 224 X 224 X 3. Contoh data gambar dapat dilihat pada gambar di bawah ini.

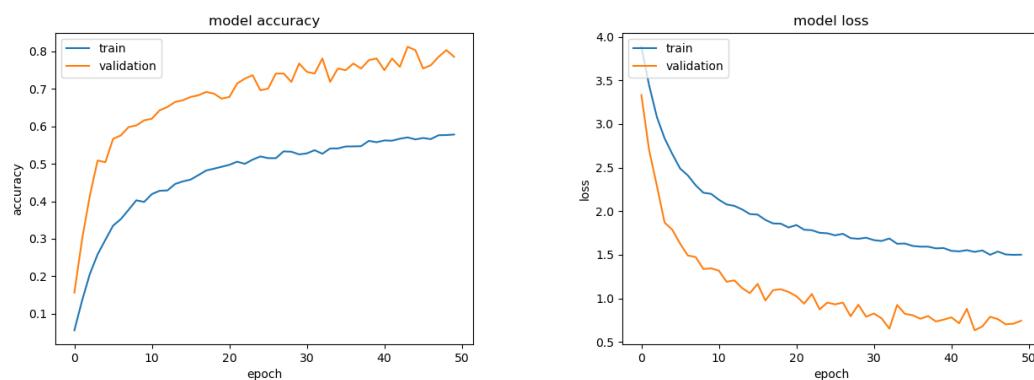
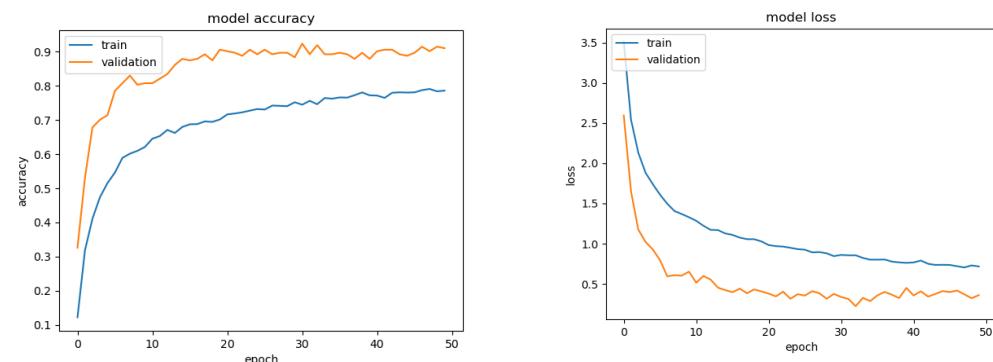


Gambar 2 Contoh Citra Kupu-Kupu

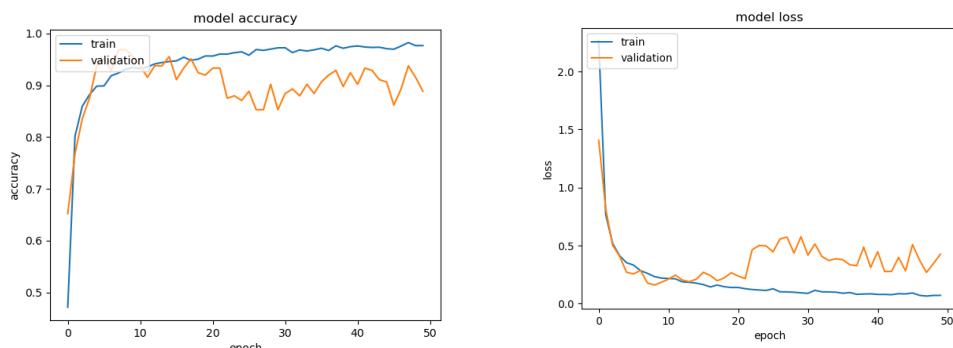
Untuk *butterfly classification modelling*, penelitian ini mengimplementasikan VGG16 dan MobileNetV2 dengan menggunakan 85% dataset untuk training dan 15% dari dataset untuk proses training. Untuk mengevaluasi kinerja algoritma, penelitian ini menggunakan standard statistical measures, antara lain accuracy, precision, recall dan F-measure [14].

3. HASIL DAN ANALISIS

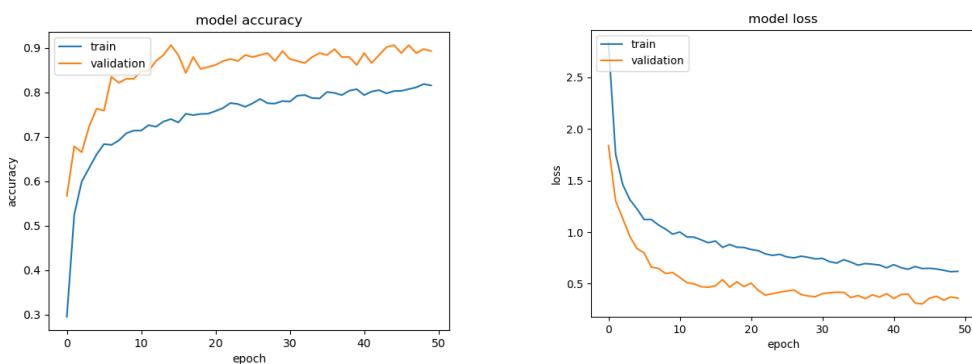
Tujuan dari penelitian ini adalah untuk mengetahui kinerja (*performance*) dari model VGG16 dan MobileNetV2 untuk klasifikasi citra gambar kupu-kupu berdasarkan hasil ekstraksi fitur pada citra gambar tersebut. VGG16 terdiri dari 5 blok konvolusi sebelum terhubung ke MLP *classifier*. Blok konvolusi terhubung ke tiga lapisan MLP yang terdiri dari dua lapisan tersembunyi (*hidden layer*) dan satu lapisan keluaran (*output layer*). Lapisan keluaran terdiri dari node yang secara langsung mewakili jumlah kelas, dan fungsi aktivasi *softmax* (untuk lebih dari dua kelas) atau fungsi aktivasi sigmoid (untuk kelas kurang dari atau sama dengan dua) [15]. Pada eksperimen pertama adalah implementasi model VGG16 tanpa *fine-tuning* yang dilanjutkan dengan implementasi model VGG16 dengan *fine-tuning*.

Gambar 3 Hasil Kinerja VGG16 Tanpa *Fine-Tuning*Gambar 4 Hasil Kinerja VGG16 Dengan *Fine-Tuning*

Model *classifier* MobileNetV2 adalah arsitektur ini yang efisien sehingga dapat diterapkan pada perangkat dengan keterbatasan kemampuan komputasi. Model ini merupakan peningkatan dari MobileNetV, sesuai untuk aplikasi visi komputer untuk mengatasi masalah kompleksitas jaringan melalui inverted residual linear bottleneck layer [16]. Pada eksperimen kedua adalah implementasi model MobileNetV2 tanpa *fine-tuning* yang dilanjutkan dengan implementasi model MobileNetV2 dengan *fine-tuning*.



Gambar 5 Hasil Kinerja MobileNetV2 Tanpa *Fine-Tuning*



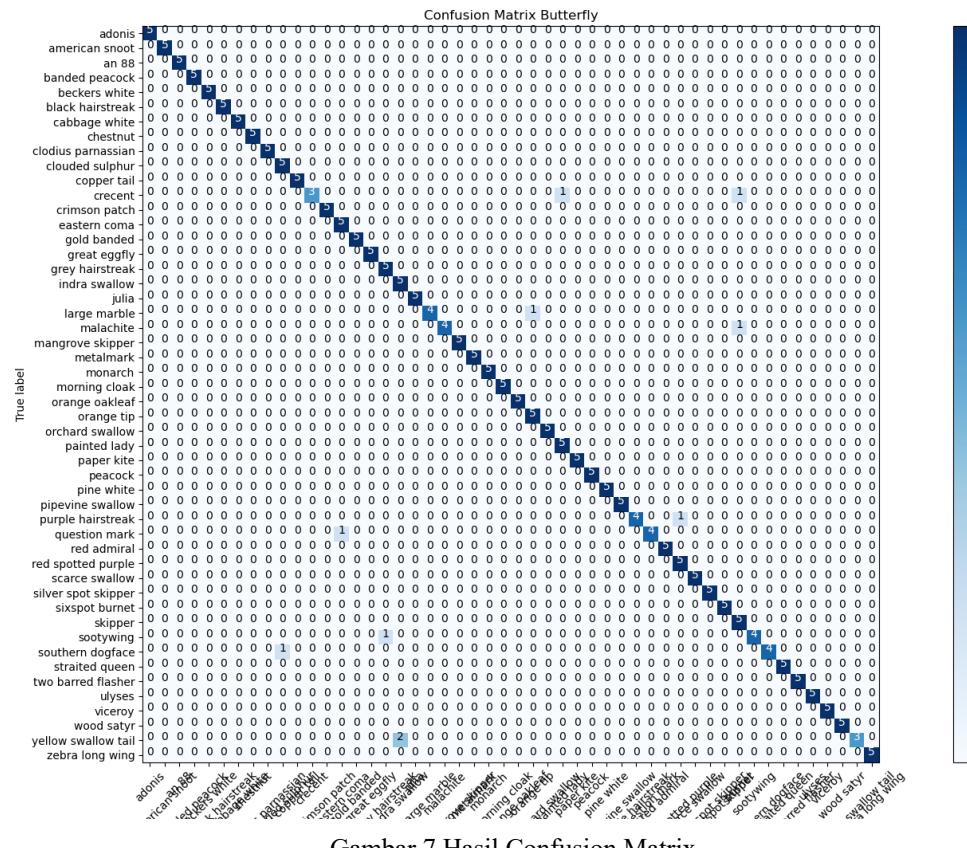
Gambar 6 Hasil Kinerja MobileNetV2 Dengan *Fine-Tuning*

Untuk mengetahui kinerja masing-masing model, hasil eksrimen diukur menggunakan pengukuran akurasi, precision, recall, F1-score dan cohens kappa seperti yang terlihat pada Tabel berikut ini.

Tabel 1 Evaluasi Kinerja Model

| Model | Akurasi Training | Akurasi Validasi | Akurasi Testing | Precision | Recall | F1-Score | Cohens Kappa |
|------------------------------|------------------|------------------|-----------------|-----------|--------|----------|--------------|
| VGG16 | 0.5706 | 0.8125 | 0.8120 | 0.8379 | 0.8120 | 0.8097 | 0.8081 |
| VGG16 with fine-tuning | 0.7451 | 0.9241 | 0.9160 | 0.9336 | 0.9160 | 0.9124 | 0.9142 |
| MobileNetV2 | 0.9236 | 0.9688 | 0.9600 | 0.9686 | 0.9600 | 0.9590 | 0.9591 |
| MobileNetV2 with fine-tuning | 0.7796 | 0.9107 | 0.9120 | 0.9314 | 0.9120 | 0.9086 | 0.9102 |

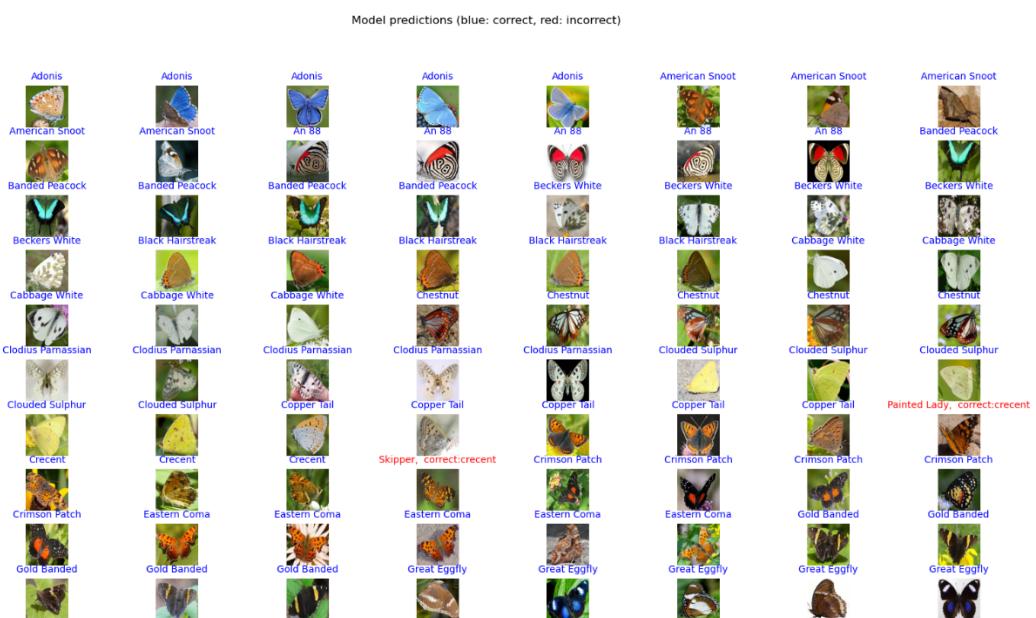
Tabel diatas memperlihatkan perbandingan hasil evaluasi model *transfer learning* VGG16 dan MobileNetV2 tanpa *fine-tuning* dan dengan *fine-tuning*. Akurasi testing terbaik diperoleh MobileNetV2 tanpa *fine-tuning*, dilanjutkan dengan VGG16 dengan *fine-tuning*, MobileNetV2 dengan *fine-tuning*, dan akurasi testing paling kecil diperoleh VGG16 tanpa *fine-tuning*. Untuk nilai Precision, Recall, F1-Score, dan Cohens Kappa lebih tinggi diperoleh model MobileNetV2 tanpa *fine tuning*, hal ini menunjukkan bahwa MobileNetV2 tanpa *fine tuning* lebih imbang dalam akurasi tiap kelasnya.



Gambar 7 Hasil Confusion Matrix

Berdasarkan Gambar diatas, pada model MobileNetV2 tanpa *fine tuning*, dari 250 images testing terdapat 240 images yang terkласifikasi dengan benar, sedangkan terdapat 10 images yang terkласifikasi salah yaitu 2 images pada kelas *crecent* dan kelas *yellow swallow tail*; dan 1 images pada kelas *large marble*, *malachite*, *purple hairstreak*, *question mark*, *sootywing*, dan *southern dogface*.

Dapat terlihat pada *confusion matrix* tersebut bahwa model MobileNetV2 mengenali hampir keseluruhan data testing. Sebanyak 42 kelas terkласifikasi secara benar untuk keseluruhan datanya, sedangkan hanya 8 kelas yang sedikit salah terkласifikasi. Gambar dibawah berikut memperlihatkan hasil prediksi untuk beberapa images pada data testing. Pada gambar terlihat untuk yang benar terkласifikasi ditunjukkan dengan label berwarna biru, sedangkan yang salah terkласifikasi ditunjukkan dengan label berwarna merah.



Gambar 8 Hasil Prediksi MobileNetV2

4. KESIMPULAN

Akurasi terbaik diperoleh MobileNetV2 tanpa fine-tuning yaitu mencapai presentase 96%, dilanjutkan dengan VGG16 dengan fine-tuning, MobileNetV2 dengan fine-tuning, dan akurasi testing paling kecil diperoleh VGG16 tanpa fine-tuning. Untuk nilai precision, recall, F1-Score, dan Cohens Kappa lebih tinggi diperoleh model MobileNetV2 tanpa fine tuning, hal ini menunjukkan bahwa MobileNetV2 tanpa *fine-tuning* lebih imbang dalam akurasi tiap kelasnya.

REFERENSI

- [1] M. Skreta, A. Luccioni, and D. Rolnick, “Spatiotemporal Features Improve Fine-Grained Butterfly Image Classification,” in *Conference on Neural Information Processing Systems*, 2020.
- [2] P. Sukmasetya, F. Nurhidayati, I. Permatasari, A. Rahmah, D. I. Sensuse, and H. Noprisson, “Developing mobile expert web-based system using brainstorming method: Case: Tetanus and botulism diagnosis and treatment in goat,” in *2017 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2017, pp. 303–308.
- [3] H. Noprisson, D. I. Sensuse, Y. G. Sucahyo, and Lukman, “Metadata Development for Ethnophytomedicine Resources Using Metadata Analysis Approach,” in *The 2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE 2016)*, 2016.
- [4] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and M. Utami, “Hand-Woven Fabric Motif Recognition Methods: A Systematic Literature Review,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 90–95.
- [5] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, “Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification,” *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [6] I. Nurhaida, V. Ayumi, D. Fitrianah, R. A. M. Zen, H. Noprisson, and H. Wei, “Implementation of deep neural networks (DNN) with batch normalization for batik pattern recognition,” *Int. J. Electr. Comput. Eng.*, vol. 10, no. 2, pp. 2045–2053, 2020.
- [7] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, “A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [8] D. S. Y. Kartika, D. Herumurti, and A. Yuniarini, “Butterfly image classification using color quantization method on hsv color space and local binary pattern,” *IPTEK J. Proc. Ser.*, no. 1, pp. 78–82, 2018.
- [9] Y. Kaya and L. Kayci, “Application of artificial neural network for automatic detection of butterfly species using color and texture features,” *Vis. Comput.*, vol. 30, no. 1, pp. 71–79, 2014.
- [10] L. Zhu and P. Spachos, “Butterfly classification with machine learning methodologies for an android application,” in *2019 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2019, pp. 1–5.
- [11] I. Nurhaida, R. A. M. Zen, V. Ayumi, and H. Wei, “Determining the Number of Batik Motif Object based on Hierarchical Symmetry Detection Approach,” *Indones. J. Electr. Eng. Informatics*, vol. 9, no. 1, pp. 141–152, 2021.
- [12] V. Ayumi, “Application of Machine Learning for SARS-CoV-2 Outbreak,” *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 5, pp. 241–248, Oct. 2021.
- [13] D. Ramayanti *et al.*, “Tuberculosis Ontology Generation and Enrichment Based Text Mining,” in *2020 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2020, pp. 429–434.
- [14] B. Ramalingam, A. K. Lakshmanan, M. Ilyas, A. V. Le, and M. R. Elara, “Cascaded machine-learning technique for debris classification in floor-cleaning robot application,” *Appl. Sci.*, vol. 8, no. 12, p. 2649, 2018.
- [15] P. Hridayami, I. K. G. D. Putra, and K. S. Wibawa, “Fish species recognition using VGG16 deep convolutional neural network,” *J. Comput. Sci. Eng.*, vol. 13, no. 3, pp. 124–130, 2019.
- [16] B. Zoph, V. Vasudevan, J. Shlens, and Q. V Le, “Learning transferable architectures for scalable image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 8697–8710.