

Human Skin Disease Detection using Convolutional Neural Network Method with Hyperparameter Tuning to Determine the Best Parameter Combination

Deteksi Penyakit Kulit Manusia Menggunakan Metode Convolutional Neural Network Dengan Hyperparameter Tuning Untuk Menentukan Kombinasi Parameter Terbaik

Riki Martua Aritonang¹, Mangaras Yanu Florestiyanto², Bambang Yuwono³

^{1,2,3} Informatika, Universitas Pembangunan Nasional Veteran Yogyakarta, Indonesia

^{1*} 123180028@student.upnyk.ac.id, ² mangaras.yanu@upnyk.ac.id, ³ bambangy@upnyk.ac.id

*: *Penulis korespondensi (corresponding author)*

Informasi Artikel

Received: February 2023

Revised: -

Accepted: May 2023

Published: June 2023

Abstract

Purpose: Obtaining the best hyperparameter combination for optimization of the Convolutional Neural Network method, for classifying skin diseases.

Design/methodology/approach: Using the CNN method with hyperparameter tuning in determining the best hyperparameter combination. System development is performed with the Python programming language.

Findings/result: The best combination of hyperparameter tuning results is RMSprop optimizer, APL dropout value is 0.05, dropout is 0.5, dense layer is 64, and produces an accuracy of 97,81%.

Originality/value/state of the art: This study has differences in terms of the types of skin diseases classified, the architecture of the CNN model, the hyperparameters tested and the combination results obtained compared to previous studies.

Abstrak

Tujuan: Mendapatkan kombinasi hyperparameter terbaik untuk optimasi metode Convolutional Neural Network, untuk pengklasifikasian penyakit kulit.

Perancangan/metode/pendekatan: Menggunakan metode CNN dengan hyperparameter tuning dalam menentukan kombinasi hyperparameter terbaik. Pengembangan sistem dilakukan dengan bahasa pemrograman python.

Hasil: Kombinasi terbaik dari hasil hyperparameter tuning yaitu RMSprop optimizer, nilai APL dropout 0,05, dropout 0,5, dense layer 64, dan menghasilkan akurasi 97,81%.

Keaslian/ state of the art: Penelitian ini memiliki perbedaan dalam hal jenis penyakit kulit yang diklasifikasikan,

Keywords: Hyperparameter Tuning, Skin Disease, CNN
Kata kunci: Hyperparameter Tuning, Penyakit Kulit, CNN

arsitektur model CNN, hyperparameter yang diuji dan hasil kombinasi yang diperoleh dibanding dengan penelitian sebelumnya.

1. Pendahuluan

Kulit merupakan bagian terluar tubuh manusia yang melapisi dan melindungi seluruh bagian organ tubuh pada manusia, pengatur suhu tubuh, dan termasuk ke dalam salah satu panca indra manusia untuk meraba [1]. Menduduki posisi ketiga dari tujuh besar penyakit yang menular langsung se Indonesia tahun 2021, seharusnya penyakit kulit tidak bisa dianggap sebelah mata. Beberapa faktor eksternal yang menyebabkan penyakit kulit yaitu Kurangnya kesadaran akan kebersihan lingkungan, iklim, perubahan udara yang ekstrim, dan alergi terhadap sesuatu [2]. Di zaman yang modern ini, sistem identifikasi penyakit kulit berbasis pemrosesan citra digital adalah solusi alat yang dapat digunakan oleh profesional kesehatan sebagai alat bantu untuk menentukan diagnosis penyakit kulit. Metode identifikasi ini memungkinkan pasien untuk menerima pengobatan yang tepat dalam waktu yang relatif singkat dan meminimalkan penularan penyakit kepada orang sekitar.

Pengolahan citra bukanlah hal baru dalam dunia teknologi, karena citra merupakan salah satu informasi yang dapat di olah komputer. Di bidang kedokteran juga menerapkan pengolahan citra dalam mengidentifikasi penyakit. Penelitian terkait klasifikasi penyakit kulit manusia menggunakan algoritma C4.5 diperoleh accuracy 94,7%, precision 94,9% dan recall sebesar 94,7%, akurasi algoritma C4.5 akan membutuhkan data training yang lebih banyak jika ingin mendapatkan akurasi yang tinggi [3]. Penelitian klasifikasi citra penyakit kulit yang menggunakan algoritma Naïve Bayes berdasarkan tekstur citra menghasilkan nilai akurasi yang tidak terlalu tinggi yaitu 73,33% [4]. Berdasarkan penelitian klasifikasi penyakit kulit diatas algoritma C4.5 memiliki kelemahan yaitu membutuhkan waktu yang lama untuk data yang banyak dan Naïve Bayes yang keakuratannya membutuhkan bukti-bukti lain untuk membuktika kebenarannya, karena tidak bisa diukur dengan satu perobabilitas saja dan variabel independen membuat berkurangnya akurasi.

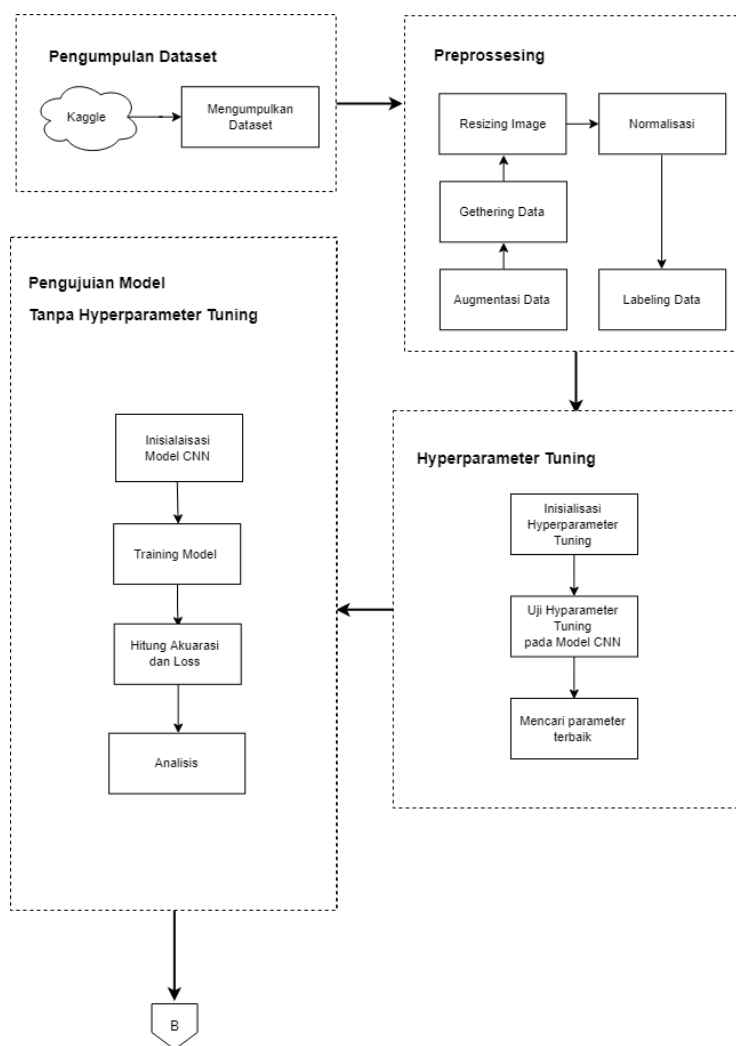
Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) untuk pengklasifikasian citra. CNN merupakan salah satu teknik pembelajaran yang digunakan untuk mengatasi kekurangan dari metode sebelumnya. Teknik ini dapat mengelola perubahan dalam posisi gambar seperti rotasi, skala, dan translasi, serta mengurangi jumlah parameter independen [5]. Dibandingkan dengan pendekatan lain, metode ini memiliki tingkat akurasi yang baik dalam pengolahan citra [6].

Penelitian terkait klasifikasi citra menggunakan Metode CNN yang mendeteksi penyakit kulit pada wajah dengan dateset sebanyak 129 citra berukuran 200×200 piksel dan empat class yaitu melanoma, Hemangioma, psoriasis, dan ringworm menghasilkan akurasi sebesar 85,71% [7]. Penelitian lainnya terkait klasifikasi citra dengan menerapkan metode CNN melakukan klasifikasi citra dengan metode CNN dan algoritma optimasi yang yang berbeda menggunakan 800 datasat citra. Algoritma optimasi yang digunakan yaitu Stochastic Gradient Descent (SGD), Adadelta, dan Adam yang menghasilklakan akurasi secara berturut turut 63%,82 % dan 83%. menunjukkan setiap algoritma optimasi memiliki perbedaan akurasi yang cukup signifikan terhadap arsitektur model yang dibuat [8].

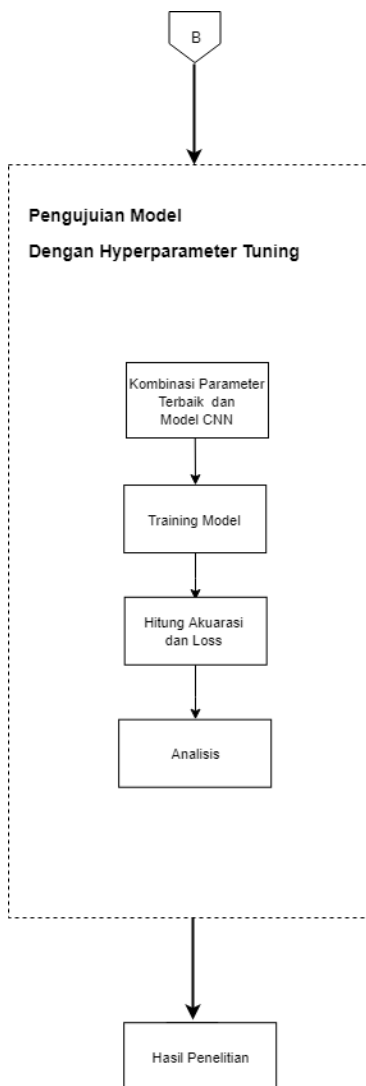
Pada bidang image processing, CNN merupakan metode yang diklaim cukup baik dalam pengenalan citra. hal tersebut dikarenakan CNN berusaha meniru sistem pengenalan citra [9]. Sehingga pada penelitian ini akan dilakukan optimasi pengklasifikasian dengan metode CNN dengan *hyperparameter tuning* agar mendapatkan hasil yang lebih optimal dengan 3 jenis penyakit kulit yaitu eczema, seboroik keratosis, melanocytic nevi.

2. Metode Penelitian

Penelitian ini dilakukan secara sistematis dan bertahap dari pencarian dataset di lanjutkan dengan preprocessing dan perancangan model arsitektur CNN sebagai metode yang digunakan untuk medeteksi penyakit kulit. Data yang digunakan dataset skunder dari kaggle dengan metode kualitatif eksperimental. Tahapan diilustrasikan pada gambar Gambar 1 dan 2.



Gambar 1. Metode Penelitian




Gambar 2. Lanjutan Metode Penelitian

2.1. Pengumpulan Dataset

Penelitian ini menggunakan data skunder yang di kumpulkan dari beberapa dataset yang bersumber dari website kaggle. Data yang ada dikumpulkan menjadi satu dataset yang berjudul Dataset Skin Disease. Dari data yang berjumlah 1605 dengan format citra jpg memiliki tiga jenis kelas yang berbeda yaitu Eczema, Keratosis, dan Melanocytic Nevi.

Data ini di susun oleh penulis dengan mengumpulkan dari dua sumber data kaggle yaitu Face Skin Diseases yang di buat oleh Amellia Mega pada Mei 2022 dan Skin Diseases Dataset yang di buat oleh Ammar Abasi pada Mei 2022. Dari kedua sumber dataset tersebut diseleksi menjadi tiga data penyakit yang di upload kembali oleh penulis ke keggel dengan judul Dataset Skin Diseases. Citra kelas pada dataset dapat dilihat pada Gambar 3.



Gambar 3. Penyakit Kulit Manusia (a) Eczema. (b) Seboroik Keratosis. (c) Melanocytic Nevi.

2.2. Preprocessing

Tahapan preprocessing merupakan tahapan yang dilakukan untuk mempersiapkan data sebelum data digunakan dalam tahap selanjutnya [15]. Tahapan preprocessing yang dilakukan adalah normalisasi, labeling data dan augmentasi. Tahapan preprocessing ini menerima input berupa dataset yang nantinya akan digunakan untuk tahapan *hyperparameter tuning* dan pengujian model.

2.2.1. Augmentasi Data

Augmentasi data merupakan proses memodifikasi jumlah data dengan membuat program mengenali data yang ada adalah data yang berbeda, sehingga diharapkan tidak terjadinya overfitting, membantu penelitian dengan jumlah data yang sedikit dan dapat meningkatkan kinerja model [11]. Proses augmentasi data yang dilakukan pada penelitian ini adalah dengan rotasi gambar sebesar 30 derajat, melakukan zoom atau memeperbesar gambar sebesar 10%, melakukan shifting atau pergeseran sebesar 10% pada lebar dan tinggi gambar dan membalik gambar secara horizontal. Hasil augmentasi gambar seperti pada Gambar 4.



Gambar 4. Augmentasi Data

Setelah dilakukan augmentasi dengan 5 jenis augmentasi dan batch size 32, jumlah data yang awalnya 1605 dataset menjadi 6905 dataset citra.

2.2.2. Gethering Data


Gethering data bertujuan untuk menggabungkan data yang berasal dari kaggle, data disimpan ke sebuah variable yang berisi direktori dari data training, validation dan testing yang nantinya dapat digunakan pada tahapan berikutnya. Berikut merupakan jumlah dari hasil penggabungan dataset.

Tabel 1. Rincian Dataset

No.	Nama	Jenis	Jumlah
1.	Citra Eczema	Training	1705
2.	Citra Seboroik Keratosis	Training	1766
3	Citra Melanocytic Nevi	Training	2052
4	Citra Eczema	Validation	213
5	Citra Seboroik Keratosis	Validation	220
6	Citra Melanocytic Nevi	Validation	256

2.2.3. Image Resizing

Tahapan *image resizing* yang bertujuan untuk menyamakan ukuran citra yang berbeda-beda, Resizing merupakan proses merubah ukuran dari resolusi citra, baik memperkecil maupun memperbesar ukuran citra. Pada umumnya resized cita bertujuan untuk memperbaiki citra menjadi sehalus mungkin dengan pemetaan dari sumber citra ke citra telah berubah ukurannya [16]. Pada penelitian ini semua citra diubah menjadi 128×128 piksel.



Gambar 5. Proses Image Resizing

2.2.4. Normalisasi

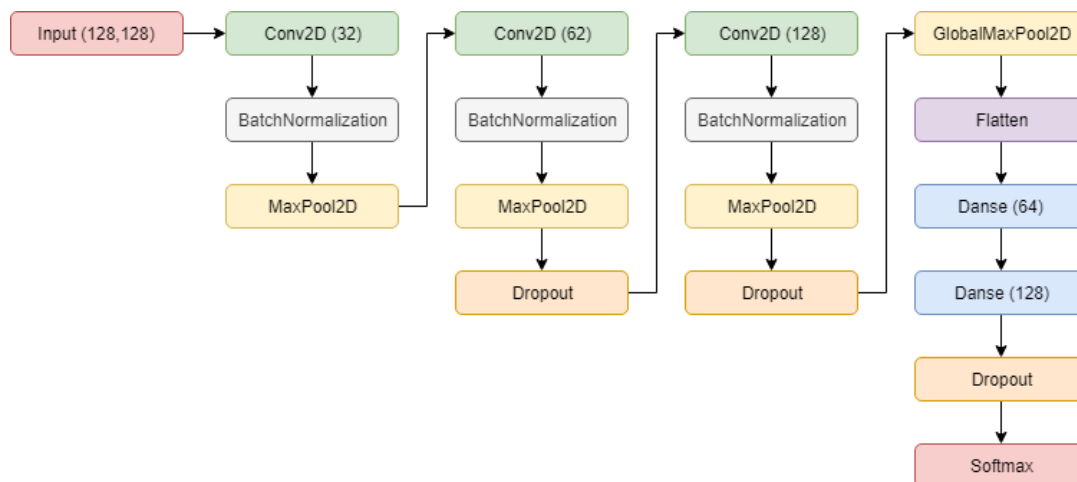
Normalisasi diterapkan untuk mempercepat konvergensi pada tahap training dengan menyamaratakan ukuran piksel gambar [10]. Normalisasi pada penelitian ini menerapkan fitur bernama *rescale* yang bertujuan untuk meningkatkan akurasi dan mengurangi loss pada tahap training data [11]. Normalisasi data dilakukan dimana setiap piksel yang memiliki range 0-255 akan dinormalisasi menjadi range 0-1.

2.2.5. Labeling Data

Labeling adalah proses pemberian identitas pada citra yang membantu model untuk classifikasi citra dan meningkatkan atau memperbaiki akurasi klasifikasi [12]. Pada penelitian ini labeling dilakukan menjadi 3 kategori yang berbeda yaitu Eczeme, Seboroik Keratosis dan Melanocytic Nevi.

2.3. Arsitektur Model

Rancangan model CNN pada penelitian ini terdiri dari input layer, convolutional layer, pooling layer, dropout layer, batch normalization dan fully connected layer. Filter yang digunakan pada convolution layer memiliki nilai (32, 64, 128), ukuran kernel yang akan digunakan adalah (3, 3), stride bernilai 1 dan padding memiliki nilai *same*, dan activation adalah softmax. Layer dropout akan dibagi menjadi dua bagian yaitu sebelum pooling dan setelah layer pooling. Arsitektur model CNN pada penelitian ini dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur Model CNN

2.4. Hyperparameter Tuning

Parameter dalam algoritma *deep learning* sangat signifikan berdampak pada model CNN, dengan itu *hyperparameter tuning* memiliki peranan yang penting dalam machine learning pada algoritma deep learning [13]. Parameter-parameter yang di ujikan kecaru satu persatu dengan atribut seperti pada Table 2.

Tabel 2. Parameter-Parameter Pembeding yang Akan di Uji Coba

No.	Hyperparameter	Parameter
1.	Optimizer	Adam, Adamax, SGD, RMSProp
2.	Convolutional Layer	3
3.	Dropout setelah pooling layer (APL Dropout)	0.05, 0,1
4.	Dropout fully connected layer (Dropout)	0.25, 0,1
5.	Dense layer	64, 128

3. Hasil dan Pembahasan


Hasil penelitian ini dilakukan dengan beberapa tahapan yaitu uji *hyperparameter tuning* terhadap model CNN, dan mengetahui pengaruh *hyperparameter tuning* terhadap hasil pengklasifikasian model CNN yang telah dibuat dengan 2 skenario. Rincian skenario yang akan dilakukan pada penlitian ini dapat dilihat pada Table 3.

Tabel 3. Skenario pengujian

No.	Skenario
1.	Model CNN tanpa <i>hyperparameter tuning</i>
2.	Model CNN dengan <i>hyperparameter tuning</i>

3.1. Hasil Pengujian Model CNN Tanpa Hyperparameter Tuning

Hasil pegujian skenario pertama model CNN yang dibuat seperti pada Gambar 5 tanpa hyperpatameter tuning. Pengujian yang dilakukan dengan optimizer Adamax, APL Dropout 0,05, dropout 0,25, dan dense layer 128. Pada proses training dilakukan dengan 100 epoch dan 40 batch size. Hasil dari skenario pertama dapat dilihat pada Gambar 6.



Gambar 6. Hasil Akurasi dan Loss Tanpa Hypertparameter Tuning

Berdasarkan hasil training yang dilakukan tanpa menggunakan *hyperparameter tuning* menghasilkan akurasi sebesar 91,63%.

3.2. Hasil Hyperparameter Tuning


Hasil pengujian *hyperparameter tuning* terhadap model CNN yang di usulkan menghasilkan 32 kombinasi parameter, sehingga didapatkan akurasi tertinggi dengan nilai akurasi sebesar 81,25. Hasil 5 *hyperparameter tuning* terbaik dapat dilihat pada Tabel 3.

Tabel 3. Parameter Terbaik dari Hyperparameter Tuning

No.	Optimizer	Convolutional Layer	APL Dropout layer	Dense Layer	Dropout layer	Akurasi
1.	RMSprop	3 Layer	0,05	64	0,5	81,25%
2.	RMSprop	3 Layer	0,1	128	0,5	79,37%
3.	RMSprop	3 Layer	0,05	64	0,25	73,75 %
4.	SGD	3 Layer	0,1	64	0,25	70,00%
5.	Adam	3 Layer	0,05	64	0,25	68,75 %

3.3. Hasil Pengujian Model CNN Dengan Hyperparameter Tuning

Hasil pegujian skenario kedua model CNN yang dibuat seperti pada Gambar 7 denagn hyperpatameter tuning. Pengujian yang dilakukan dengan optimizer RMSProp, APL Dropout 0,05, dan dense layer 64. Pada proses training dilakukan dengan 100 epoch dan 40 batch size. Hasil dari skenario pertama dapat dilihat pada Gambar 7.



Gambar 7. Hasil Akurasi dan Loss Dengan Hypertparameter Tuning

Berdasarkan hasil training yang dilakukan dengan menggunakan hyperparameter tuning menghasilkan akurasi sebesar 97,81%. Berdasarkan gambar 7 menghasilkan visualisasi yang menunjukkan bahwa dengan kombinasi tersebut menghasilkan model yang lebih stabil dalam hal akurasi dan loss dari model. Hasil training juga menunjukkan performa yang baik dari model yang menerapkan *hyperparameter tuning*.

3.4. Hasil dan Analisis

Berdasarkan hasil penelitian dari setiap skenario yang dilakukan terdapat beberapa perbedaan pada hasil confusion matriks yang dapat dilihat pada Tabel 4.

Tabel 4. Parameter Terbaik dari Hyperparameter Tuning

Model	Confusion Matriks (Average Macro)		
	Accuracy	Precision	Recall
Skenario 1	91,63	0,93	0,90
Skenario 2	97,81	0,97	0,96

Berdasarkan hasil penelitian pada table 4 menunjukkan kenaikan akurasi dan sebesar 6,18%, pada precision dan recall juga mengalami kenaikan persentase. Kenaikan persentase confusion matriks dari skenario 1 dan skenario 2 menunjukkan bahwa model dengan *hyperparameter tuning* menunjukkan kinerja yang lebih baik [14].

4. Kesimpulan dan Saran

Berdasarkan hasil penelitian deteksi citra penyakit kulit manusia ini, didapatkan kombinasi *hyperparameter* terbaik yaitu 3 *convolutional layer*, 0,05 *APL dropout*, 0,5 *dropout layer*, 64 *dense layer* dan optimizer RMSProp. persentase akurasi dari skenario 1 tanpa *hyperparameter tuning* menghasilkan akurasi 91,63% dan skenario 2 menggunakan *hyperparameter tuning* dengan akurasi 97,81%. Penggunaan hyperparameter yang tepat dapat menjadikan model CNN memiliki kualitas klasifikasi yang baik. Hasil pengujian model, didapatkan bahwa hyperparameter yang tepat mempengaruhi kualitas model CNN, sehingga dibutuhkan analisis terlebih dahulu terhadap kombinasi hyperparameter yang digunakan. Dan juga dengan pemilihan augmentasi data yang baik dapat mempengaruhi akurasi dari sebuah model dalam melakukan klasifikasi.

Saran untuk penelitian kedepannya diharapkan dapat menggunakan kombinasi *hyperparameter* yang berbeda lainnya seperti *learning rate*, *learning rule*, *batch size*. Dikarenakan sulitnya mendapatkan dataset citra penyakit kulit, maka penelitian kedepannya disarankan dapat memperbanyak jenis penyakit kulit manusia yang berbeda lainnya untuk dideteksi seperti penyakit herpes, penyakit eksim, penyakit psoriasis, penyakit kurap yang lebih sering dialami orang awam.

Pada pengujian sistem terkait gambar yang akan di uji, diharapkan dapat mencoba teknik augmentasi data lainnya yang lebih baik untuk hasil klasifikasi yang lebih baik pula, serta dapat dibantu dengan kualitas citra yang tinggi untuk citra data training model, dan citra yang akan dilakukan untuk penujian sistem.

Daftar Pustaka

- [1] Hanin, M. A., Patmasari, R. and Nur, R. Y. (2021) ‘Sistem Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (CNN)’, 8(1), pp. 273–281.
- [2] Permadi, O. (2021) Profil Kesehatan Indonesia 2020, IT - Information Technology. doi: 10.1524/itit.2006.48.1.6.
- [3] Prajarini, D. et al. (2016) ‘Perbandingan Algoritma Klasifikasi Data Mining Untuk Prediksi Penyakit Kulit’, *Informatics Journal*, 1(3), p. 137.
- [4] Hafisah, I. S. and Andono, P. N. (2015) ‘Deteksi Otomatis Penyakit Kulit Menggunakan Algoritma Naive Bayes’, *Jurnal Kesehatan*, (5), pp. 1–6.
- [5] Leelavathy S, Jaichandran R, Shobana R, Vasudevan, S. S. P. and N. (2020) ‘Skin Disease Detection Using Computer Vision and Machine Learning Technique’, *European Journal of Molecular & Clinical Medicine*, 7(4), pp. 2999–3003.
- [6] Nurkhasanah, N. and Murinto, M. (2022) ‘Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network’, *Sainteks*, 18(2), p. 183. doi: 10.30595/sainteks.v18i2.13188.
- [7] Kurniawan, I. (2019) ‘Implementasi Convolutional Neural Network dalam Mengidentifikasi Penyakit Kulit’, *Repositori Institusi USU*.
- [8] Irfan, D. et al. (2022) ‘Perbandingan Optimasi Sgd, Adadelta, Dan Adam Dalam Klasifikasi Hydrangea Menggunakan CNN’, *Journal of Science and Social Research*, 4307(June), pp. 244–253.
- [9] Suartika, I Wayan, Wijaya Arya Yudhi, S. R. (2016) ‘Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101’, *Jurnal Teknik ITS*, 5(1), p. 76.
- [10] Masykur, F., Setyawan, M. B. and Winangun, K. (2022) ‘Epoch Optimization on Rice Leaf Image Classification Using Convolutional Neural Network (CNN) MobileNet’, *CESS (Journal of Computer Engineering, System and Science)*, 7(2), p. 581. doi: 10.24114/cess.v7i2.37336.
- [11] Minarno, A. E. et al. (2021) ‘Convolutional Neural Network with Hyperparameter Tuning for Brain Tumor Classification’, *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 4. doi: 10.22219/kinetik.v6i2.1219.
- [12] Wu, J. et al. (2019) ‘Hyperparameter optimization for machine learning models based on Bayesian optimization’, *Journal of Electronic Science and Technology*, 17(1), pp. 26–40. doi: 10.11989/JEST.1674-862X.80904120.
- [13] Aszemi, N. M. and Dominic, P. D. D. (2019) ‘Hyperparameter optimization in convolutional neural network using genetic algorithms’, *International Journal of Advanced Computer Science and Applications*, 10(6), pp. 269–278. doi: 10.14569/ijacsa.2019.0100638.
- [14] Hong, C. S. and Oh, T. G. (2021) ‘TPR-TNR plot for confusion matrix’, *Communications for Statistical Applications and Methods*, 28(2), pp. 161–169. doi:

10.29220/CSAM.2021.28.2.161

- [15] Polat, K. and Onur Koc, K. (2020) ‘Detection of Skin Diseases from Dermoscopy Image Using the combination of Convolutional Neural Network and One-versus-All’, *Journal of Artificial Intelligence and Systems*, 2(1), pp. 80–97. doi: 10.33969/ais.2020.21006.
- [16] Zelinsky, A. (2009) *Learning OpenCV---Computer Vision with the OpenCV Library (Bradski, G.R. et al.; 2008)[On the Shelf]*, *IEEE Robotics & Automation Magazine*. doi: 10.1109/mra.2009.933612.