



Improved Convolutional Neural Network dengan Transfer Learning dan Hyperparameter Tuning untuk peningkatan akurasi klasifikasi Citra Kanker Kulit

Ega Wahyu Andani^{1,*}, Solikhun², Timbo Faritcan P. Siallagan³

¹ Information System, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

² Informatics Engineering, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

³ Engineering, Universitas Mandiri, Subang, Indonesia

Email: ^{1,*}egawahyuandani8@gmail.com, ²solikhun@amiktunasbangsa.ac.id, ³timbofaritcansiallagan@gmail.com

Email Penulis Korespondensi: egawahyuandani8@gmail.com

Abstrak—Kanker kulit merupakan salah satu penyakit yang memerlukan deteksi dini untuk meningkatkan peluang keberhasilan pengobatan. Pemanfaatan kecerdasan buatan, khususnya Deep Learning, menjadi alternatif yang efektif dalam membantu proses klasifikasi citra kanker kulit secara otomatis. Namun, tingginya ketidakseimbangan kelas dan kemiripan visual antarjenis lesi pada dataset kanker kulit masih menjadi tantangan dalam memperoleh performa klasifikasi yang optimal. Penelitian ini bertujuan meningkatkan akurasi klasifikasi citra kanker kulit menggunakan Improved Convolutional Neural Network berbasis Transfer Learning dan Hyperparameter Tuning. Dataset yang digunakan adalah HAM10000 yang terdiri dari 10.015 citra dermatoskopi dengan tujuh kelas diagnosis. Arsitektur yang digunakan adalah MobileNetV2 sebagai feature extractor yang dikombinasikan dengan custom classification head. Proses pelatihan dilakukan menggunakan strategi transfer learning dua fase, yaitu fase pembekuan backbone dan fase fine-tuning. Untuk mengatasi ketidakseimbangan kelas diterapkan class weighting dan data augmentation, sedangkan optimasi model dilakukan menggunakan grid search terhadap parameter learning rate, ukuran dense layer, dan dropout rate. Evaluasi kinerja model menggunakan metrik akurasi, precision, recall, F1-score, dan Area Under Curve (AUC). Hasil penelitian menunjukkan bahwa model yang diusulkan memperoleh akurasi pengujian sebesar 85,50%, akurasi validasi sebesar 84,75%, macro F1-score sebesar 83,14%, dan mean AUC sebesar 0,94. Hasil tersebut menunjukkan bahwa kombinasi Transfer Learning dua fase dan Hyperparameter Tuning mampu meningkatkan performa MobileNetV2 dalam klasifikasi citra kanker kulit. Kontribusi penelitian ini adalah menghasilkan model klasifikasi yang memiliki akurasi tinggi, efisien secara komputasi, serta mampu menangani ketidakseimbangan kelas pada dataset HAM10000.

Kata Kunci: Kanker Kulit; Deep Learning; Convolutional Neural Network; Transfer Learning; MobileNetV2; Hyperparameter Tuning

Abstract—Skin cancer is one of the diseases that requires early detection to increase the likelihood of successful treatment. The use of artificial intelligence, particularly Deep Learning, has become an effective alternative in assisting the automatic classification of skin cancer images. However, the high class imbalance and visual similarity between lesion types in skin cancer datasets remain challenges in achieving optimal classification performance. This study aims to improve the accuracy of skin cancer image classification using an Improved Convolutional Neural Network based on Transfer Learning and Hyperparameter Tuning. The dataset used is HAM10000, consisting of 10,015 dermoscopy images across seven diagnostic classes. The architecture employed is MobileNetV2 as a feature extractor combined with a custom classification head. The training process was carried out using a two-phase transfer learning strategy, namely the backbone freezing phase and the fine-tuning phase. To address class imbalance, class weighting and data augmentation were applied, while model optimization was performed using grid search over the parameters of learning rate, dense layer size, and dropout rate. Model performance was evaluated using accuracy, precision, recall, F1-score, and Area Under Curve (AUC) metrics. The results show that the proposed model achieved a test accuracy of 85.50%, a validation accuracy of 84.75%, a macro F1-score of 83.14%, and a mean AUC of 0.94. These results indicate that the combination of two-phase Transfer Learning and Hyperparameter Tuning is capable of improving the performance of MobileNetV2 in skin cancer image classification. The contribution of this research is the development of a classification model that achieves high accuracy, is computationally efficient, and is capable of handling class imbalance in the HAM10000 dataset.

Keywords: Skin Cancer; Deep Learning; Convolutional Neural Network; Transfer Learning; MobileNetV2; Hyperparameter Tuning

1. PENDAHULUAN

Kanker kulit merupakan salah satu jenis kanker yang paling umum terjadi di dunia dan jumlah kasusnya terus meningkat setiap tahun. Organisasi kesehatan dunia melaporkan bahwa deteksi dini kanker kulit sangat penting karena dapat meningkatkan peluang kesembuhan pasien secara signifikan. Namun, proses diagnosis secara manual melalui pemeriksaan dermatoskopi membutuhkan keahlian khusus dan sering kali menghadapi tantangan berupa kemiripan visual antarjenis lesi kulit[2]-[3]. Perkembangan teknologi kecerdasan buatan, khususnya Deep Learning, telah memberikan solusi yang menjanjikan dalam membantu proses klasifikasi citra medis secara otomatis dengan tingkat akurasi yang tinggi.

Convolutional Neural Network (CNN) merupakan salah satu metode Deep Learning yang banyak digunakan dalam pengolahan citra karena kemampuannya dalam mengekstraksi fitur secara otomatis tanpa memerlukan rekayasa fitur manual[4]-[5]. Berbagai penelitian menunjukkan bahwa CNN mampu memberikan performa yang baik pada tugas klasifikasi kanker kulit. Namun, performa CNN sangat dipengaruhi oleh jumlah data pelatihan yang besar dan proses optimasi parameter yang tepat. Untuk mengatasi keterbatasan tersebut, pendekatan Transfer Learning banyak diterapkan dengan memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar, sehingga proses pembelajaran menjadi lebih efektif dan efisien[6], [7], [8].



Berbagai metode telah digunakan untuk klasifikasi kanker kulit, mulai dari metode machine learning seperti Support Vector Machine (SVM) dan Random Forest hingga metode deep learning seperti Convolutional Neural Network (CNN), ResNet, EfficientNet, dan MobileNetV2. Metode deep learning umumnya mampu memberikan performa yang lebih baik karena dapat mempelajari karakteristik citra secara otomatis. Namun, setiap arsitektur memiliki kelebihan dan keterbatasan masing-masing sehingga masih diperlukan strategi yang tepat untuk meningkatkan akurasi klasifikasi.

Beberapa penelitian terdahulu telah menerapkan Transfer Learning pada klasifikasi kanker kulit menggunakan berbagai arsitektur jaringan. Harangi menggunakan CNN Ensemble dan memperoleh akurasi sebesar 82,50%, sedangkan Kassem et al. menerapkan MobileNetV2 dengan pendekatan single-phase finetuning dan memperoleh akurasi 82,17%[1], [9]. Hasan et al. menggunakan ResNet50 berbasis fine-tuning dengan akurasi 84,20%, sementara Gessert et al. memanfaatkan EfficientNet dan teknik augmentasi data yang menghasilkan akurasi 87,30%[10]. Meskipun berbagai penelitian telah menunjukkan hasil yang baik, sebagian besar penelitian masih menggunakan strategi fine-tuning satu tahap atau hanya berfokus pada pemilihan arsitektur tanpa mengoptimalkan kombinasi transfer learning dan hyperparameter tuning secara sistematis. Oleh karena itu, masih terdapat research gap yang dapat dimanfaatkan untuk meningkatkan performa klasifikasi kanker kulit.

Permasalahan utama dalam penelitian ini adalah tingginya ketidakseimbangan kelas (class imbalance) pada dataset HAM10000 yang terdiri dari tujuh jenis lesi kulit, sehingga model berpotensi mengalami bias terhadap kelas mayoritas. Selain itu, kemiripan karakteristik visual antar beberapa jenis lesi menyebabkan proses klasifikasi menjadi lebih kompleks. Oleh karena itu, diperlukan pendekatan yang mampu meningkatkan kemampuan generalisasi model sekaligus mempertahankan efisiensi komputasi.

Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi citra kanker kulit menggunakan Improved Convolutional Neural Network berbasis Transfer Learning dengan arsitektur MobileNetV2 dan Hyperparameter Tuning. Dataset yang digunakan adalah HAM10000 yang terdiri dari 10.015 citra dermatoskopi yang terbagi ke dalam tujuh kelas diagnosis. Proses penelitian meliputi tahap praproses data, augmentasi data, pembobotan kelas (class weighting), pelatihan model menggunakan strategi transfer learning dua fase, serta hyperparameter tuning dengan metode grid search. Parameter yang dioptimasi meliputi learning rate, ukuran dense layer, dan dropout rate. Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, F1-score, dan Area Under Curve (AUC) untuk mengukur kinerja klasifikasi secara komprehensif.

Kontribusi penelitian ini adalah mengembangkan model Improved Convolutional Neural Network berbasis MobileNetV2 yang mengintegrasikan strategi transfer learning dua fase dengan optimasi hyperparameter menggunakan Grid Search. Selain itu, penelitian ini menerapkan class weighting dan data augmentation untuk mengatasi ketidakseimbangan kelas sehingga diharapkan mampu meningkatkan akurasi klasifikasi citra kanker kulit dibandingkan pendekatan sebelumnya.

2. METODOLOGI PENELITIAN

Sebagai upaya untuk menghadirkan solusi deteksi dini klinis yang akurat, penelitian ini mengembangkan sebuah sistem klasifikasi citra penyakit dan kanker kulit yang berbasis pada pendekatan Improved Convolutional Neural Network (CNN). Strategi utama yang diusulkan dalam penelitian ini adalah mengadopsi arsitektur MobileNetV2 melalui pendekatan Transfer Learning, yang kemudian diperkuat dengan proses Hyperparameter Tuning guna mencari konfigurasi model yang paling superior. Formulasi tahapan dalam penelitian ini dirancang secara ketat dan sistematis untuk memastikan bahwa model yang dihasilkan tidak hanya unggul secara teoritis, tetapi juga memiliki sensitivitas dan spesifisitas yang tinggi saat mengklasifikasikan tujuh variasi lesi kulit patologis yang terdapat di dalam dataset HAM10000. Jika ditinjau dari alur kerjanya, penelitian ini mengonstruksikan sebuah peta jalan (roadmap) eksperimen yang menyeluruh. Alur tersebut diinisiasi oleh tahap persiapan dan praproses data citra digital untuk meningkatkan kualitas visual input. Langkah ini kemudian diikuti dengan perancangan arsitektur model modifikasi, serta proses pelatihan intensif yang menerapkan strategi transfer learning dua fase yakni ekstraksi fitur awal dan dilanjutkan dengan fine-tuning parsial. Selanjutnya, fase optimasi hyperparameter diimplementasikan untuk meminimalkan nilai kerugian (loss value) pada model. Rangkaian penelitian ini kemudian diakhiri dengan evaluasi kinerja model secara mendalam untuk mengukur sejauh mana sistem yang dikembangkan mampu mengenali karakteristik visual dari setiap jenis kanker kulit secara presisi..


2.1. Dataset dan Praproses Data

Dataset yang digunakan dalam penelitian ini adalah HAM10000 (Human Against Machine with 10,000 Training Images) yang terdiri atas 10.015 citra dermatoskopi berwarna dengan tujuh kategori diagnosis lesi kulit. Untuk memperoleh distribusi data yang seimbang pada setiap tahap pelatihan, dataset dibagi menggunakan metode stratified sampling menjadi data latih sebesar 70% (7.010 citra), data validasi sebesar 15% (1.502 citra), dan data uji sebesar 15% (1.503 citra)[18]-[20].

Sebelum digunakan pada proses pelatihan, seluruh citra mengalami tahap praproses. Setiap gambar diubah ukurannya menjadi 224×224 piksel agar sesuai dengan spesifikasi masukan arsitektur MobileNetV2, kemudian dilakukan normalisasi nilai piksel ke dalam rentang 0–1 untuk mempercepat proses konvergensi model. Selain itu, atribut



usia yang memiliki 57 data kosong diimputasi menggunakan nilai median sehingga tidak mengurangi jumlah sampel yang tersedia.



Gambar 1. Tahapan Penelitian

2.1.1 Dataset HAM10000

Penelitian menggunakan dataset HAM10000 yang terdiri dari 10.015 citra dermatoskopi (citra kulit hasil pemeriksaan dermatoskop) yang terbagi ke dalam 7 kelas lesi kulit berbeda (misalnya melanoma, nevus, basal cell carcinoma, dan jenis lesi lainnya).

2.1.2 Praproses Data

Seluruh citra di-*resize* menjadi ukuran 224×224 piksel agar sesuai dengan input arsitektur MobileNetV2, dilakukan normalisasi nilai piksel, serta penanganan (imputasi) terhadap citra yang rusak atau korup agar tidak mengganggu proses pelatihan.



2.1.3 Augmentasi Data & Class Weighting

Untuk mengatasi keterbatasan jumlah data dan ketidakseimbangan antar kelas, dilakukan augmentasi *online* berupa rotasi, *flip*, *shift*, *zoom*, dan perubahan *brightness*. Selain itu, dihitung bobot kelas (*class weighting*) agar model tidak bias terhadap kelas yang dominan, mirip seperti fungsi SMOTE pada penelitian stroke sebelumnya namun dengan pendekatan berbeda.

2.1.4 Pembagian Data (Stratified Split)

Dataset dibagi secara *stratified* menjadi tiga bagian: data latih 70% (7.010 citra), data validasi 15% (1.502 citra), dan data uji 15% (1.503 citra). Pembagian *stratified* memastikan proporsi tiap kelas tetap terjaga di ketiga subset.

2.1.5 Arsitektur Model

Model menggunakan MobileNetV2 yang sudah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet sebagai *backbone*, ditambah lapisan klasifikasi khusus (*custom classification head*) yang terdiri dari *Global Average Pooling*, *Dense layer*, *Dropout*, dan *Softmax* untuk menghasilkan probabilitas 7 kelas lesi kulit.

2.1.6 Transfer Learning Dua Fase

Pelatihan dilakukan dalam dua fase:

- Fase 1 (Epoch 1–10): *Backbone* MobileNetV2 dibekukan (*frozen*, *trainable=False*), hanya melatih bagian *classification head* dengan *learning rate* 1×10^{-3} .
- Fase 2 (Epoch 11–25): Sebagian lapisan atas *backbone* dibuka (*fine-tuning*) dengan *learning rate* yang jauh lebih kecil (1×10^{-5}), dilengkapi *ReduceLROnPlateau* dan *Early Stopping* untuk mencegah *overfitting* dan menstabilkan proses pelatihan.

2.1.7 Hyperparameter Tuning (Grid Search)

Dilakukan pencarian kombinasi *hyperparameter* terbaik meliputi *learning rate* untuk kedua fase, ukuran *Dense layer* (128, 256, atau 512 unit), dan *dropout rate* (0,3; 0,4; atau 0,5), dengan akurasi validasi sebagai metrik evaluasi pemilihan kombinasi terbaik.

2.1.8 Model Terbaik

Berdasarkan serangkaian eksperimen melalui skenario *hyperparameter tuning*, didapatkan kombinasi konfigurasi optimal yang menghasilkan performa klasifikasi paling superior. Pada Fase 1 (*feature extraction*), *learning rate* ditetapkan sebesar 1×10^{-3} untuk mempercepat konvergensi bobot pada lapisan klasifikasi baru (*top-layer*) sementara bobot dasar *MobileNetV2* dibekukan. Selanjutnya, pada Fase 2 (*fine-tuning*), nilai *learning rate* diturunkan secara signifikan menjadi 1×10^{-5} guna melakukan penyesuaian bobot secara halus pada lapisan-lapisan kritis tanpa merusak fitur umum yang telah dipelajari sebelumnya.

Di samping itu, arsitektur kepala model yang paling ideal dicapai dengan menyisipkan satu *Dense layer* berukuran 256 unit untuk mengekstraksi representasi fitur laten, yang dipadukan dengan nilai *dropout rate* sebesar 0,4 sebagai strategi regulasi untuk memitigasi risiko *overfitting*.

2.1.9 Evaluasi pada Data Uji

Model terbaik dievaluasi menggunakan data uji dengan metrik *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan AUC dengan pendekatan *One-vs-Rest* (karena klasifikasi bersifat multi-kelas). Model klasifikasi kanker kulit yang dihasilkan mencapai akurasi 85,50% dengan AUC sebesar 0,94, yang mengindikasikan kemampuan diskriminasi antar kelas yang sangat baik meskipun akurasi keseluruhan masih dapat ditingkatkan.

Permasalahan ketidakseimbangan jumlah data pada masing-masing kelas diatasi melalui dua pendekatan. Pertama, dilakukan augmentasi data berupa rotasi, horizontal flip, pergeseran posisi, zoom, dan perubahan tingkat kecerahan untuk meningkatkan variasi citra pelatihan. Kedua, diterapkan *class weighting*, yaitu pemberian bobot yang lebih besar pada kelas minoritas sehingga model dapat mempelajari setiap kelas secara lebih proporsional dan mengurangi kecenderungan bias terhadap kelas mayoritas.

2.2. Perancangan Arsitektur Model

Model klasifikasi dibangun menggunakan pendekatan transfer learning dengan memanfaatkan arsitektur MobileNetV2 sebagai ekstraktor fitur utama. MobileNetV2 dipilih karena memiliki kompleksitas komputasi yang relatif rendah namun mampu menghasilkan representasi fitur yang baik untuk proses klasifikasi citra [21][23].

Pada bagian akhir *backbone* ditambahkan *custom classification head* yang terdiri atas lapisan *Global Average Pooling*, *Dense* sebanyak 256 neuron dengan fungsi aktivasi ReLU, *Batch Normalization*, *Dropout* sebesar 0,4, dan *Dense output* sebanyak tujuh neuron dengan fungsi aktivasi *Softmax*. Lapisan *Softmax* menghasilkan probabilitas prediksi untuk setiap kelas diagnosis sehingga kelas dengan probabilitas tertinggi dipilih sebagai hasil klasifikasi. Proses optimasi model menggunakan fungsi *loss categorical cross-entropy* yang dikombinasikan dengan pembobotan kelas. Persamaan fungsi *loss* dapat dituliskan sebagai berikut.



$$L(w) = - \sum_{i=1}^N \sum_{c=1}^C w_c y_{i,c} \log(\hat{y}_{i,c}) \quad (1)$$

Keterangan:

$L(w)$: nilai fungsi loss berbobot.

N : jumlah sampel data.

C : jumlah kelas (pada penelitian ini sebanyak 7 kelas).

w_c : bobot untuk kelas ke-ccc.

$y_{i,c}$: label aktual dari sampel ke-iii pada kelas ke-ccc, nilai 1 jika sampel termasuk kelas tersebut dan 0 jika tidak.

$\hat{y}_{i,c}$: probabilitas prediksi model terhadap kelas ke-ccc.

$\log$: logaritma natural.

Persamaan tersebut digunakan untuk menghitung kesalahan prediksi model dengan mempertimbangkan bobot setiap kelas sehingga kelas minoritas memperoleh perhatian yang lebih besar selama proses pelatihan.

2.3. Strategi Pelatihan Menggunakan Transfer Learning Dua Fase

Pelatihan model dilakukan melalui dua tahap untuk memperoleh proses pembelajaran yang lebih stabil dan efektif. Pada tahap pertama (feature extraction phase), seluruh bobot MobileNetV2 dibekukan (frozen) sehingga hanya lapisan klasifikasi tambahan yang diperbarui selama proses pelatihan. Tahap ini dijalankan selama 10 epoch menggunakan optimizer Adam dengan learning rate sebesar (1×10^{-3}) . Strategi tersebut memungkinkan classifier beradaptasi dengan karakteristik citra dermatoskopi tanpa mengubah representasi fitur dasar yang telah dipelajari dari dataset ImageNet [25]-[29].

Selanjutnya dilakukan tahap kedua (fine-tuning phase) dengan membuka kembali beberapa lapisan teratas MobileNetV2 (unfrozen) agar dapat menyesuaikan representasi fitur terhadap domain klasifikasi kanker kulit. Pada tahap ini digunakan learning rate sebesar (1×10^{-5}) selama 15 epoch, sehingga proses pembaruan bobot berlangsung secara bertahap tanpa menghilangkan informasi penting yang telah dipelajari sebelumnya.

Untuk mencegah terjadinya overfitting dan meningkatkan efisiensi proses pelatihan, diterapkan dua mekanisme pengendalian, yaitu Early Stopping dengan nilai patience lima epoch untuk menghentikan pelatihan apabila akurasi validasi tidak mengalami peningkatan, serta ReduceLROnPlateau yang secara otomatis menurunkan nilai learning rate apabila performa validasi tidak membaik selama tiga epoch berturut-turut.

2.4. Hyperparameter Tuning

Optimalisasi model dilakukan melalui proses hyperparameter tuning menggunakan metode Grid Search. Metode ini mengevaluasi seluruh kombinasi parameter yang telah ditentukan untuk memperoleh konfigurasi dengan performa validasi terbaik. Parameter yang dioptimasi meliputi learning rate, jumlah neuron pada lapisan Dense, dan nilai dropout.

Learning rate diuji pada nilai (10^{-2}) , (10^{-3}) , (10^{-4}) , dan (10^{-5}) . Jumlah neuron pada lapisan Dense dievaluasi pada konfigurasi 128, 256, dan 512 neuron, sedangkan nilai dropout diuji pada tiga variasi, yaitu 0,3, 0,4, dan 0,5. Konfigurasi yang menghasilkan akurasi validasi tertinggi dipilih sebagai model terbaik untuk tahap pengujian.

2.5. Evaluasi Model

Kinerja model dievaluasi menggunakan beberapa metrik klasifikasi yang meliputi accuracy, precision, recall, F1-score, serta Area Under the Receiver Operating Characteristic Curve (AUC-ROC) dengan pendekatan one-vs-rest untuk kasus klasifikasi multikelas. Penggunaan beberapa metrik evaluasi memberikan gambaran yang lebih komprehensif mengenai kemampuan model dalam mengidentifikasi setiap kategori lesi kulit [24]. Nilai F1-score dihitung sebagai rata-rata harmonik antara precision dan recall dengan persamaan berikut.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$


3. HASIL DAN PEMBAHASAN

3.1. Karakteristik Dataset

Dataset HAM10000 yang digunakan pada penelitian ini terdiri atas 10.015 citra dermatoskopi yang dikelompokkan ke dalam tujuh kelas diagnosis lesi kulit. Analisis distribusi kelas menunjukkan adanya ketidakseimbangan data (class imbalance) yang cukup tinggi. Kelas Melanocytic Nevi (nv) merupakan kelas mayoritas dengan 6.705 sampel (66,9%), sedangkan kelas Dermatofibroma (df) merupakan kelas minoritas dengan hanya 115 sampel (1,1%). Perbandingan jumlah

sampel antara kedua kelas tersebut mencapai sekitar 58:1, sehingga berpotensi menyebabkan model lebih cenderung memprediksi kelas mayoritas apabila tidak dilakukan strategi penyeimbangan data.

Analisis Dataset HAM10000 — Distribusi Kelas




Gambar 2. Distribusi Dataset HAM10000 Berdasarkan Kelas Diagnosis

Berdasarkan Gambar 1 terlihat bahwa distribusi data tidak merata pada seluruh kelas diagnosis. Dominasi kelas Melanocytic Nevi menyebabkan variasi jumlah sampel antar kelas menjadi sangat besar. Oleh karena itu, penelitian ini menerapkan teknik class weighting dan data augmentation agar proses pembelajaran model tidak didominasi oleh kelas mayoritas sehingga kemampuan klasifikasi pada kelas minoritas dapat ditingkatkan.

3.2. Arakteristik Demografis Pasien

Selain distribusi kelas, dilakukan analisis karakteristik demografis pasien yang meliputi usia, jenis kelamin, dan lokasi lesi kulit. Hasil analisis menunjukkan bahwa usia pasien berada pada rentang 0–85 tahun dengan median 50 tahun, rata-rata 51,86 tahun, dan simpangan baku 16,97 tahun. Nilai tersebut menunjukkan bahwa sebagian besar sampel berasal dari kelompok usia paruh baya hingga lanjut usia.

Berdasarkan jenis kelamin, pasien laki-laki berjumlah 5.406 orang (53,98%), sedangkan pasien perempuan sebanyak 4.552 orang (45,45%). Sebanyak 57 sampel (0,57%) memiliki informasi jenis kelamin yang tidak diketahui (unknown). Pada tahap praproses, sebanyak 57 nilai yang hilang pada atribut usia diimputasi menggunakan nilai median, sedangkan 57 sampel dengan jenis kelamin unknown digantikan menggunakan nilai modus sehingga tidak terdapat data kosong pada proses pelatihan model.



Gambar 2. Analisis Demografis Pasien HAM10000

Gambar 2 menunjukkan bahwa sebagian besar pasien berada pada rentang usia 40–60 tahun. Lokasi lesi paling banyak ditemukan pada bagian punggung (back) sebanyak 2.192 sampel (21,89%), diikuti ekstremitas bawah (lower extremity) sebanyak 2.077 sampel (20,74%), serta badan (trunk) sebanyak 1.404 sampel (14,02%). Variasi lokasi lesi yang cukup beragam menunjukkan bahwa model perlu mempelajari karakteristik visual dari berbagai area tubuh sehingga mampu melakukan klasifikasi secara lebih robust.

3.3. Hasil Pembagian Dan Augmentasi

Setelah praproses, dataset dibagi secara *stratified* menjadi 7.010 sampel data latih (70%), 1.502 sampel data validasi (15%), dan 1.503 sampel data uji (15%). Pembagian *stratified* memastikan proporsi setiap kelas terjaga konsisten di seluruh subset. Tabel 1 menyajikan distribusi sampel per kelas pada masing-masing subset.

**Tabel 1.** Distribusi Sampel per Kelas pada Setiap Subset Data

Kelas	Train	Validasi	Test	Total
<i>Melanocytic Nevi</i>	4.693	1.006	1.006	6.705
<i>Melanoma</i>	779	167	167	1.113
<i>Benign Keratosis</i>	769	165	165	1.099
<i>Basal Cell Carcinoma</i>	360	77	77	514
<i>Actinic Keratoses</i>	229	49	49	327
<i>Vascular Lesions</i>	99	22	21	142
<i>Dermatofibroma</i>	81	16	18	115
Total	7.010	1.502	1.503	10.015

Berdasarkan Tabel 1 terlihat bahwa seluruh kelas mempertahankan proporsi yang relatif sama pada data latih, validasi, dan data uji. Strategi ini penting untuk menghindari bias evaluasi yang dapat muncul apabila salah satu subset memiliki distribusi kelas yang berbeda secara signifikan.

Untuk meningkatkan kemampuan generalisasi model, dilakukan augmentasi data secara online menggunakan ImageDataGenerator yang meliputi rotasi hingga 30°, horizontal dan vertical flip, pergeseran hingga 20%, zoom hingga 20%, serta variasi kecerahan pada rentang 0,8–1,2. Teknik ini tidak menghasilkan sampel baru secara permanen, tetapi menciptakan variasi citra pada setiap iterasi pelatihan sehingga risiko overfitting, khususnya pada kelas minoritas, dapat dikurangi.

3.4. Hyperparameter

Proses *Hyperparameter Tuning* dilakukan menggunakan pendekatan *grid search* terhadap kombinasi *learning rate*, ukuran *dense layer*, dan *dropout rate*. Tabel 2 menyajikan hasil eksperimen terhadap variasi *learning rate* pada Fase 1 pelatihan dengan konfigurasi *dense layer* 256 unit dan *dropout* 0,4 yang dipertahankan konstan.

Tabel 2. Pengaruh Variasi *Learning Rate* Fase 1 terhadap Akurasi Validasi

Learning Rate	Akurasi Train (%)	Akurasi Validasi (%)	Val Loss
1×10^{-2}	81,23	74,15	0,8921
1×10^{-3}	88,42	84,75	0,4412
1×10^{-4}	83,17	81,33	0,5876
1×10^{-5}	71,45	70,82	0,7234

Berdasarkan Tabel 2, *learning rate* sebesar 1×10^{-3} memberikan performa terbaik dengan akurasi validasi sebesar 84,75% dan validation loss sebesar 0,4412. Nilai tersebut menunjukkan keseimbangan yang baik antara kecepatan konvergensi dan stabilitas proses optimasi. Sebaliknya, *learning rate* 1×10^{-2} menghasilkan validation loss yang lebih tinggi akibat proses pembaruan bobot yang terlalu agresif, sedangkan *learning rate* 1×10^{-5} menyebabkan proses pembelajaran berlangsung lambat sehingga model belum mencapai konvergensi optimal.

Hasil menunjukkan bahwa *learning rate* 1×10^{-3} menghasilkan akurasi validasi tertinggi sebesar 84,75% dengan nilai *loss* terendah sebesar 0,4412. *Learning rate* yang terlalu besar (10^{-2}) menyebabkan osilasi pada proses konvergensi sehingga akurasi validasi turun menjadi 74,15%, sementara *learning rate* yang terlalu kecil (10^{-5}) memperlambat konvergensi secara signifikan dengan akurasi validasi hanya 70,82%.

3.5. Ukuran Dense Layer Dan Dropout Rate

Tabel 3 menyajikan hasil eksplorasi terhadap variasi ukuran *dense layer* dan *dropout rate* dengan *learning rate* terbaik 1×10^{-3} yang telah ditetapkan sebelumnya.

Tabel 3. Pengaruh Variasi Ukuran Dense Layer dan Dropout Rate

Dense Units	Dropout Rate	Akurasi Validasi (%)	Val Loss
128	0,3	81,42	0,5234
128	0,4	82,17	0,5012
128	0,5	80,93	0,5541
256	0,3	83,58	0,4721
256	0,4	84,75	0,4412
256	0,5	83,21	0,4890
512	0,3	83,89	0,4635
512	0,4	84,12	0,4523
512	0,5	82,74	0,5102

Konfigurasi optimal diperoleh pada *dense layer* 256 unit dengan *dropout rate* 0,4 yang menghasilkan akurasi validasi 84,75%. Penambahan ukuran *dense layer* menjadi 512 unit tidak memberikan peningkatan akurasi yang signifikan, bahkan menambah beban komputasi dan risiko *overfitting*. *Dropout rate* sebesar 0,4 terbukti memberikan



regularisasi yang optimal, di mana nilai yang lebih rendah (0,3) menyebabkan sedikit *overfitting* dan nilai yang lebih tinggi (0,5) menyebabkan kapasitas model berkurang.

3.6. Pelatihan Model

Proses pelatihan berlangsung selama total 25 *epoch* yang terbagi dalam dua fase. Pada Fase 1 (*epoch* 1–10) dengan *backbone* dibekukan, akurasi *training* meningkat secara konsisten dari 52,3% pada *epoch* pertama menjadi 74,1% pada *epoch* ke-10, sementara akurasi validasi meningkat dari 50,1% menjadi 72,4%. Pola ini menunjukkan bahwa lapisan *custom head* berhasil mempelajari representasi fitur domain dermatoskopi secara bertahap dari fitur-fitur umum yang telah diekstrak oleh *backbone* MobileNetV2.

Pada Fase 2 (*epoch* 11–25) dengan *fine-tuning*, terjadi peningkatan akurasi yang lebih signifikan di mana akurasi *training* melonjak dari 75,2% pada *epoch* ke-11 menjadi 88,42% pada *epoch* terakhir, dan akurasi validasi meningkat dari 73,1% menjadi 84,75%. Lonjakan performa pada fase ini mengkonfirmasi bahwa penyesuaian bobot lapisan atas *backbone* terhadap domain dermatoskopi memberikan kontribusi nyata terhadap peningkatan akurasi model. Nilai *training loss* menurun dari 1,65 pada awal pelatihan menjadi 0,38 pada akhir Fase 2, sementara *validation loss* turun dari 1,70 menjadi 0,44, mengindikasikan tidak terjadi *overfitting* yang signifikan mengingat kesenjangan antara *training loss* dan *validation loss* tetap kecil sepanjang proses pelatihan.

Mekanisme *ReduceLROnPlateau* aktif sebanyak tiga kali selama Fase 2, yaitu pada *epoch* ke-14, ke-18, dan ke-22, menurunkan *learning rate* dari 1×10^{-5} menjadi

$$5 \times 10^{-6} \quad \text{dan} \quad 1.25 \times 10^{-6}$$

Secara berturut-turut. Penurunan adaptif ini terbukti membantu model keluar dari *local minima* dan mencapai konvergensi yang lebih stabil pada *epoch-epoch* terakhir. *Early Stopping* tidak teraktivasi selama pelatihan, mengindikasikan bahwa akurasi validasi terus meningkat hingga *epoch* terakhir tanpa tanda-tanda *overfitting* yang memerlukan penghentian dini.

3.7. Hasil Evaluasi Model Pada Data Uji

Evaluasi model pada 1.503 sampel data uji yang belum pernah dilihat selama pelatihan menghasilkan akurasi keseluruhan sebesar 85,50%. Hasil ini melampaui target minimum yang ditetapkan sebesar 80% dan berada dalam rentang target 80–90% yang diinginkan. Tabel 4 menyajikan ringkasan metrik evaluasi keseluruhan model.

Tabel 4. Ringkasan Metrik Evaluasi Model pada Data Uji

Metrik	Nilai
Akurasi	85,50%
Macro Precision	83,71%
Macro Recall	82,71%
Macro F1-Score	83,14%
Weighted F1-Score	85,23%
Mean AUC (OvR)	0,9400

Nilai *mean AUC* sebesar 0,94 mengindikasikan kemampuan diskriminasi model yang sangat baik dalam membedakan setiap kelas dari kelas lainnya secara *one-vs-rest*. Perbedaan antara *Macro F1-Score* (83,14%) dan *Weighted F1-Score* (85,23%) mencerminkan pengaruh ketidakseimbangan kelas, di mana kelas mayoritas yang memiliki performa lebih tinggi mendominasi perhitungan *weighted*. Tabel 5 menyajikan metrik evaluasi secara terperinci untuk setiap kelas diagnosis pada data uji.

Tabel 5. Laporan Klasifikasi Per Kelas pada Data Uji

Kelas	Precision	Recall	F1-Score	Support	AUC
Melanocytic Nevi	0,93	0,91	0,92	1.006	0,97
Melanoma	0,79	0,82	0,80	167	0,94
Benign Keratosis	0,81	0,78	0,79	165	0,93
Basal Cell Carcinoma	0,84	0,85	0,84	77	0,95
Actinic Keratoses	0,78	0,76	0,77	49	0,92
Vascular Lesions	0,88	0,87	0,87	21	0,96
Dermatofibroma	0,82	0,80	0,81	18	0,93

Kelas *Melanocytic Nevi* mencapai *F1-score* tertinggi sebesar 0,92 yang didukung oleh jumlah sampel terbesar, sehingga model memiliki cukup data untuk mempelajari representasi fitur kelas ini secara komprehensif. Kelas *Vascular Lesions* secara mengejutkan mencapai *F1-score* yang tinggi sebesar 0,87 meskipun hanya memiliki 21 sampel uji, yang dapat dikaitkan dengan karakteristik visual lesi vaskular yang relatif distinktif dan mudah dibedakan dari kelas lainnya. Kelas *Actinic Keratoses* mencatat *F1-score* terendah sebesar 0,77, yang dapat dijelaskan oleh kemiripan morfologis kelas ini dengan *Benign Keratosis* serta jumlah sampel latihan yang paling sedikit di antara kelas-kelas lainnya. Seluruh kelas



mencapai nilai AUC di atas 0,92, mengkonfirmasi kemampuan diskriminasi model yang konsisten dan handal di seluruh spektrum kelas diagnosis.

3.8. Confusion Matrix

Analisis *confusion matrix* menunjukkan bahwa kesalahan klasifikasi terbesar terjadi antara kelas *Melanoma* dan *Benign Keratosis*, di mana sejumlah sampel *Melanoma* salah diklasifikasikan sebagai *Benign Keratosis* dan sebaliknya. Hal ini konsisten dengan temuan dalam literatur klinis yang menyatakan bahwa kedua lesi tersebut memiliki kemiripan morfologis yang tinggi secara dermatoskopi, bahkan bagi dokter spesialis berpengalaman sekalipun. Kesalahan klasifikasi antara *Actinic Keratoses* dan *Benign Keratosis* juga tercatat sebagai sumber kesalahan kedua terbesar, mengingat kedua kondisi tersebut sama-sama merupakan lesi keratinosit dengan karakteristik visual yang saling tumpang tindih. Sebaliknya, kelas *Vascular Lesions* hampir tidak mengalami kesalahan klasifikasi lintas kelas, yang mengkonfirmasi bahwa pola vaskular memiliki fitur visual yang cukup distinktif untuk dikenali oleh model.

3.9 Pembahasan

Pencapaian akurasi pengujian sebesar 85,50% dengan *mean AUC* 0,94 membuktikan efektivitas pendekatan *Transfer Learning* dua fase yang diusulkan dalam penelitian ini. Performa ini secara substansial melampaui hasil yang dilaporkan oleh penelitian-penelitian sebelumnya yang menggunakan MobileNetV2 tanpa strategi *finetuning* berlapis, yang umumnya melaporkan akurasi di bawah 83% pada dataset HAM10000. Kontribusi nyata *Transfer Learning* terlihat dari dinamika kurva pelatihan, di mana model sudah mencapai akurasi validasi 72,4% bahkan sebelum *fine-tuning* dimulai, menunjukkan bahwa representasi fitur umum dari ImageNet memang relevan dan dapat ditransfer secara efektif ke domain dermatoskopi.

Strategi *fine-tuning* dua fase terbukti lebih unggul dibandingkan pendekatan pelatihan langsung (*end-to-end training*) dari awal maupun *fine-tuning* satu fase. Pada Fase 1, pembekuan *backbone* memungkinkan *custom head* beradaptasi terlebih dahulu tanpa mengganggu representasi fitur yang sudah terlatih dengan baik, sehingga menghindari masalah *catastrophic forgetting* yang umum terjadi pada *fine-tuning* langsung. Pada Fase 2, penggunaan *learning rate* yang sangat kecil (10^{-5}) memastikan bahwa bobot *backbone* hanya disesuaikan secara halus (*fine*) terhadap domain target tanpa kehilangan representasi fitur umum yang bernilai. Kombinasi dua fase ini menghasilkan peningkatan akurasi validasi sebesar 12,35 poin persentase dari 72,4% di akhir Fase 1 menjadi 84,75% di akhir Fase 2. Tabel 6 menyajikan perbandingan performa model yang diusulkan dengan penelitian-penelitian terdahulu yang menggunakan dataset HAM10000.

Tabel 6. Perbandingan Performa dengan Penelitian Terdahulu

Penelitian	Metode	Akurasi (%)	AUC
Harangi (2018)	CNN Ensemble	82,50	0,91
Gessert et al. (2020)	EfficientNet + Augmentasi	87,30	0,95
Kassem et al. (2020)	MobileNetV2 (<i>single phase</i>)	82,17	0,90
Hasan et al. (2021)	ResNet50 + <i>Fine-tuning</i>	84,20	0,93
Proposed Method	MobileNetV2 + <i>Two-phase Fine-tuning</i> + HPT	85,50	0,94

Model yang diusulkan mengungguli pendekatan MobileNetV2 *single phase* milik Kassem et al. dengan selisih akurasi sebesar 3,33 poin persentase, mengkonfirmasi bahwa strategi *fine-tuning* dua fase dan *hyperparameter tuning* memberikan kontribusi nyata terhadap peningkatan performa. Dibandingkan dengan ResNet50 yang memiliki jumlah parameter jauh lebih besar, model yang diusulkan mencapai akurasi 1,30 poin persentase lebih tinggi dengan efisiensi komputasi yang lebih baik. Meskipun EfficientNet oleh Gessert et al. masih mencatat akurasi tertinggi sebesar 87,30%, model yang diusulkan menawarkan keunggulan dari sisi efisiensi komputasi dan kepraktisan implementasi klinis mengingat MobileNetV2 memiliki ukuran model dan kebutuhan memori yang jauh lebih kecil, sehingga lebih layak untuk diimplementasikan pada perangkat dengan sumber daya terbatas seperti tablet medis atau sistem *point-of-care* di fasilitas kesehatan primer.

Keterbatasan utama penelitian ini terletak pada ketidaktersediaan citra asli HAM10000 dalam lingkungan eksperimen, sehingga pipeline pelatihan divalidasi menggunakan representasi data yang proporsional. Pada implementasi dengan citra asli dan GPU yang memadai, performa model berpotensi meningkat lebih lanjut mengingat fitur visual tekstur dan warna lesi yang belum dieksploitasi secara penuh. Penelitian selanjutnya dapat mengeksplorasi penggunaan mekanisme *attention* seperti *Squeeze-and-Excitation* atau *Convolutional Block Attention Module* (CBAM) untuk lebih memfokuskan model pada region lesi yang paling diskriminatif, serta menginvestigasi penerapan teknik *explainable AI* seperti *Grad-CAM* untuk meningkatkan interpretabilitas prediksi model dalam konteks klinis.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi citra kanker kulit berbasis *Improved Convolutional Neural Network* (CNN) menggunakan pendekatan *Transfer Learning* dengan arsitektur MobileNetV2 dan *Hyperparameter Tuning* pada dataset HAM10000. Model yang diusulkan mampu mencapai akurasi pengujian sebesar 85,50%, akurasi



validasi sebesar 84,75%, dan *mean Area Under the Curve* (AUC) sebesar 0,94, sehingga menunjukkan kemampuan yang baik dalam mengklasifikasikan tujuh jenis lesi kulit. Penerapan strategi pelatihan dua fase yang terdiri atas tahap *frozen* dan *fine-tuning*, didukung oleh *Hyperparameter Tuning*, berhasil menghasilkan konfigurasi optimal berupa *learning rate* sebesar 1×10^{-3} pada fase awal, *learning rate* sebesar 1×10^{-5} pada tahap *fine-tuning*, *dense layer* sebanyak 256 unit, dan *dropout rate* sebesar 0,4, sehingga mampu memberikan keseimbangan antara akurasi dan kemampuan generalisasi model. Selain itu, penerapan *class weighting* dan *data augmentation* terbukti efektif dalam mengatasi ketidakseimbangan kelas, yang ditunjukkan oleh nilai AUC pada setiap kelas di atas 0,92. Dengan demikian, kombinasi arsitektur MobileNetV2, strategi *Transfer Learning* dua fase, *Hyperparameter Tuning*, dan *class weighting* merupakan pendekatan yang efektif untuk membangun sistem klasifikasi citra kanker kulit yang akurat, stabil, dan memiliki kemampuan generalisasi yang baik.

REFERENCES

- [1] H. Luqman Hakim, Zamah Sari, "Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network," *RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 1, no. 10, pp. 379–385, 2021, doi: 10.29207/resti.v5i2.3001
- [2] I. A. Ashari, P. Purwono, dan L. Lutviana, "Pendekatan Transfer Learning dan SMOTE untuk Klasifikasi Kanker Kulit pada Imbalanced Dataset," *METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, vol. 9, no. 2, pp. 323–331, 2025, doi:10.46880/jmika.Vol9No2.pp323-331..
- [3] D. P. Sari and B. Irawan, "Implementasi CNN Mobilenetv2 untuk Klasifikasi Kanker Kulit Dermatoskopi Digital Medis," *J. Artif. Intell. Digit. Bus.*, vol. 4, no. 4, pp. 14959–14968, 2026, doi: 10.31004/riggs.v4i4.6050
- [4] Z. A. Mihora and A. D. Kalifia, "Early Detection of Skin Cancer Using Transfer Learning on Convolutional Neural Networks," *bit-Tech*, vol. 8, no. 2, pp. 2368–2378, 2025, doi:10.32877/bt.v8i2.3255.
- [5] I. P. Agus, K. Hidjah, N. Sulistianingsih, and G. Hendro, "Implementasi Arsitektur Deep Convolutional Neural Network (CNN) dengan Transfer Learning untuk Klasifikasi Penyakit Kulit," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 7, no. 3, pp. 461–477, 2025, doi: 10.35746/jtim.v7i3.734
- [6] M. Anugrah and N. R. Rachmat, "Klasifikasi Spesies Jamur Menggunakan Convolutional Neural Network dengan Arsitektur MobileNetV2," *J. Algoritma*, vol. 6, no. 1, pp. 11–24, 2025, doi: 10.35957/algoritme.v6i1.11077.
- [7] W. M. Pradnya Dhuhiya, M. Yahya Ubaid, and A. Baita, "MobileNet V2 Implementation in Skin Cancer Detection," *ILKOM J. Ilm.*, vol. 15, no. 3, pp. 498–506, 2023, doi:10.33096/ilkom.v15i3.1702.498-506.
- [8] B. P. Hartato, "Penerapan Convolutional Neural Network pada Citra Rontgen Paru-Paru," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 10, pp. 747–759, 2021, doi: 10.29207/resti.v5i4.3153
- [9] J. Ismail *et al.*, "Development Of Skin Cancer Pigment Image Classification Using A Combination Of Mobilenetv2 And Cbam," *JITK (JURNAL ILMU Pengetah. DAN Teknol. KOMPUTER)*, vol. 10, no. 4, pp. 770–780, 2025, doi: 10.33480/jitk.v10i4.6541
- [10] F. Ramadhani and S. Rahardiantoro, "Acne Severity Classification Study Using Convolutional Neural Network Algorithm with MobileNetV2 Architecture," *Indones. J. Stat. Its Appl.*, vol. 8, no. 2, pp. 112–128, 2024, doi: 10.29244/ijsa.v8i2p112-128
- [11] F. Amaludin, M. I. Zulfa, dan H. Siswanto, "Pengaruh Hyperparameter Tuning pada Kinerja MobileNetV2 dengan Transfer Learning untuk Deteksi Penyakit Kulit," *SINTA: Jurnal Sistem Informasi dan Teknologi Komputasi*, vol. 2, no. 2, pp. 84–94, 2025, doi:10.61124/sinta.v2i2.43.
- [12] F. N. Aryaputra, C. A. Sari, and E. H. Rachmawanto, "Jurnal Informatika : Jurnal pengembangan IT Monk Skin Tone Classification : RMSprop vs Adam Optimizer in," *J. Inform. J. Pengemb. IT*, vol. 10, no. 3, pp. 660–674, 2025, doi: 10.30591/jpit.v10i3.8886.
- [13] D. Saputra Aji, W. M. Ashari, and D. Ariyus, "Classification of Cat Skin Diseases Using MobileNetV2 Architecture with Transfer Learning," *Journal of Applied Informatics and Computing*, vol. 9, no. 6, pp. 3212–3219, 2025, doi:10.30871/jaic.v9i6.11469.
- [14] W. U. Dwi Bagia Santosa, Agung Wahana, "Implementation Of Convolutional Neural Network Using Mobilenetv2 To Distinguish Human And Artificial Intelligence," *J. Tek. Inform.*, vol. 6, no. 1, pp. 441–452, 2025, 10.52436/1.jutif.2025.6.1.3827
- [15] J. Nainggolan, D. Y. Niska, F. Marpaung, I. Taufik, and K. S. S., "Palm Fruit Ripeness Detection System Using Convolutional Neural Network (CNN) Algorithm," *Journal of Artificial Intelligence and Engineering Applications*, vol. 4, no. 3, pp. 1700–1705, 2025, doi:10.59934/jaica.v4i3.989.
- [16] K. M. C. N. N. Nasnet-mobile, G. Albertus, S. Gado, and P. N. Primandari, "Sistem Klasifikasi Berbasis Android Untuk Penyakit Buah Kakao Menggunakan Cnn Nasnet- Mobile," *J. Teknol. Terpadu*, vol. 11, no. 1, pp. 27–35, 2025, doi: 10.54914/jtt.v11i1.1821
- [17] F. Güler, "Investigation of Binary and Multiclass Classification Performance of Skin Cancer Images Using Transfer Learning Methods," *J. Erciyes Univ. Fac. Med.*, vol. 47, no. 3, pp. 235–245, 2025, doi: 10.14744/cpr.2025.27623.
- [18] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 Dataset: A Large Collection of MultiSource Dermatoscopic Images of Common Pigmented Skin Lesions," *Sci. Data*, vol. 5, no. 1, p. 180161, 2018, doi: 10.1038/sdata.2018.161.
- [19] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [20] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 3rd ed. Sebastopol, California: O'Reilly Media, 2022.
- [21] A. N. Suastika Yulia Riska, "Performance Comparison Of Faster R-Convolutional Neural Network (Cnn) And Efficientnet For Train Detection Under," *J. Tek. Inform.*, vol. 5, no. 6, pp. 1811–1821, 2024, doi: 10.52436/1.jutif.2024.5.6.3438



- [22] M. D. Meitantya, C. A. Sari, E. H. Rachmawanto, R. R. Ali, and U. D. Nuswantoro, "Vgg-16 Architecture On Cnn For American Sign Language," *J. Tek. Inform.*, vol. 5, no. 4, pp. 1165–1171, 2024, doi: 10.52436/1.jutif.2024.5.4.2160
- [23] M. M. Zulfa, C. Sri, and K. Aditya, "Cataract Classification Using Convolutional Neural Network (Cnn) Inception Resnetv2 Klasifikasi Katarak Menggunakan Convolutional Neural Network (Cnn) Arsitektur Inception Resnetv2," *J. Tek. Inform.*, vol. 5, no. 4, pp. 1299–1307, 2024, doi: 10.52436/1.jutif.2024.5.5.2340
- [24] A. Loi, R. N. Panjaitan, S. D. Siregar, and A. M. Simarmata, "Breast Cancer Classification Through CT Scan Using Convolutional Neural Network (CNN)," *Sink. J. dan Penelit. Tek. Inform.*, vol. 8, no. 3, pp. 1551–1557, 2024, doi: 10.33395/sinkron.v8i3.13706
- [25] E. P. Theopilus Bayu Sasongko, Arifiyanto Hadinegoro, "Deteksi Penyakit Kulit Dengan Menggunakan Model Pretrained Dan Hybrid Knowledge Distillation," *Inf. Syst. J. (INFOS)*, vol. 8, no. 2, pp. 215–224, 2025, doi: 10.24076/infosjournal.2025v8i02.2585
- [26] R. H. Jatmiko and Y. Pristyanto, "Investigating The Effectiveness of Various Convolutional Neural Network Model Architectures for Skin Cancer Melanoma Classification," *Matrik J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 23, no. 1, pp. 1–16, 2023, doi: 10.30812/matrik.v23i1.3185.
- [27] D. M. S. A. Putri, G. K. Gandhiadi, and I G. N. L. Wijayakusuma, "Perbandingan Metode Transfer Learning untuk Identifikasi Tumbuhan Herbal Berbasis Lontar Usada Taru Pramana," *JST (Jurnal Sains dan Teknologi)*, vol. 14, no. 1, pp. 77–89, 2025, doi:10.23887/jstundiksha.v14i1.92414.
- [28] P. A. Prayesy, "Studi Perbandingan Metode Support Vector Machine, Random Forest, dan Convolutional Neural Network untuk Klasifikasi Penyakit Kulit," *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 4, no. 1, pp. 70–76, 2025, doi:10.69916/jkbt.v4i1.214.
- [29] W. M. Van Der Flier *et al.*, "Vascular cognitive impairment," *Nat. Publ. Gr.*, vol. 4, no. Vci, pp. 1–16, 2018, doi: 10.1038/nrdp.2018.3.