

Klasifikasi *Undertone* Kulit Menggunakan *Convolutional Neural Network EfficientNetB0* Dengan Pendekatan Transfer Learning Berbasis Citra Pergelangan Tangan

^{1*}Lisa Agustin, ²Danar Putra Pamungkas, ³Made Ayu Dusea Widyadara

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: *¹agustinlisa420@gmail.com, ²danar@unpkediri.ac.id, ³ madedara@gmail.com

Penulis Korespondens : Nama Penulis

Abstrak— Pemilihan *shade foundation* yang tepat penting untuk menghasilkan tampilan riasan yang natural, namun banyak pengguna mengalami kesulitan dalam mengidentifikasi *undertone* kulit secara akurat. Penelitian ini mengembangkan model klasifikasi *undertone* kulit berbasis citra urat nadi pada pergelangan tangan menggunakan *Convolutional Neural Network EfficientNetB0*. Pendekatan yang digunakan adalah *deep learning* dengan *transfer learning*, dimana data citra dikumpulkan menggunakan kamera *smartphone* dalam pencahayaan alami. Proses penelitian meliputi *preprocessing*, *ekstraksi fitur*, dan *klasifikasi*, serta evaluasi menggunakan *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan *undertone* ke dalam tiga kategori yaitu *cool*, *neutral*, dan *warm* dengan model memperoleh nilai *accuracy* sebesar 52%, dengan rata-rata *precision* sebesar 0,53, *recall* sebesar 0,52, dan *F1-score* sebesar 0,52, yang menunjukkan bahwa model memiliki kemampuan dalam melakukan klasifikasi awal terhadap *undertone* kulit.

Kata Kunci— citra pergelangan tangan , *cnn*, *deep learning*, *efficientnetb0*, klasifikasi *undertone*

Abstract— Selecting an appropriate foundation shade is essential for achieving a natural makeup appearance; however, many users have difficulty accurately identifying their skin undertone. This study develops a skin undertone classification model based on wrist vein images using the EfficientNetB0 Convolutional Neural Network. A deep learning approach with transfer learning is applied, where image data are collected using smartphone cameras under natural lighting conditions. The research process includes preprocessing, feature extraction, and classification, followed by evaluation using accuracy, precision, recall, and F1-score. The results show that the model is capable of classifying skin undertones into three categories (cool, neutral, and warm) with an accuracy of 52%, precision of 0,53, recall of 0.52, and an F1-score of 0.52 which indicates that the model demonstrates the ability to perform initial classification of skin undertones.

Keywords— wrist image, *cnn*, *deep learning*, EfficientNetB0, undertone classification

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Foundation merupakan produk kosmetik yang berfungsi untuk meratakan warna kulit dan menghasilkan tampilan wajah yang halus serta natural, dimana keberhasilan penggunaannya sangat ditentukan oleh kesesuaian *shade* dengan warna dan *undertone* kulit [1]. Pemilihan *shade* yang tidak tepat dapat menyebabkan wajah terlihat terlalu gelap, pucat, atau tidak selaras dengan warna kulit asli, sehingga penting untuk memahami *undertone* kulit secara akurat. Namun, banyak pengguna masih mengalami kesulitan dalam menentukan *undertone* kulit karena metode manual cenderung subjektif dan dipengaruhi oleh kondisi pencahayaan. *Undertone* kulit umumnya diklasifikasikan menjadi tiga jenis, yaitu *cool*, *neutral*, dan *warm*, yang dapat dikenali melalui warna urat nadi pada pergelangan tangan [2]. Berbeda dengan penelitian (HERYANTO, 2023) menggunakan metode *Backpropagation Neural Network* berbasis fitur GLCM (*Gray Level Co-occurrence Matrix*) untuk klasifikasi jenis kulit wajah. Pada penelitian tersebut, ekstraksi fitur tekstur dilakukan secara manual menggunakan GLCM sebelum proses klasifikasi dilakukan oleh jaringan saraf tiruan. Oleh karena itu, diperlukan pendekatan berbasis teknologi untuk menganalisis *undertone* kulit secara lebih objektif dan konsisten [4]. Pada penelitian [5] menggunakan model warna CIELAB dan algoritma *Support Vector Machine* (SVM) untuk mendeteksi *skintone* berdasarkan fitur warna kulit hasil ekstraksi manual. Namun, metode tersebut masih bergantung pada ekstraksi fitur manual sehingga kemampuan model dalam mengenali pola visual kompleks menjadi terbatas.

Perkembangan *computer vision* dan *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah banyak dimanfaatkan dalam klasifikasi citra. Penelitian sebelumnya menunjukkan bahwa CNN mampu mengklasifikasikan *undertone* kulit dengan akurasi tinggi (Rekayasa, 2021). Penelitian [7] membahas perkembangan dan penerapan *Convolutional Neural Network* (CNN) dalam bidang *computer vision*, termasuk proses ekstraksi fitur otomatis, klasifikasi citra, serta berbagai arsitektur CNN modern yang digunakan dalam pengolahan citra digital. Penelitian tersebut menjelaskan bahwa CNN memiliki kemampuan tinggi dalam mempelajari pola visual kompleks secara otomatis dibandingkan metode *machine learning* tradisional. Selain itu, pendekatan *transfer learning* seperti *ResNet-50* terbukti efektif dalam klasifikasi citra kulit [8]. Arsitektur *EfficientNet* juga dikenal memiliki performa tinggi dengan efisiensi komputasi yang baik [9]. CNN juga digunakan dalam sistem rekomendasi warna kosmetik berbasis citra wajah [10]. Penelitian [11] berfokus pada klasifikasi jenis kulit wajah, sedangkan penelitian ini lebih spesifik pada klasifikasi *undertone* kulit berdasarkan pola warna urat nadi pada pergelangan tangan. Dengan demikian, penelitian ini memiliki kebaruan pada penggunaan pendekatan CNN untuk klasifikasi *undertone* kulit berbasis citra urat nadi. Selain itu penelitian [12] menggunakan arsitektur *EfficientNetB0* untuk klasifikasi penyakit kulit dengan pendekatan *Convolutional Neural Network* dan optimasi *hyperparameter*. Penelitian tersebut menunjukkan bahwa *EfficientNetB0* mampu melakukan ekstraksi fitur citra secara efektif sehingga menghasilkan performa klasifikasi yang baik pada citra penyakit kulit. Meskipun demikian, penelitian yang secara khusus memanfaatkan *EfficientNetB0* untuk klasifikasi *undertone* kulit berbasis citra urat nadi pada pergelangan tangan masih terbatas.

Berdasarkan hal tersebut, penelitian ini mengusulkan penggunaan model CNN berbasis *transfer learning EfficientNetB0* untuk mengklasifikasikan *undertone* kulit dari citra pergelangan tangan. Permasalahan yang diangkat adalah bagaimana menghasilkan model klasifikasi *undertone* yang akurat berdasarkan citra urat nadi. Tujuan penelitian ini adalah mengembangkan model klasifikasi *undertone* kulit berbasis citra menggunakan *EfficientNetB0* serta mengevaluasi kinerja model berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

II. METODE

2.1 Pengumpulan Data

Penelitian ini menggunakan pendekatan eksperimen kuantitatif yang dilaksanakan di Kampus 2 Universitas Nusantara PGRI Kediri yang melibatkan mahasiswi sebagai responden sejumlah 250 dengan tambahan dataset *public* sebanyak 215 dengan hasil pembagian kelas seperti tabel 1 berikut. Data yang digunakan berupa citra pergelangan tangan yang menampilkan warna urat nadi, diambil menggunakan kamera smartphone dengan resolusi minimal 8 MP pada kondisi pencahayaan alami. Dataset dikelompokkan ke dalam tiga kelas *undertone*, yaitu *cool*, *neutral*, dan *warm*.

Tabel 1. Augmentasi Jumlah Dataset

Label	Data Asli (Jumlah Orang)	Hasil Augmentasi
<i>Cool</i>	155	775
<i>Neutral</i>	155	775
<i>Warm</i>	155	775



Gambar 1.
Undertone Cool



Gambar 2.
Undertone Neutral



Gambar 3.
Undertone Warm

Pada gambar 1 menunjukkan *undertone cool*, yang ditandai dengan warna urat nadi yang tampak kebiruan atau ungu pada permukaan kulit. Gambar 2 menunjukkan *undertone neutral*, yang terlihat dari warna urat nadi tampak sebagai campuran biru dan hijau sehingga tidak dominan ke salah satu warna tertentu. Sementara itu, gambar 3 menunjukkan *undertone warm*, yang ditandai dengan warna urat nadi yang tampak kehijauan pada permukaan kulit.

2.2 Preprocessing Data

Tahap *preprocessing* dilakukan untuk menyiapkan data citra agar sesuai dengan kebutuhan model dan meningkatkan kualitas pembelajaran. Proses pertama adalah *resize*, yaitu mengubah ukuran citra menjadi 224×224 piksel agar sesuai dengan input model *EfficientNetB0*. Normalisasi dilakukan dengan mengubah nilai piksel dari rentang 0–255 menjadi 0–1 menggunakan persamaan :

$$x_{norm} = \frac{x}{255} \dots \dots \dots (1)$$

Selain itu, diterapkan teknik augmentasi data untuk meningkatkan variasi *dataset* dan mengurangi risiko *overfitting*. Augmentasi dilakukan dengan rotasi citra pada sudut tertentu menggunakan transformasi rotasi titik piksel (x, y) menjadi (x', y') berdasarkan persamaan transformasi rotasi. Pada penelitian ini digunakan sudut rotasi sebesar $\pm 10^\circ$ untuk mensimulasikan variasi orientasi citra seperti persamaan (2), (3) :

$$x' = x \cos \theta - y \sin \theta \dots \dots \dots (2)$$

$$y' = x \sin \theta + y \cos \theta \dots \dots \dots (3)$$

$$x' = W - x \dots \dots \dots (4)$$



Gambar 4a. Rotasi 10°



Gambar 4b. Rotasi -10°



Gambar 4c. Flipping Horizontal

Setelah itu dilakukan *flipping horizontal* seperti gambar 4c untuk mensimulasikan variasi posisi tangan kanan dan kiri sehingga setiap citra menghasilkan satu variasi tambahan saat pengambilan gambar menggunakan persamaan (4).

Penyesuaian *brightness* dilakukan untuk mensimulasikan variasi kondisi pencahayaan. Proses ini dilakukan dengan meningkatkan intensitas piksel menggunakan transformasi linear dengan parameter $\alpha = 1.08$ dan $\beta = 4$, sehingga citra menjadi sedikit lebih terang tanpa mengubah struktur utama objek dengan persamaan (5) :

$$I' = \alpha I + \beta \dots \dots \dots (5)$$



Gambar 5a. Penyesuaian *Brightness*



Gambar 5b. *Zoom*


Augmentasi terakhir dilakukan dengan teknik *zoom* seperti gambar 5b untuk mensimulasikan variasi jarak pengambilan citra. *Zoom* diterapkan dengan faktor skala 1.08 melalui *cropping* terpusat dan *resizing* ke ukuran semula, dimana koordinat piksel (x, y) berubah menjadi (x', y') sesuai transformasi skala menggunakan persamaan (6), (7) :

$$x' = sx \dots \dots \dots (6)$$

$$y' = sy \dots \dots \dots (7)$$

2.3 Model Klasifikasi

Proses klasifikasi dilakukan menggunakan model *Convolutional Neural Network* berbasis *transfer learning EfficientNetB0* yang berfungsi sebagai ekstraktor fitur. *EfficientNet-B0* adalah salah satu varian arsitektur CNN modern yang dirancang untuk mencapai keseimbangan optimal antara performa akurasi dan efisiensi komputasi. Beberapa penelitian Indonesia menunjukkan bahwa model ini sangat cocok digunakan untuk tugas klasifikasi citra.



Gambar 6. Alur *EfficientNetB0*

Pada gambar 6 diatas menunjukkan alur arsitektur model *EfficientNetB0* yang digunakan dalam penelitian untuk melakukan klasifikasi undertone kulit berdasarkan citra urat nadi pada pergelangan tangan. Secara umum, proses pada model terdiri dari tiga bagian utama, yaitu *input image*, *backbone EfficientNetB0*, dan *custom classification head* hingga menghasilkan keluaran berupa tiga kelas undertone, yaitu *cool*, *neutral*, dan *warm*.

Pada tahap awal, citra pergelangan tangan dimasukkan ke dalam sistem sebagai *input image* dengan ukuran 224×224 piksel dan format *RGB* ($224 \times 224 \times 3$). Ukuran citra ini disesuaikan dengan kebutuhan *input* dari model *EfficientNetB0* agar proses ekstraksi fitur dapat berjalan optimal. Citra yang digunakan berasal dari hasil pengambilan gambar menggunakan kamera *smartphone* dengan pencahayaan alami sehingga pola warna urat nadi dapat terlihat dengan lebih jelas.

Selanjutnya, citra diproses menggunakan *backbone EfficientNetB0* sebagai bagian utama ekstraksi fitur. *EfficientNetB0* terdiri dari beberapa blok konvolusi yang disebut MBConv (Mobile Inverted Bottleneck Convolution) yang dilengkapi dengan mekanisme *compound scaling* dan *Squeeze-and-Excitation (SE) blocks*. Pada tahap ini, model melakukan proses pembelajaran fitur secara bertahap mulai dari fitur sederhana seperti warna dan tekstur hingga fitur yang lebih kompleks seperti pola urat nadi pada kulit. Penggunaan *EfficientNetB0* memungkinkan proses ekstraksi fitur dilakukan secara efisien dengan jumlah parameter yang lebih ringan dibandingkan beberapa arsitektur CNN lainnya.

Pada penelitian ini digunakan pendekatan *transfer learning* dengan memanfaatkan bobot awal (*pre-trained weights*) dari dataset *ImageNet* sehingga model mampu mengenali pola visual dasar seperti warna, tekstur, dan pola citra sebelum dilakukan pelatihan pada *dataset undertone* kulit. Pada tahap ini, model mempelajari fitur citra secara bertahap mulai dari fitur sederhana hingga fitur yang lebih kompleks seperti pola urat nadi pada kulit. Pemilihan *EfficientNetB0* didasarkan pada kemampuannya dalam menghasilkan performa yang baik dengan jumlah parameter yang relatif lebih sedikit dibandingkan beberapa arsitektur CNN lainnya, sehingga proses ekstraksi fitur dan pelatihan model menjadi lebih efisien serta sesuai digunakan untuk klasifikasi *undertone* kulit berbasis citra pergelangan tangan.

Setelah proses ekstraksi fitur selesai, hasil keluaran dari *backbone EfficientNetB0* diteruskan ke bagian *custom classification head*. Tahap pertama pada bagian ini menggunakan layer *GlobalAveragePooling2D* yang berfungsi untuk mereduksi dimensi fitur tanpa menghilangkan informasi penting dari citra. Layer ini mengubah *feature map* berukuran $7 \times 7 \times 1280$ menjadi vektor fitur berdimensi 1280 sehingga data lebih mudah diproses pada tahap klasifikasi.

Tahap berikutnya menggunakan *Dense Layer* dengan 128 neuron dan fungsi aktivasi ReLU (*Rectified Linear Unit*). Layer ini berfungsi untuk mempelajari hubungan antar fitur hasil ekstraksi sehingga model mampu mengenali karakteristik khusus dari masing-masing kelas *undertone* kulit. Setelah itu diterapkan *Dropout Layer* dengan nilai *dropout rate* sebesar 0,4 untuk mengurangi risiko *overfitting*. Proses *dropout* dilakukan dengan menonaktifkan sebagian neuron secara acak selama pelatihan sehingga model tidak terlalu bergantung pada neuron tertentu.

Pada tahap akhir digunakan *Dense Layer* dengan 3 neuron dan fungsi aktivasi *softmax*. Layer ini menghasilkan probabilitas klasifikasi untuk masing-masing kelas *undertone*, yaitu *cool*, *neutral*, dan *warm*. Kelas dengan nilai probabilitas tertinggi akan dipilih sebagai hasil prediksi akhir model. Berdasarkan arsitektur tersebut, model *EfficientNetB0* pada penelitian ini tidak hanya memanfaatkan kemampuan transfer learning dari model pretrained *ImageNet*, tetapi juga menambahkan *classification head* khusus agar model lebih mampu mengenali karakteristik *undertone* kulit berdasarkan pola warna urat nadi pada citra pergelangan tangan.

2.4 Evaluasi Kinerja Sistem

Kinerja model dievaluasi menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur tingkat ketepatan keseluruhan prediksi model, sedangkan *precision* dan *recall* digunakan untuk mengevaluasi ketepatan dan kelengkapan hasil klasifikasi pada masing-masing kelas. *F1-score* digunakan sebagai ukuran gabungan antara *precision* dan *recall* untuk memberikan evaluasi yang lebih seimbang. Evaluasi dilakukan pada data pengujian untuk mengetahui kemampuan model dalam mengklasifikasikan *undertone* kulit ke dalam kategori yang telah ditentukan.

- 1) **Accuracy**, digunakan untuk mengukur keakuratan prediksi model dengan membandingkan jumlah prediksi akurat terhadap total kumpulan data yang digunakan untuk pengujian :

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \dots \dots \dots (8)$$

- 2) **Precision**, menggambarkan tingkat ketepatan model dalam memprediksi suatu kelas positif, yang dihitung menggunakan rumus persamaan :

$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (9)$$

- 3) **Recall**, digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh sampel dari kelas positif secara benar, dengan rumus :

$$Recall = \frac{TP}{TP + FN} \dots \dots \dots (10)$$

- 4) **F1-Score**, merupakan rata-rata harmonik dari *precision* dan *recall*, sehingga dapat menunjukkan keseimbangan performa model dalam mendeteksi kelas positif dan menghindari kesalahan prediksi. Rumusnya adalah sebagai berikut :

$$F1 - Score = 2 \frac{recall * precision}{recall + precision} \dots \dots \dots (11)$$

III. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Model

Pengujian model dilakukan menggunakan data *validation* dan data *testing* yang telah dipisahkan dari data *training*. Evaluasi kinerja model dilakukan menggunakan *confusion matrix* serta metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Berdasarkan hasil pengujian, diperoleh nilai *training accuracy* sebesar 63,87%, *validation accuracy* sebesar 52,22%, dan *test accuracy* sebesar 55,56%. Selain itu, pada data *validation* diperoleh nilai *precision* sebesar 0,53, *recall* sebesar 0,52, dan *F1-score* sebesar 0,52.


Tabel 2. Hasil Evaluasi Model

Matrix	Nilai
Training Accuracy	63,87%
Validation Accuracy	52,22%
Test Accuracy	55,56%
Precision	0,53
Recall	0,52
F1-Score	0,52

Berdasarkan Tabel 2, nilai *training accuracy* sebesar 63,87% lebih tinggi dibandingkan *validation accuracy* sebesar 52,22% dan *test accuracy* sebesar 55,56%. Perbedaan nilai tersebut menunjukkan bahwa model mampu mempelajari data training dengan cukup baik, namun kemampuan generalisasi terhadap data baru masih belum optimal. Hasil ini mengindikasikan bahwa performa model dalam mengklasifikasikan undertone kulit masih terbatas, terutama pada data validation dan testing.

3.2 Grafik Training Model

Hasil pelatihan model ditunjukkan pada grafik akurasi dan loss. Akurasi training mengalami peningkatan dari sekitar 47% hingga mencapai 70% pada *epoch* terakhir. Namun, akurasi *validation* cenderung stagnan dan mengalami penurunan hingga sekitar 42%.




Gambar 7. Grafik Training dan Validation Accuracy serta loss

Nilai *loss training* menunjukkan penurunan yang konsisten, sedangkan *loss validation* cenderung fluktuatif dan tidak menunjukkan penurunan yang signifikan. Kondisi ini mengindikasikan adanya kecenderungan *overfitting*, dimana model mampu mempelajari data training dengan baik namun masih terbatas dalam melakukan generalisasi terhadap data *validation*

3.3 Confusion Matrix

Pada data *validation*, model menunjukkan kemampuan klasifikasi yang belum merata pada ketiga kelas undertone. Kelas *cool* memiliki jumlah prediksi benar yang lebih tinggi dibandingkan kelas lainnya, sedangkan kelas *neutral* dan *warm* masih menunjukkan tingkat kesalahan klasifikasi yang cukup signifikan. Kesalahan prediksi terjadi antar ketiga kelas undertone, yang mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan karakteristik warna urat nadi yang memiliki kemiripan visual. Kondisi ini menunjukkan bahwa fitur yang dipelajari model belum mampu merepresentasikan perbedaan antar kelas secara optimal.



Gambar 8. Confusion Matrix Validation dan Confusion Matrix Test

Distribusi prediksi yang cukup tersebar juga memperlihatkan adanya kecenderungan model untuk mengklasifikasikan beberapa sampel ke kelas *cool*. Pada kelas *warm* dan *neutral*, masing-masing terdapat sejumlah sampel yang salah diprediksi sebagai *cool*. Fenomena ini mengindikasikan adanya *feature overlap* atau tumpang tindih fitur visual antar kelas undertone, khususnya pada pola warna tertentu. Akibatnya, model menjadi lebih bias terhadap kelas *cool* dibandingkan kelas lainnya.

Tabel 3. *Classification Report*

Kelas	Precision	Recall	F1-Score
Cool	0,46	0,57	0,51
Neutral	0,56	0,50	0,53
Warm	0,58	0,50	0,54

Berdasarkan tabel 3 *classification report*, kelas *cool* memiliki nilai *recall* tertinggi sebesar 0,57, sedangkan kelas *warm* memiliki *precision* tertinggi sebesar 0,58. Hasil ini menunjukkan bahwa model lebih sensitif dalam mengenali kelas *cool*, namun masih mengalami kesalahan klasifikasi antar kelas *undertone*.

3.4 Perbandingan Penelitian Terdahulu

Jika dibandingkan dengan penelitian sebelumnya yang menggunakan metode CNN, seperti penelitian [6] dan [8] yang memperoleh akurasi di atas 99%, performa model pada penelitian ini masih tergolong lebih rendah dengan nilai *test accuracy* sebesar 55,56%. Perbedaan hasil tersebut kemungkinan dipengaruhi oleh beberapa faktor, seperti jumlah dataset yang masih terbatas, variasi pencahayaan saat pengambilan citra, serta kemiripan pola warna urat nadi antar kelas undertone yang menyebabkan model mengalami kesulitan dalam membedakan fitur visual secara optimal. Selain itu, kualitas citra yang diambil menggunakan kamera smartphone juga berpotensi menghasilkan perbedaan intensitas warna dan detail citra yang mempengaruhi proses ekstraksi fitur oleh model. Penelitian [13] menggunakan algoritma *Convolutional Neural Network* dengan arsitektur EfficientNet-B0 dan ResNet-50 untuk klasifikasi jenis sampah. Penelitian tersebut menunjukkan bahwa EfficientNet-B0 mampu menghasilkan performa klasifikasi yang baik dengan proses ekstraksi fitur citra yang efisien. Berbeda dengan penelitian tersebut, penelitian ini memanfaatkan EfficientNetB0 untuk klasifikasi undertone kulit berdasarkan citra urat nadi pada pergelangan tangan.

Penelitian [14] menggunakan arsitektur *Convolutional Neural Network* EfficientNet-B3 dengan teknik augmentasi data untuk klasifikasi penyakit daun padi. Hasil penelitian menunjukkan bahwa augmentasi data membantu meningkatkan variasi citra sehingga performa model klasifikasi menjadi lebih baik dan mampu mengurangi risiko *overfitting*. Berbeda dengan penelitian tersebut, menggunakan arsitektur EfficientNetB0 untuk klasifikasi undertone kulit berdasarkan citra urat nadi pada pergelangan tangan. Selain objek penelitian yang berbeda, penelitian ini juga berfokus pada klasifikasi undertone ke dalam kategori *cool*, *neutral*, dan *warm* menggunakan pendekatan *transfer learning*. [15] mengembangkan sistem *SkinMatch* untuk mendeteksi *undertone* kulit dan memberikan rekomendasi warna pakaian menggunakan pengolahan citra digital dengan model warna HSV dan LAB. Penelitian tersebut mampu mengklasifikasikan *undertone* ke dalam kategori *warm*, *cool*, dan *neutral* serta menghasilkan rekomendasi warna pakaian yang sesuai.

Hasil pelatihan model juga menunjukkan adanya kecenderungan *overfitting*, dimana nilai *training accuracy* lebih tinggi dibandingkan *validation accuracy* dan *test accuracy*. Kondisi ini menunjukkan bahwa model mampu mempelajari data training dengan baik, namun kemampuan generalisasi terhadap data baru masih belum optimal. Hal tersebut juga diperkuat oleh hasil *confusion matrix* yang menunjukkan masih banyaknya kesalahan klasifikasi antar kelas *cool*, *neutral*, dan *warm*. Model terlihat lebih cenderung memprediksi data ke kelas *cool*, yang mengindikasikan adanya *feature overlap* atau kemiripan fitur visual antar kelas undertone.

Selain dipengaruhi oleh jumlah dataset, performa model juga dipengaruhi oleh distribusi data antar kelas yang belum sepenuhnya seimbang serta proses pelabelan undertone yang masih bersifat subjektif. Meskipun demikian, penggunaan EfficientNetB0 pada penelitian ini menunjukkan bahwa metode *deep learning* berbasis *transfer learning* memiliki kemampuan dalam melakukan ekstraksi fitur citra secara otomatis tanpa proses ekstraksi fitur manual. Dengan pengembangan lebih lanjut seperti penambahan jumlah dataset, optimasi augmentasi data, serta pengaturan parameter pelatihan yang lebih optimal, performa model berpotensi ditingkatkan pada penelitian selanjutnya.

IV. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan arsitektur Convolutional Neural Network (CNN) EfficientNetB0 dengan pendekatan transfer learning mampu digunakan untuk mengklasifikasikan undertone kulit berdasarkan citra urat nadi pada pergelangan tangan ke dalam kategori cool, neutral, dan warm. Model yang dikembangkan menunjukkan bahwa pendekatan deep learning dapat dimanfaatkan untuk membantu proses identifikasi undertone kulit secara otomatis melalui analisis citra digital.

Penelitian ini memberikan kontribusi dalam pengembangan penerapan kecerdasan buatan dan pengolahan citra digital pada bidang klasifikasi karakteristik kulit, khususnya undertone kulit yang selama ini masih banyak ditentukan secara subjektif. Penggunaan EfficientNetB0 memungkinkan proses ekstraksi fitur dilakukan secara otomatis sehingga dapat mengurangi ketergantungan pada ekstraksi fitur manual yang umumnya digunakan pada metode klasifikasi konvensional.

Meskipun demikian, kemampuan model dalam melakukan generalisasi masih dipengaruhi oleh kualitas dan jumlah dataset, kondisi pencahayaan saat pengambilan citra, serta kemiripan karakteristik visual antar kelas undertone. Oleh karena itu, pengembangan lebih lanjut diperlukan melalui penambahan jumlah data, peningkatan kualitas proses akuisisi citra, serta optimasi model agar diperoleh performa klasifikasi yang lebih baik dan lebih stabil pada berbagai kondisi data.

DAFTAR PUSTAKA

- [1]. Ramadona, "Pengaruh Pemilihan Jenis Foundation Terhadap Hasil Make up Pesta," *Jurnal Farmasi*, vol. 01, no. 1, p. 6, 2023, [Online]. Available: <https://lib.unnes.ac.id/31594/>
- [2]. R. Ramli and A. D. Kalifia, "Chatbot for Clothing Color Recommendations Based on Skin Tone," *bit-Tech*, vol. 8, no. 2, pp. 2206–2217, 2025.
- [3]. M. A. HERYANTO, D. JUANANTA, A. SADANARESWARI, and S. A. WULANDARI, "Klasifikasi Jenis Kulit Wajah menggunakan Backpropagation Neural Networks Berbasis GLCM," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik*

- Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 3, p. 705, 2023, doi: 10.26760/elkomika.v11i3.705.
- [4]. Y.-M. Choi and S. Bae, "A Study on Foundation Color Classification with the Application of Personal Colors," *Asian Journal of Beauty and Cosmetology*, vol. 22, no. 2, pp. 323–334, 2024.
 - [5]. Shofiyah and N. Pratiwi, "Deteksi Skintone Menggunakan Model Warna CIELAB dan Klasifikasi Support Vector Machine," *Progresif: Jurnal Ilmiah Komputer*, vol. 21, no. 2, pp. 520–531, 2025.
 - [6]. K. K. Rekayasa, R. Fayyadhila, A. Junaidi, and N. A. Prasetyo, "Terbit online pada laman web jurnal: <http://journal.ittelkom-pwt.ac.id/index.php/dinda> JOURNAL OF DINDA UNDERTONE MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK," 2021. [Online]. Available: <http://journal.ittelkom-pwt.ac.id/index.php/dinda>
 - [7]. X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, *A review of convolutional neural networks in computer vision*, vol. 57, no. 4. Springer Netherlands, 2024. doi: 10.1007/s10462-024-10721-6.
 - [8]. D. A. Agustina, "Klasifikasi Citra Jenis Kulit Wajah Dengan Algoritma Convolutional Neural Network (Cnn) Resnet-50," *Jurnal Riset Sistem Informasi*, vol. 1, no. 3, pp. 1–7, 2024.
 - [9]. R. T. Wahyuningrum, R. Erfian, A. Kusumaningsih, and H. P. A. Tjahyaningtijas, "Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning EfficientNetB5," *Jurnal Pekommas*, vol. 10, no. 1, pp. 1–8, 2025, doi: 10.56873/jpkm.v9i1.5322.
 - [10]. H. U. Adzkia, "Warna Berdasarkan Seasonal Color," vol. 19, no. 2, 2025, [Online]. Available: <https://doi.org/10.47111/jti.v19i2.20597>
 - [11]. K. P. Alaska, I. Indrawati, and H. T. Hidayat, "Klasifikasi Citra Kulit Wajah Menggunakan Metode Naïve Bayes Berbasis Android," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 1, no. 1, p. 16, 2021, doi: 10.30811/jaise.v1i1.2217.
 - [12]. P. Khairunnisa, W. E. Putra, W. Yitong, A. Jufrizal, and M. N. A. Makmum, "Convolutional Neural Networks Using EfficientNetB0 Architecture and Hyperparameters on Skin Disease Classification," *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 2, no. 2, pp. 127–137, 2025, doi: 10.57152/predatecs.v2i2.1569.
 - [13]. W. M. Ardana, "Optimization of Convolutional Neural Network Algorithm with Efficientnet-B0 and Resnet-50 Architecture for Waste Type Classification Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sa," vol. 5, no. October, pp. 1274–1286, 2025.
 - [14]. D. P. Ayuni, "Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi," *AUGMENTASI DATA PADA IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR EFFICIENTNET-B3 UNTUK KLASIFIKASI PENYAKIT DAUN PADI*, vol. 5, no. 2, pp. 239–250, 2023.
 - [15]. L. E. Butarbutar, V. F. Tambunan, S. Davina, and H. Syahputra, "Skinmatch: Rekomendasi Warna Pakaian Berdasarkan Undertone Kulit Menggunakan Pengolahan Citra Digital," *Jurnal Fasilkom*, vol. 15, no. 2, pp. 391–397, 2025.