Jurnal Ilmiah Sains Teknologi dan Informasi
Volume 4, Nomor 4, Oktober 2026
e-ISSN: 2964-3104; p-ISSN: 2964-3090, Hal. 466-484
DOI: https://doi.org/10.59024/jiti.v4i4.2703
Tersedia: https://jurnal.alimspublishing.co.id/index.php/JITI

Klasifikasi Skintone Menggunakan *Convolutional Neural Network* (CNN) untuk Mencari Persentase Kecocokan dengan Warna Pakaian

Rafif Nauval Tuah Siregar[1*], Said Iskandar Al Idrus[2], Arnita[3], Insan Taufik[4], Zulfahmi Indra[5]
[1-5]Ilmu Komputer, Universitas Negeri Medan, Indonesia
**Penulis Korespondensi: rafifnaufal37@gmail.com*

Abstract.. *Choosing clothing colors that complement an individual's skin tone often relies on subjective judgment. This study develops a Convolutional Neural Network (CNN)-based system to classify skin tone and calculate clothing color compatibility percentages. A modified MobileNetV2 model was trained on 2,935 facial images categorized into Light, Medium, and Dark classes. Preprocessing included augmentation, normalization, resizing, and face detection using MediaPipe. Model performance was evaluated on an independent test set obtained from Kaggle and separated from training data before model development. The model achieved 94% test accuracy. Following classification, skin color was analyzed in CIELAB and HSV color spaces. Clothing color compatibility was calculated using a weighted scoring method involving five parameters: Hue, Undertone, Value, Saturation, and LAB Distance scores. Compatibility percentages were determined using predefined color-matching criteria. The system was implemented as a web-based application displaying predicted skin tone and compatibility percentages for predefined clothing colors. These findings demonstrate the potential of combining deep learning and color analysis to support more objective and personalized clothing color recommendations.*

Keywords*: Clothing Color Compatibility; Convolutional Neural Network; MobileNetV2; Skin Color Analysis; Skin Tone Classification.*

Abstrak. Pemilihan warna pakaian yang sesuai dengan warna kulit seseorang umumnya masih didasarkan pada penilaian subjektif, sehingga menghasilkan rekomendasi yang tidak konsisten. Penelitian ini bertujuan untuk mengembangkan sistem berbasis Convolutional Neural Network (CNN) untuk mengklasifikasikan warna kulit berdasarkan citra wajah dan menghitung persentase kecocokan warna pakaian. Model yang digunakan mengadopsi arsitektur MobileNetV2 yang dimodifikasi dan dilatih menggunakan 2.935 citra wajah yang dikelompokkan ke dalam tiga kelas, yaitu Light (terang), Medium (sedang), dan Dark (gelap). Tahapan prapemrosesan citra meliputi augmentasi data, normalisasi, pengubahan ukuran citra, dan deteksi wajah menggunakan MediaPipe Face Detection. Setelah proses klasifikasi, warna kulit diekstraksi dan dikonversi ke dalam ruang warna CIELAB dan HSV. Persentase kecocokan warna pakaian dihitung menggunakan metode pembobotan berdasarkan lima parameter, yaitu Skor Hue, Skor Undertone, Skor Value, Skor Saturation, dan Skor Jarak LAB. Hasil pengujian menunjukkan bahwa model CNN mencapai akurasi sebesar 94%. Model tersebut berhasil diimplementasikan dalam aplikasi berbasis web yang menampilkan hasil prediksi warna kulit beserta persentase kecocokan untuk warna pakaian yang telah ditentukan. Hasil penelitian ini menunjukkan potensi penggabungan deep learning dan analisis warna untuk memberikan rekomendasi warna pakaian yang lebih objektif dan personal berdasarkan karakteristik warna kulit individu.

Kata Kunci: Analisis Warna Kulit; Jaringan Saraf Konvolusional; Kecocokan Warna Pakaian; Klasifikasi Warna Kulit; MobileNetV2.

1. LATAR BELAKANG

Industri fashion terus berkembang seiring dengan digitalisasi dan meningkatnya kebutuhan konsumen terhadap produk yang dipersonalisasi, termasuk pemilihan warna pakaian berdasarkan karakteristik warna kulit (*skin tone*). Namun, pemilihan warna pakaian masih banyak mengandalkan penilaian subjektif yang dapat dipengaruhi oleh pencahayaan, lingkungan pengambilan gambar, dan perbedaan persepsi individu (Elavarthi et al., 2023; Feng et al., 2020). Padahal, kecocokan warna pakaian tidak hanya ditentukan oleh kategori warna kulit, tetapi juga oleh kecerahan, kejenuhan, *undertone*, dan kontras visual. Oleh karena itu,

Naskah Masuk: 16 Agustus 2026; Revisi: 18 September 2026; Diterima: 19 Oktober 2026; Terbit: 28 Oktober 2026

diperlukan pendekatan komputasional untuk mendukung identifikasi warna kulit dan penilaian kecocokan warna pakaian secara lebih terukur (Fortuna et al., 2024; Ridla, 2022). Perkembangan *deep learning*, khususnya *Convolutional Neural Network* (CNN), memungkinkan ekstraksi fitur visual secara otomatis untuk berbagai tugas klasifikasi citra (Fonda, 2020; Naufal et al., 2021; Nurkhasanah et al., 2022). Arsitektur MobileNetV2 yang dimodifikasi menjadi salah satu alternatif untuk membangun model klasifikasi warna kulit yang relatif efisien dan berpotensi diterapkan pada aplikasi berbasis web. Penelitian sebelumnya telah mengeksplorasi klasifikasi warna dan personalisasi kecantikan menggunakan CNN (Anupama et al., 2025; Fortuna et al., 2024), serta klasifikasi fashion secara hierarkis (Seo et al., 2019). Namun, klasifikasi warna kulit, rekomendasi *makeup*, dan klasifikasi objek fashion belum secara langsung menjawab kebutuhan integrasi klasifikasi warna kulit dengan penilaian kecocokan warna pakaian.

Kesenjangan tersebut menjadi dasar pengembangan sistem yang mengintegrasikan CNN untuk mengklasifikasikan warna kulit ke dalam tiga kategori, yaitu *Light*, *Medium*, dan *Dark*, dengan metode *weighted multi-parameter scoring* untuk menghitung persentase kecocokan warna pakaian. Metode ini menggabungkan lima parameter, yaitu *Hue Score*, *Undertone Score*, *Value Score*, *Saturation Score*, dan *LAB Distance Score*. Penilaian memanfaatkan ruang warna HSV untuk merepresentasikan rona, kejenuhan, dan kecerahan, serta CIELAB untuk mengukur perbedaan warna berdasarkan dimensi kecerahan dan komponen kromatik. Kelima parameter tersebut diberi bobot untuk menghasilkan skor kecocokan yang mempertimbangkan berbagai karakteristik warna secara bersamaan.

Penelitian ini bertujuan mengembangkan sistem klasifikasi warna kulit berbasis CNN dengan arsitektur MobileNetV2 yang dimodifikasi dan mengintegrasikannya dengan metode *weighted multi-parameter scoring* untuk memberikan rekomendasi warna pakaian. Model dilatih menggunakan 2.935 citra wajah yang dikelompokkan ke dalam kelas *Light*, *Medium*, dan *Dark*, melalui tahapan augmentasi data, normalisasi, pengubahan ukuran citra, dan deteksi wajah menggunakan MediaPipe Face Detection. Hasil klasifikasi kemudian digunakan dalam analisis warna berbasis CIELAB dan HSV untuk menghitung persentase kecocokan warna pakaian. Sistem diimplementasikan dalam aplikasi berbasis web yang menampilkan prediksi warna kulit dan skor kecocokan dari pilihan warna pakaian yang tersedia. Dengan demikian, penelitian ini diharapkan dapat mendukung pemilihan warna pakaian secara lebih terukur dan personal berdasarkan karakteristik warna kulit pengguna.

2. KAJIAN TEORITIS

Karakteristik Biologis Skintone dan Harmonisasi Warna Busana

Warna kulit manusia (*skintone*) dijelaskan sebagai hasil interaksi dan kombinasi dari beberapa pigmen biologis utama, khususnya melanin pada lapisan luar kulit (epidermis), serta didukung oleh hemoglobin yang memberi rona kemerahan dan karotenoid yang memberi rona kekuningan (Jablonski, 2006). Karakteristik warna kulit tidak semata-mata berkorelasi dengan faktor ras, melainkan merupakan wujud adaptasi biologis dan evolusioner tubuh terhadap intensitas paparan radiasi sinar ultraviolet di berbagai belahan dunia (Jablonski, 2006). Dalam dunia dermatologi maupun kosmetologi, sistem klasifikasi warna kulit yang paling umum digunakan secara global adalah *Fitzpatrick Skin Phototype Scale* yang dirumuskan oleh Thomas B. Fitzpatrick (Coleman et al., 2023).

Skala ini membagi spektrum warna kulit ke dalam enam tingkatan (Tipe I hingga Tipe VI) berdasarkan kandungan melanin serta kecenderungan kulit untuk terbakar atau menggelap di bawah sinar matahari (Coleman et al., 2023; High & Prok, 2021). Klasifikasi tersebut merentang mulai dari Tipe I yang sangat terang dan pucat, Tipe II (putih terang/krem), Tipe III (beige sedang/hangat), Tipe IV (cokelat terang/zaitun), Tipe V (cokelat gelap), hingga Tipe VI yang paling gelap dengan nuansa cokelat kehitaman (High & Prok, 2021). Di Indonesia, keberagaman geografis dan etnis menghasilkan variasi warna kulit yang sebagian besar terkonsentrasi pada rentang Tipe III hingga Tipe V, meliputi warna kulit putih, kuning langsat, hingga cokelat muda atau sawo matang (Juanita & Juliadi, 2020).

Dalam konteks estetika tata busana, pemilihan warna pakaian berkaitan erat dengan karakteristik visual individu, khususnya warna kulit (Perrett & Sprengelmeyer, 2021). Perbedaan tingkat melanin pada kulit terbukti memengaruhi keserasian dan preferensi warna pakaian; individu berkulit terang cenderung lebih harmonis mengenakan warna bernuansa dingin seperti biru atau lavender, sementara individu berkulit gelap atau sawo matang (*tanned*) lebih cocok memadukan warna bernuansa hangat seperti oranye, merah bata, dan kuning keemasan (Perrett & Sprengelmeyer, 2021). Pemilihan warna busana yang selaras dengan *skintone* tidak hanya memperkuat impresi visual secara estetis, tetapi juga memberikan efek psikologis positif yang mampu meningkatkan daya tarik penampilan dan rasa percaya diri pemakainya (Aja & Gebbert, 2019).

Deep Learning dan Convolutional Neural Network (CNN)

Perkembangan teknologi komputasi dalam bidang *computer vision* banyak didorong oleh pemanfaatan *deep learning*, yaitu cabang *machine learning* yang terinspirasi oleh struktur

jaringan saraf biologis manusia (Pratiwi et al., 2021). Keunggulan utama *deep learning* terletak pada kemampuannya mengekstraksi representasi fitur-fitur penting dari data citra secara otomatis dan hierarkis tanpa membutuhkan perancangan fitur manual (Okta, 2023; Pratiwi et al., 2021). Model *deep learning* tersusun atas jaringan saraf tiruan (*Neural Network*) yang mengolah sinyal masukan melalui perkalian bobot dan bias pada lapisan-lapisan neuron (Agustina et al., 2022; Aryanti, 2023). Selain itu, efisiensi pelatihan model *deep learning* dapat ditingkatkan melalui pendekatan *transfer learning*, yakni memanfaatkan model yang telah dilatih sebelumnya untuk menyelesaikan permasalahan klasifikasi pada domain data baru (Okta, 2023; Sadewa & Yamasari, 2024).

Salah satu arsitektur *deep learning* yang dirancang khusus untuk memproses data berstruktur grid dua dimensi seperti citra adalah *Convolutional Neural Network* (CNN) (Anhar & Putra, 2023). Proses komputasi pada CNN secara umum terbagi menjadi dua tahapan fundamental, yaitu pembelajaran fitur (*feature learning*) dan klasifikasi (*classification layer*) (Azmi et al., 2023; Nugroho et al., 2020). Pada tahap *feature learning*, lapisan konvolusi (*convolutional layer*) melakukan operasi konvolusi matematis menggunakan sejumlah filter kernel untuk mengekstrak pola visual lokal seperti tepi, kontur, dan tekstur warna (Alwanda et al., 2020). Transformasi non-linear kemudian ditambahkan menggunakan fungsi aktivasi seperti *Rectified Linear Unit* (ReLU) yang mempertahankan nilai positif dan mengubah nilai negatif menjadi nol, sehingga mampu memitigasi kendala hilangnya gradien (*vanishing gradient problem*) selama proses optimasi (Ide & Kurita, 2017; Nair & Hinton, 2010).

Untuk menyederhanakan kompleksitas komputasi, lapisan *pooling*—terutama *max pooling*—diterapkan guna mereduksi dimensi matriks (*down-sampling*) tanpa menghilangkan informasi penting dari *feature maps* (Magdalena et al., 2021). Pada tahap akhir, keluaran fitur diratakan (*flatten*) dan dihubungkan ke lapisan terkoneksi penuh (*fully connected layer*) yang mengintegrasikan fungsi aktivasi *Softmax* guna menghasilkan distribusi probabilitas kelas keluaran (Agustina et al., 2022; Wardani & Leonardi, 2023). Kinerja pembaruan bobot model ini sangat dipengaruhi oleh pengaturan *hyperparameter* seperti ukuran *batch* (Kusuma et al., 2021), jumlah *epoch* (Brownlee et al., 2022; Wasil et al., 2022), laju pembelajaran (*learning rate*) (Sadewa & Yamasari, 2024), serta algoritma *optimizer* seperti Adam atau RMSprop (Nugraha & Sasongko, 2022; Tugas et al., 2020).

Ruang Warna CIELAB dan Pengukuran Jarak Perseptual

Dalam pemrosesan citra digital, citra pada umumnya tersimpan dalam representasi ruang warna RGB (Astiningrum et al., 2019). Akan tetapi, format RGB tidak bersifat perseptual seragam (*perceptually uniform*), sehingga nilai kedekatan matematis pada ruang RGB sering

kali tidak linear terhadap sensasi perbedaan warna yang diterima oleh sistem visual manusia (Anupama et al., 2025; Astiningrum et al., 2019). Untuk mengatasinya, Komisi Internasional untuk Pencahayaan merumuskan ruang warna CIELAB ($L^*a^*b^*$) yang diturunkan dari model warna tristimulus XYZ (Astiningrum et al., 2019). Ruang warna CIELAB membagi komponen warna ke dalam tiga dimensi ortogonal, yaitu: Sumbu L^* yang menyatakan tingkat kecerahan (*lightness*) dalam rentang nilai 0 (hitam) hingga 100 (putih). Sumbu a^* yang merepresentasikan gradasi antara warna hijau (nilai negatif) hingga merah (nilai positif) (Astiningrum et al., 2019). Sumbu b^* yang merepresentasikan gradasi antara warna biru (nilai negatif) hingga kuning (nilai positif) (Astiningrum et al., 2019).

Perbedaan warna visual antara dua objek dapat dihitung secara kuantitatif melalui jarak Euclidean pada ruang CIELAB yang dikenal sebagai nilai ΔE^*_{ab} (Astiningrum et al., 2019). Semakin kecil nilai ΔE^*_{ab}, semakin identik kedua warna tersebut secara visual (Astiningrum et al., 2019). Kendati demikian, dalam ranah estetika mode, pemilihan busana tidak dapat diselesaikan semata-mata dengan mencari nilai ΔE^*_{ab} terkecil atau kesamaan warna absolut (*color similarity*), sebab warna pakaian yang terlalu serupa dengan warna kulit pemakai justru menimbulkan tampilan pucat (*washed-out effect*) (Perrett & Sprengelmeyer, 2021). Oleh karena itu, evaluasi estetika busana memerlukan integrasi antara ruang warna CIELAB dan ruang warna HSV (*Hue, Saturation, Value*) untuk mengukur proporsi harmoni rona (Hue Score), temperatur warna dasar (*Undertone Score*), rasio kontras terang-gelap (*Value Score*), intensitas kejenuhan (*Saturation Score*), dan batasan jarak perseptual terukur (*LAB Distance Score*) (Fortuna et al).

Pengembangan model komputasi cerdas dalam analisis warna busana dan karakteristik kulit telah dieksplorasi oleh sejumlah peneliti terdahulu. Manza et al. (2025) memanfaatkan algoritma *machine learning* konvensional *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan kategori warna busana. Namun, penelitian tersebut hanya berorientasi pada pelabelan warna pakaian tanpa mengaitkannya dengan keserasian karakteristik biologis pemakainya.

Di ranah analisis citra wajah, Fayyadhila et al. (2021) mengimplementasikan CNN untuk mengklasifikasikan *undertone* kulit wajah. Pendekatan ini kemudian diperluas oleh Fortuna et al. (2024) yang mengombinasikan ekstraksi ruang warna RGB dan YCbCr bersama algoritma CNN untuk optimasi rekomendasi tata rias (*makeup*) berbasis *undertone* kulit, dengan capaian akurasi sebesar 99,83% di tengah variasi pencahayaan. Selain itu, Anupama et al. (2025) mengeksplorasi keterbatasan deteksi warna berbasis ambang batas RGB dan LAB

tradisional, serta membuktikan bahwa pendekatan berbasis *deep learning* mampu menghasilkan tingkat akurasi dan adaptabilitas yang jauh lebih superior dalam pengenalan warna kulit (mencapai akurasi deteksi 94,2% dan klasifikasi 92,8%). Adapun penelitian yang memiliki keterkaitan langsung dengan penentuan busana dilakukan oleh Prabowo et al. (2024), yang mengaplikasikan metode CNN untuk mendeteksi warna kulit guna menentukan kecocokan antara warna kulit dan warna busana. Meskipun demikian, sebagian besar penelitian yang telah ada masih membatasi keluarannya pada pengelompokan kelas diskrit yang kaku atau penyajian rekomendasi palet warna busana secara umum tanpa menyediakan sistem penilaian numerik yang personal.

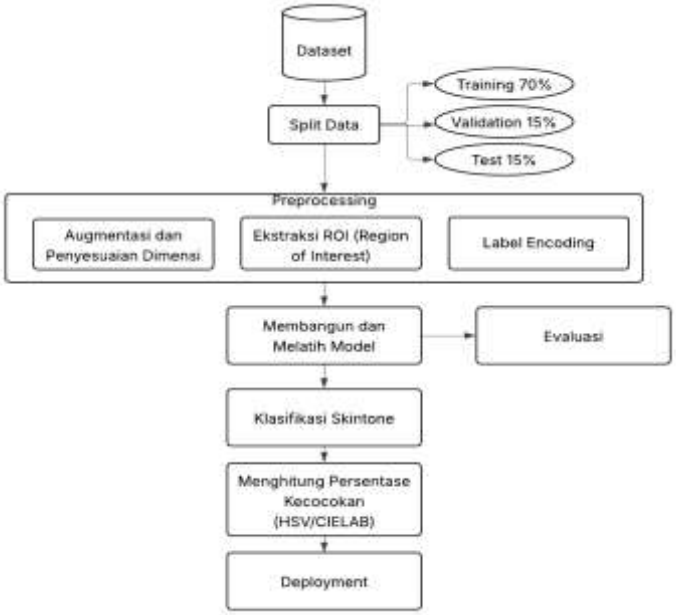
Tinjauan Penelitian Sebelumnya dan Posisi Kebaruan (*State of the Art*)

Posisi kebaruan (*novelty*) dari penelitian ini hadir untuk melengkapi celah penelitian (*research gap*) tersebut. Sistem yang dikembangkan tidak hanya berhenti pada klasifikasi citra wajah ke dalam kelas *skintone* (Light, Medium, Dark) menggunakan arsitektur MobileNetV2, melainkan melanjutkan ke tahap ekstraksi nilai riil warna kulit dari area wajah (*Region of Interest*) yang telah dilokalisasi menggunakan MediaPipe Face Detection. Nilai piksel tersebut kemudian dikonversi secara simultan ke dalam ruang warna CIELAB dan HSV untuk dihitung persentase kecocokannya terhadap variasi warna pakaian melalui metode penilaian berbobot (*weighted multi-parameter scoring*) berbasis lima dimensi estetika (*Hue, Undertone, Value, Saturation*, dan ΔE^*_{ab}). Pendekatan ini memungkinkan sistem menghasilkan rekomendasi warna busana yang tidak hanya objektif dan presisi secara matematis, tetapi juga bersifat personal dan aplikatif bagi pengguna (Fortuna et al., 2024; Prabowo et al., 2024; Perrett & Sprengelmeyer, 2021).

3. METODE PENELITIAN

Desain Penelitian dan Alur Sistem

Penelitian ini menggunakan pendekatan eksperimental terapan berbasis *computer vision* dan *machine learning* untuk membangun sistem klasifikasi *skintone* wajah sekaligus memberikan rekomendasi persentase kecocokan warna pakaian secara objektif. Alur penelitian dirancang secara sistematis melalui beberapa tahapan utama yang mencakup pengumpulan data, prapemrosesan citra (*preprocessing*), pengembangan dan pelatihan model *Convolutional Neural Network* (CNN), ekstraksi nilai warna kulit, perumusan algoritma penilaian keselarasan multi-parameter (*weighted scoring*), serta pengujian dan evaluasi kinerja sistem. Alur penelitian lebih lengkapnya dapat dilihat pada Gambar 1. berikut.



Gambar 1. Alur Penelitian.

Populasi, Sampel, dan Dataset Penelitian

Data yang digunakan dalam penelitian ini terdiri atas dua komponen utama, yaitu dataset citra wajah dan data atribut warna pakaian. Dataset citra wajah diperoleh dari repositori publik Roboflow dengan total sampel sebanyak 2.935 citra wajah tampak depan (*frontal view*) dalam format RGB. Sampel tersebut dikelompokkan ke dalam tiga kelas *skintone*, yaitu *Dark* (1.013 citra), *Medium* (979 citra), dan *Light* (943 citra). Seluruh dataset kemudian dipisahkan secara acak menjadi data latih (*training*) sebesar 70% (2.574 citra), data validasi (*validation*) sebesar 15% (247 citra), dan data uji (*testing*) sebesar 15% (114 citra) untuk menjamin objektivitas evaluasi serta menghindari *data leakage*. Sementara itu, data warna pakaian ditentukan sebanyak 18 warna representatif yang mencakup kelompok *neutral color* (seperti *black, charcoal, grey, taupe, ivory, white*), *warm color* (seperti *peach, mustard, coral, gold, rust, burgundy*), dan *cool color* (seperti *sky blue, navy, teal, emerald, lavender, plum*) yang umum digunakan dalam dunia mode.

Teknik Pengumpulan Data dan Instrumen Penelitian

Instrumen pengumpulan data citra wajah dilakukan melalui penarikan data digital teranotasi dan penyeragaman format visual. Untuk instrumen validasi keselarasan warna pakaian, penelitian ini melibatkan validator ahli di bidang tata busana, yaitu akademisi dari Program Studi Pendidikan Tata Busana. Pengujian instrumen difokuskan pada validitas isi dan kelayakan logika rekomendasi warna pakaian. Berdasarkan hasil pengujian validasi ahli, instrumen dan sistem rekomendasi dinyatakan "Layak" digunakan dengan skor rata-rata

evaluasi sebesar 3,8 dari skala 5 (kategori Baik), yang mengonfirmasi bahwa parameter estetika dan formula penilaian yang dirumuskan telah sesuai dengan kaidah harmonisasi tata busana. Eksperimen komputasi dan implementasi sistem didukung oleh perangkat keras laptop berspesifikasi AMD Ryzen 5 7640HS dengan RAM 8 GB, serta perangkat lunak berbasis lingkungan pemrograman Python menggunakan pustaka utama TensorFlow/Keras, MediaPipe, NumPy, Scikit-Image, Matplotlib, dan kerangka kerja Flask untuk implementasi antarmuka web.

Tahapan Prapemrosesan Citra

Tahap prapemrosesan data bertujuan meningkatkan keterbacaan fitur dan efisiensi komputasi model, yang meliputi: Ekstraksi *Region of Interest* (ROI): Menggunakan pustaka MediaPipe Face Detection untuk melokalisasi area wajah pengguna ke dalam bentuk *bounding box* koordinat yang kemudian dipotong (*crop*), sehingga model terisolasi dari gangguan latar belakang (*background*). Penyesuaian Dimensi (*Resize*) dan Normalisasi: Citra wajah diseragamkan ke dimensi 224 × 224 piksel dengan nilai intensitas piksel yang dinormalisasi ke dalam rentang 0 hingga 1 melalui pembagian skala 255 guna mempercepat konvergensi model. Augmentasi Data**:** Diterapkan khusus pada data latih menggunakan transformasi acak seperti *horizontal flip*, *rotation*, dan penyesuaian skala (*zoom*) untuk memperkaya variasi data serta mereduksi risiko *overfitting*. Dengan rumus rumus sebagai berikut:$horizontal\ flip = x' = W - 1 - x, y' = y, rotation = \begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} x - c_x \\ y - c_y \end{bmatrix} + \begin{bmatrix} c_x \\ c_y \end{bmatrix}$, $scale\ = y' = s(y - c_y) + c_y$.

Keterangan: x, y: Koordinat pixel awal, x', y': Koordinat pixel setelah transformasi, W: Lebar citra dalam pixel, c_x, c_y: Koordinat titik pusat citra, θ: Sudut rotasi dalam radian, s: faktor skala, dengan $s > 1$ untuk memperbesar dan $0 < s < 1$ untuk memperkecil citra. Hasil augmentasi data dapat dilihat pada Gambar 2. dibawah



Gambar 2. Hasil Augmentasi Data.

Model Klasifikasi dan Arsitektur Jaringan

Model klasifikasi skintone dikembangkan menggunakan pendekatan transfer learning dengan MobileNetV2 sebagai feature extractor. Fitur berukuran $7 \times 7 \times 1280$ diproses melalui Global Average Pooling, Batch Normalization, Dense 128 neuron dengan aktivasi ReLU, Dropout, dan lapisan output 3 neuron dengan aktivasi Softmax untuk mengklasifikasikan kelas Light, Medium, dan Dark. Pelatihan menggunakan Adam optimizer dengan learning rate 10^{-4}, batch size 32, fungsi kerugian Categorical Cross-Entropy, dan 15 epoch. Perumusan matematis konvolusi, ReLU, Softmax, dan fungsi kerugian mengacu pada Nugroho et al. (2020) serta Sadewa dan Yamasari (2024).

Setelah kategori *skintone* teridentifikasi, sistem mengekstraksi nilai piksel rata-rata RGB pada area tengah wajah dan mengonversinya ke ruang warna CIELAB ($L^*a^*b^*$) serta HSV (*Hue, Saturation, Value*). Transformasi dan pengukuran jarak persepsi warna Euclidean ΔE^*_{ab} merujuk pada standar CIE (Astiningrum et al., 2019). Persentase kecocokan warna pakaian terhadap warna kulit pemakai dihitung menggunakan model penilaian berbobot (*weighted multi-parameter scoring*) yang mengintegrasikan lima dimensi estetika busana: Final Score $= (0{,}22 \times h) + (0{,}23 \times u) + (0{,}20 \times v) + (0{,}10 \times s) + (0{,}25 \times d)$Pada model di atas, nilai kecocokan akhir (Final Score) dinyatakan dalam persentase rentang 0 hingga 100%, di mana h merepresentasikan *Hue Score* yang mengukur keselarasan rona lingkaran warna HSV, u menyatakan *Undertone Score* untuk kesesuaian temperatur suhu warna (hangat, dingin, atau netral), v menunjukkan *Value Score* untuk mengukur kontras kecerahan luminansi (L^*), merepres *s*entasikan *Saturation Score* untuk menjaga keseimbangan kejenuhan kroma, dan d merupakan *LAB Distance Score* yang mengukur batas proporsional jarak perseptual warna ΔE^*_{ab}. Besaran koefisien bobot pada masing-masing variabel ditetapkan berdasarkan hasil perumusan bersama validator ahli tata busana.

Alat Analisis dan Metrik Evaluasi Data

Kinerja klasifikasi model dievaluasi secara kuantitatif menggunakan data uji (*testing data*) melalui *confusion matrix*. Metrik evaluasi yang digunakan meliputi akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*, di mana perumusan matematis masing-masing metrik merujuk pada kaidah evaluasi klasifikasi standar (Fadli & Saputra, 2023; Karnadi & Handhayani, 2024; Rustam et al., 2021). Hasil inferensi akhir kemudian disajikan ke dalam aplikasi prototipe berbasis web menggunakan perankingan nilai kecocokan warna busana dari persentase tertinggi ke terendah.

4. HASIL DAN PEMBAHASAN

Pengumpulan Data, Waktu, dan Lokasi Penelitian

Penelitian ini dilaksanakan di Laboratorium Komputer Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Negeri Medan, yang beralamat di Jalan William Iskandar Pasar V, Percut Sei Tuan, Deli Serdang, Sumatera Utara. Rentang waktu pelaksanaan penelitian berlangsung mulai bulan Desember 2024 hingga selesai pada bulan Juni 2026.

Pengumpulan dataset citra wajah dihimpun melalui repositori publik Roboflow yang memuat variasi karakteristik warna kulit manusia tampak depan (*frontal view*). Total data citra yang dikumpulkan berjumlah 2.935 sampel citra berformat digital RGB yang terbagi secara proporsional ke dalam tiga kategori *skintone*, yaitu *Dark* sebanyak 1.013 citra, *Medium* sebanyak 979 citra, dan *Light* sebanyak 943 citra. Sebelum digunakan dalam tahapan pemodelan, dataset diseparasi secara acak menggunakan rasio pembagian 70% data latih (*training*), 15% data validasi (*validation*), dan 15% data uji (*testing*). Distribusi pembagian dataset disajikan pada Tabel 1.

Tabel 1. Pembagian Data.

Kelas Skintone	Data Latih (70%)	Data Validasi (15%)	Data Uji (15%)	Total Citra
Dark	906	69	38	1.013
Medium	855	85	39	979
Light	813	93	37	943
Total	2.574	247	114	2.935

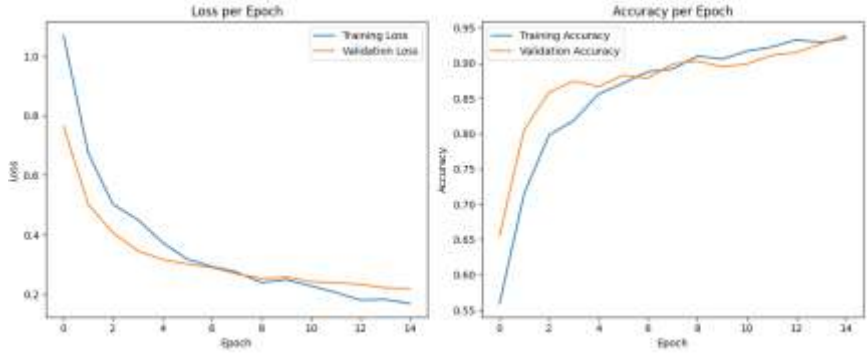
Berdasarkan Tabel 1, pemisahan data ini dirancang untuk menjaga integritas pengujian model *deep learning* agar terbebas dari bias kebocoran data (*data leakage*), sehingga kinerja generalisasi model dapat diuji secara objektif terhadap sampel yang belum pernah dilihat sebelumnya.

Hasil Analisis Data dan Kinerja Model CNN

Pelatihan dan Evaluasi Model MobileNetV2

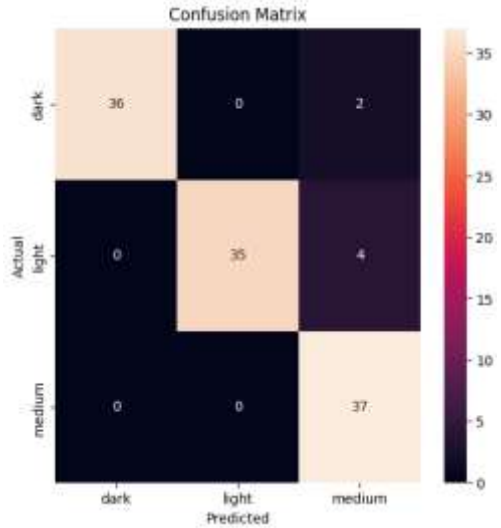
Proses prapemrosesan data diawali dengan deteksi area wajah menggunakan MediaPipe Face Detection untuk mengisolasi *Region of Interest* (ROI), penyeragaman resolusi citra menjadi 224x224 piksel, serta normalisasi nilai intensitas piksel ke rentang 0 hingga 1. Khusus pada subset data latih, teknik augmentasi data berupa *random horizontal flip*, rotasi acak, dan variasi skala (*zoom*) diimplementasikan guna meningkatkan variasi data dan ketahanan model terhadap variasi pose wajah. Model CNN yang dikembangkan memanfaatkan mekanisme *transfer learning* dari arsitektur MobileNetV2 sebagai pengekstraksi fitur (*feature extractor*) dasar berbobot terbekukan (*frozen*), yang kemudian diintegrasikan dengan lapisan klasifikasi kustom meliputi *Global Average Pooling*, *Batch Normalization*, *Dense layer* (128

neuron dengan aktivasi ReLU), *Dropout* (rasio 0,2), dan *Dense output layer* (3 neuron dengan aktivasi Softmax). Total parameter yang terlibat mencapai 2.427.459 parameter, dengan 166.915 parameter latih (*trainable parameters*). Model dilatih selama 15 *epoch* dengan *batch size* 32 dan laju pembelajaran 10^{-4} menggunakan *optimizer* Adam dan fungsi kerugian *Categorical Cross-Entropy*. Kurva hasil pelatihan ditampilkan pada Gambar 3.



Gambar 3. Kurva Hasil Pelatihan.

Kinerja klasifikasi model dievaluasi secara terperinci menggunakan data uji (*testing data*) sebanyak 114 citra. Evaluasi dilakukan dengan menyusun *confusion matrix* multikelas yang disajikan pada Gambar 4 dibawah dan kemudian direkapitulasi ke dalam metrik presisi (*precision*), *recall*, *F1-score*, dan akurasi (*accuracy*). Rekapitulasi hasil evaluasi kinerja model disajikan pada Tabel 2.



Gambar 4. Confusion Matrix.

Tabel 2. Hasil Evaluasi Kinerja Model.

Kelas Skintone	Jumlah Data Uji	Presisi (Precision)	Recall	F1-Score	Akurasi (Accuracy)
Dark	38	1,00	0,95	0,97	-
Medium	39	0,86	1,00	0,92	-
Light	37	1,00	0,90	0,95	-
Rata-rata / Total	114	0,95	0,95	0,95	94,7%

Mengacu pada Tabel 2, model CNN MobileNetV2 berhasil mengklasifikasikan 108 dari 114 citra uji dengan akurasi 94,7%. Kelas *Dark* dan *Light* memperoleh presisi 1,00, sedangkan kelas *Medium* memiliki presisi 0,86 dan recall 1,00. Kesalahan klasifikasi terjadi pada 6 citra *Dark* dan *Light* yang diprediksi sebagai *Medium*, diduga akibat perbedaan pencahayaan dan kemiripan luminansi. Meski demikian, nilai *F1-score* di atas 0,92 pada seluruh kelas menunjukkan kemampuan klasifikasi yang baik.

Ekstraksi Nilai Warna dan Konversi Ruang Warna

Setelah kategori *skintone* diprediksi oleh jaringan CNN, sistem mengekstraksi nilai piksel representatif pada area kulit wajah hasil deteksi MediaPipe. Nilai warna kulit diperoleh melalui perhitungan rata-rata intensitas piksel (*mean pixel value*) pada kanal warna Red, Green, dan Blue (RGB) untuk meredam derau (*noise*) mikroskopis permukaan kulit. Vektor warna RGB tersebut selanjutnya dinormalisasi dan ditransformasikan ke dalam ruang warna CIELAB ($L^*a^*b^*$) untuk memperoleh koordinat luminansi serta kromatisitas yang seragam secara perseptual. Hasil perbandingan ekstraksi warna RGB dan konversinya ke CIELAB pada tiga sampel representatif ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Hasil RGB dan Nilai CILEAB Tiap Sampel.

Sampel Skintone	Nilai Rata-rata RGB	Nilai Kecerahan (L∗)	Sumbu Merah-Hijau (a∗)	Sumbu Kuning-Biru (b∗)
Sampel 1 (*Light*)	(226, 207, 194)	84,6	4,5	8,9
Sampel 2 (*Medium*)	(193, 133, 103)	63,1	18,2	24,7
Sampel 3 (*Dark*)	(80, 54, 42)	27,3	10,5	13,2

Berdasarkan data pada Tabel 3, koordinat L^* menunjukkan penurunan linear yang mencerminkan transisi kecerahan dari kulit *Light* (84,6), *Medium* (63,1), hingga *Dark* (27,3). Selain itu, seluruh sampel menghasilkan nilai a^* dan b^* yang bernilai positif, yang merepresentasikan kecenderungan pigmen ke arah rona kemerahan (*reddish*) dan kekuningan (*yellowish*), menandakan keberadaan *warm undertone* alami yang dominan pada populasi sampel wajah yang diuji

Penentuan tingkat keselarasan antara warna kulit pengguna dan warna busana dihitung menggunakan metode pembobotan multi-parameter (*weighted multi-parameter scoring*). Pengujian matematis dilakukan dengan mensimulasikan sampel warna kulit kategori *Medium* dengan nilai RGB (193, 133, 103), sudut rona *Hue* $\$ 20°$, *Saturation* 0,46, serta koordinat CIELAB (63,1; 18,2; 24,7) terhadap warna busana *Burgundy* yang memiliki nilai *Hue* $345°$, *Saturation* 1,00, dan CIELAB (25,5; 48,0; 15,2). Perhitungan kelima dimensi parameter diuraikan sebagai berikut: *Hue Score* (h), Selisih sudut rona lingkaran warna dihitung menggunakan *circular hue calculation*: $\text{diff} =$

$\min(\quad |20^\circ - 345^\circ|, 360^\circ - |20^\circ - 345^\circ| \quad) = \min(325^\circ, 35^\circ) = 35^\circ$. Berdasarkan aturan penilaian sudut rona, selisih 35° berada pada rentang $< 90^\circ$, menghasilkan skor $h = 65$, yang mengindikasikan adanya hubungan analog yang harmonis pada roda warna. *Undertone Score (u).* Karakteristik warna kulit sampel memiliki temperatur *warm*, yang berpasangan secara selaras dengan atribut termal warna *Burgundy* yang juga berkarakter *warm*. Kesesuaian temperatur ini menghasilkan skor keselarasan maksimal $u = 95$. *Value Score (v).* Kontras kecerahan dihitung melalui selisih absolut nilai luminansi CIELAB: $\text{diff}_{L^*} = |63{,}1 - 25{,}5| = 37{,}6$. Selisih nilai L^* sebesar 37,6 berada pada interval > 30, menghasilkan perolehan nilai $v = 75$, yang membuktikan adanya tingkat kontras terang-gelap yang memadai agar busana tampak tegas terhadap warna kulit pengguna. *Saturation Score (s).* Tingkat kejenuhan kroma warna busana (Burgundy = 1,00) memiliki nilai yang lebih tinggi daripada saturasi warna kulit ditambah batas ambang ($0{,}46 + 0{,}30 = 0{,}76$). Kondisi ini menghasilkan nilai $s = 80$, yang memastikan busana memberikan kesan vitalitas visual yang segar dan tidak terlihat kusam. *Lab Distance Score (d)*, Jarak perbedaan warna perseptual dihitung melalui jarak EuclideanΔE^*_{ab}:$\Delta E^*_{ab} = \sqrt{(63{,}1 - 25{,}5)^2 + (18{,}2 - 48{,}0)^2 + (24{,}7 - 15{,}2)^2} = \sqrt{1413{,}76 + 888{,}04 + 90{,}25} \approx 48{,}9$. Nilai ΔE^*_{ab} sebesar 48,9 berada pada interval proporsional ideal (20–50), menghasilkan skor $d = 95$. Hal ini membuktikan warna pakaian memiliki kontras perseptual yang pas—tidak terlalu identik yang menyebabkan *washed-out effect*, dan tidak terlalu kontras secara ekstrem. Rekapitulasi integrasi kelima parameter beserta bobot penilaian yang divalidasi oleh ahli tata busana dimuat pada Tabel 4.

Tabel 4. Parameter Bobot Penilaian.

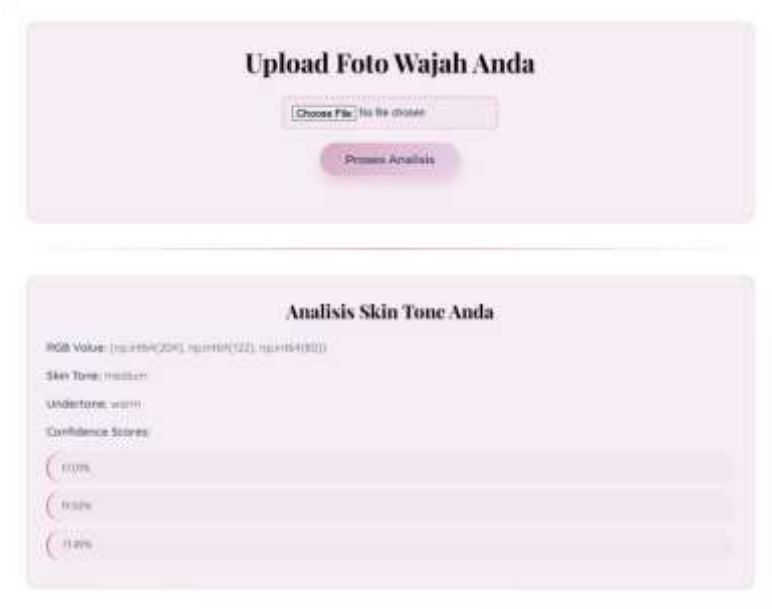
Parameter Estetika	Nilai Parameter	Bobot (w)	Skor Terbobot (w×Skor)
Hue Score (h)	65	0,22	14,30
Undertone Score (u)	95	0,23	21,85
Value Score (v)	75	0,20	15,00
Saturation Score (s)	80	0,10	8,00
LAB Distance Score (d)	95	0,25	23,75
Skor Akhir (*Final Match Score*)	-	1,00	82,90%

Mengacu pada Tabel 4, integrasi seluruh parameter menghasilkan persentase kecocokan akhir sebesar 82,90%, yang mengonfirmasi bahwa warna *Burgundy* memiliki derajat keselarasan estetika yang sangat tinggi terhadap individu dengan karakteristik *skintone Medium* dan *warm undertone*.

Deployment Sistem Berbasis Web

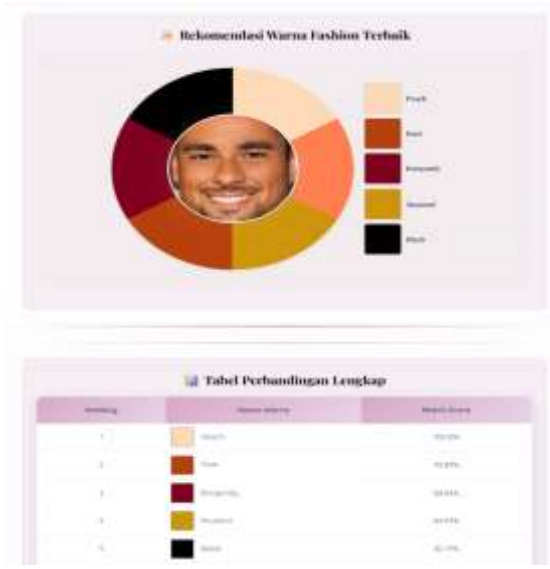
Tahap *deployment* bertujuan untuk mengintegrasikan model klasifikasi *skintone* dan algoritma *weighted multi-parameter scoring* ke dalam aplikasi berbasis web yang interaktif dan dapat diakses oleh pengguna akhir. Sistem dikembangkan menggunakan bahasa

pemrograman Python dengan arsitektur *server-side inferencing*. *Framework* Flask digunakan sebagai *backend* utama untuk menangani alur logika komputasi, menerima berkas masukan dari pengguna, memanggil model MobileNetV2 berformat .h5 via TensorFlow/Keras, serta mengeksekusi konversi ruang warna dan formula penilaian keselarasan busana. Pada bagian antarmuka depan (*frontend*), tata letak dirancang responsif menggunakan kombinasi HTML, CSS, dan JavaScript. Formulir Unggah Citra dan Analisis Skintone, Halaman awal sistem menyediakan formulir interaktif bagi pengguna untuk mengunggah citra wajah tampak depan melalui tombol *Choose File* dan memicu proses inferensi melalui tombol *Proses Analisis*. Ketika citra diproses, sistem melokalisasi area wajah menggunakan MediaPipe Face Detection, mengekstraksi nilai rata-rata piksel RGB, serta memprediksi kategori *skintone* beserta probabilitasnya. Tampilan antarmuka masukan dan hasil analisis warna kulit disajikan pada Gambar 5.



Gambar 5. Formulir Unggah Gambar.

Visualisasi Harmonisasi dan Perankingan Rekomendasi Busana, Setelah tahapan ekstraksi karakteristik kulit dan klasifikasi *skintone* selesai, sistem secara otomatis mengeksekusi perhitungan persentase keselarasan terhadap seluruh basis data warna pakaian menggunakan algoritma *weighted multi-parameter scoring*. Hasil rekomendasi disajikan secara visual melalui diagram lingkaran harmonisasi warna (*color wheel wheel representation*) yang memusatkan potongan ROI wajah pengguna di bagian tengah, serta didampingi oleh tabel perankingan nilai keselarasan busana (*Match Score*) dari persentase tertinggi ke terendah. Implementasi keluaran rekomendasi warna fashion disajikan pada Gambar 6.



Gambar 6. Visualisai Harmonisasi dan Rangking Warna Busana.

Pembahasan dan Implikasi

Hasil penelitian ini membuktikan secara empiris bahwa penentuan keselarasan warna busana tidak dapat diselesaikan semata-mata melalui prinsip kedekatan jarak visual murni (*color similarity*). Berdasarkan teori estetika busana (*clothing aesthetics*) dan teori warna musiman (*Seasonal Color Theory*), busana yang memiliki kroma dan kecerahan identik dengan warna kulit justru menimbulkan efek visual yang pucat dan tersamarkan (*washed-out effect*) (Perrett & Sprengelmeyer, 2021). Temuan ini tercermin secara konsisten dalam model penilaian yang dirancang, di mana nilai ΔE^*_{ab} terendah (< 20) memperoleh skor minimal (40), sedangkan jarak perseptual moderat pada interval 20–50 menghasilkan skor optimal (95). Hal ini mengonfirmasi bahwa keselarasan busana menuntut keseimbangan antara harmoni temperatur rona (*undertone*) dan diferensiasi kontras luminansi yang terukur (Aja & Gebbert, 2019).

Jika dibandingkan dengan kajian terdahulu, pendekatan yang diajukan berhasil mengatasi sejumlah limitasi metodologis. Studi oleh Manza et al. (2025) hanya berfokus pada pelabelan warna pakaian tanpa mempertimbangkan atribut fisik pemakai. Di sisi lain, riset berbasis CNN oleh Fayyadhila et al. (2021), Fortuna et al. (2024), serta Anupama et al. (2025) mampu mengenali warna kulit dan *undertone* secara akurat, namun keluarannya terbatas pada rekomendasi tata rias atau klasifikasi diskrit yang kaku. Sementara itu, model rekomendasi busana yang diajukan Prabowo et al. (2024) masih menyajikan rekomendasi palet statis secara umum. Penelitian ini berhasil menjembatani celah tersebut dengan mengintegrasikan klasifikasi MobileNetV2 berakurasi 94,7% dan formulasi *weighted multi-parameter scoring* berbasis CIELAB serta HSV, menghasilkan rekomendasi persentase numerik yang dinamis,

terurut (*ranking*), dan divalidasi layak oleh ahli tata busana dengan skor 3,8 dari skala 5. Secara teoretis, integrasi multi-ruang warna ini memberikan landasan komputasi baru untuk memodelkan prinsip estetika busana ke dalam representasi matematika yang objektif. Secara terapan, sistem yang telah diimplementasikan ke dalam prototipe web berbasis Flask ini siap diadopsi pada platform *e-commerce*, layanan *AI personal stylist*, maupun etalase ritel busana daring guna menekan angka ketidaksesuaian pemilihan warna pakaian secara mandiri oleh konsumen.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem klasifikasi *skin tone* menggunakan arsitektur CNN berbasis MobileNetV2 dan metode *weighted multi-parameter scoring* untuk menentukan persentase kecocokan warna pakaian. Berdasarkan hasil pengujian, model klasifikasi memperoleh akurasi sebesar 94,7%. Sistem juga berhasil diimplementasikan dalam prototipe web yang menampilkan hasil prediksi *skin tone* serta persentase kecocokan warna pakaian berdasarkan lima parameter, yaitu Hue Score, Undertone Score, Value Score, Saturation Score, dan LAB Distance Score, yang melibatkan ruang warna HSV dan CIELAB. Hasil evaluasi oleh ahli tata busana memperoleh skor 3,8 dari 5, yang menunjukkan adanya penilaian ahli terhadap hasil rekomendasi yang dihasilkan sistem. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada penggunaan 18 palet warna pakaian, pengaruh variasi pencahayaan terhadap citra wajah, serta belum dipertimbangkannya atribut fisik dan preferensi pengguna lainnya. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dan meningkatkan keragaman dataset, membandingkan kinerja beberapa arsitektur model, memperluas variasi palet warna, serta mengintegrasikan atribut fisik dan preferensi pengguna. Pengembangan tersebut diharapkan dapat meningkatkan cakupan dan personalisasi rekomendasi warna pakaian pada kondisi penggunaan yang lebih beragam.

DAFTAR REFERENSI

Agustina, R., Magdalena, R., & Pratiwi, N. K. C. (2022). Klasifikasi kanker kulit menggunakan metode convolutional neural network dengan arsitektur VGG-16. ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika, 10(2), 446–458. https://doi.org/10.26760/elkomika.v10i2.446

Aja, C., & Gebbert, B. (2019). Does black suit everyone? The fit between skin tone and clothing color. Semantic Scholar. https://api.semanticscholar.org/CorpusID:218057342

Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi metode convolutional neural network menggunakan arsitektur LeNet-5 untuk pengenalan doodle. Jurnal Algoritme, 1(1), 45–56.

Anhar, A., & Putra, R. A. (2023). Perancangan dan implementasi self-checkout system pada toko ritel menggunakan convolutional neural network (CNN). ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika, 11(2), 466–478. https://doi.org/10.26760/elkomika.v11i2.466

Anupama, M. M., Aditya, M., Bindu, M., Prriya, M. G. G., & Prajna, M. (2025). Colour analysis using deep learning: Automating the future of colour detection and classification. International Journal of Advanced Research in Science, Communication and Technology, 1–7.

Aryanti, W. (2023). Penerapan artificial neural network dengan algoritma backpropagation untuk memprediksi harga saham. Jurnal Riset Statistika, 3(2), 107–118.

Astiningrum, M., Mentari, M., & Maranatha, Y. G. (2019). Ekstraksi fitur citra buah salak untuk penentuan mutu buah salak menggunakan pengolahan citra digital. Dalam Seminar Informatika Aplikatif Polinema (SIAP) (hlm. 205–210).

Azmi, K., Defit, S., & Sumijan, S. (2023). Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat Sumatera Barat. Jurnal Unitek, 16(1), 28–40. https://doi.org/10.52072/unitek.v16i1.504

Brownlee, J., Chng, Z. M., Chung, D., Cristina, S., Saeed, M., & Tam, A. (2022). Python for machine learning: Learn Python from machine learning projects. Machine Learning Mastery.

Coleman, W., Mariwalla, K., & Grimes, P. (2023). Updating the Fitzpatrick classification: The skin color and ethnicity scale. Dermatologic Surgery, 49(8), 725–731. https://doi.org/10.1097/DSS.0000000000003860

Fadli, M., & Saputra, R. A. (2023). Klasifikasi dan evaluasi performa model random forest untuk prediksi stroke. Jurnal Teknik, 12(1), 1–8.

Fayyadhila, R., Junaidi, A., & Prasetyo, N. A. (2021). Implementasi deep learning untuk klasifikasi citra undertone menggunakan algoritma convolutional neural network. Jurnal Informatika dan Rekayasa Perangkat Lunak, 3(2), 112–119.

Fortuna, D., Tahyudin, I., & Utomo, F. S. (2024). Optimization in makeup recommendations using RGB and YCbCr analysis with CNN algorithm for skin undertone. Dalam 2024 8th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE) (hlm. 545–550). IEEE. https://doi.org/10.1109/ICITISEE63424.2024.10730153

High, W. A., & Prok, L. D. (2021). Dermatology secrets (Edisi ke-6). Elsevier.

Ide, H., & Kurita, T. (2017). Improvement of learning for CNN with ReLU activation by introducing gating mechanism. Dalam 2017 International Joint Conference on Neural Networks (IJCNN) (hlm. 1655–1662). IEEE.

Jablonski, N. G. (2006). Skin: A natural history. University of California Press.

Juanita, R. A., & Juliadi, D. (2020). Penetapan potensi tabir surya krim ekstrak etanol daun ceremai (Phyllanthus acidus L.) dengan spektrofotometri UV-Vis. Jurnal Farmagazine, 7(1), 51–58. https://doi.org/10.47653/farm.v7i1.154

Karnadi, B., & Handhayani, T. (2024). Klasifikasi jenis buah dengan menggunakan metode MobileNetV2 dan InceptionV3. Jurnal Eksplora Informatika, 14(1), 35–42. https://doi.org/10.30864/eksplora.v14i1.1067

Kusuma, T. A. A. H., Usman, K., & Saidah, S. (2021). People counting for public transportations using You Only Look Once method. Jurnal Teknik Informatika (JUTIF), 2(1), 57–66. https://doi.org/10.20884/1.jutif.2021.2.2.77

Magdalena, R., Saidah, S., Pratiwi, N. K. C., & Putra, A. T. (2021). Klasifikasi tutupan lahan melalui citra satelit SPOT-6 dengan metode convolutional neural network (CNN). Jurnal Edukasi dan Penelitian Informatika (JEPIN), 7(3), 335–342. https://doi.org/10.26418/jp.v7i3.48195

Manza, Y., Suhada, M. W. D., Ndruru, A. F. S., & Rosnelly, R. (2025). Model machine learning untuk klasifikasi warna fashion menggunakan metode K-nearest neighbor. Jurnal Komputasi dan Sistem Informasi, 4(1), 20–29.

Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. Dalam Proceedings of the 27th International Conference on Machine Learning (ICML) (hlm. 807–814).

Nugraha, W., & Sasongko, A. (2022). Hyperparameter tuning on classification algorithm with grid search. Sistemasi: Jurnal Sistem Informasi, 11(2), 391–401. https://doi.org/10.32520/stmsi.v11i2.1750

Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia. Algor: Jurnal Ilmiah Komputer, 2(1), 12–20.

Okta, T. (2023). Perbandingan kinerja arsitektur LeNet dan AlexNet untuk klasifikasi citra aksara Lampung [Skripsi, Universitas Lampung]. Repositori Institusi.

Perrett, D. I., & Sprengelmeyer, R. (2021). Clothing aesthetics: Consistent colour choices to match fair and tanned skin tones. i-Perception, 12(6), 1–17. https://doi.org/10.1177/20416695211053361

Prabowo, F. W., Homaidi, A., & Lutfi, A. (2024). Deteksi warna kulit menggunakan metode deep learning dengan CNN (convolutional neural network) untuk menentukan kecocokan warna kulit dan warna busana. Jurnal J-Intech, 12(1), 45–54.

Pratiwi, H. A., Cahyanti, M., & Lamsani, M. (2021). Implementasi deep learning flower scanner menggunakan metode convolutional neural network. Sebatik, 25(1), 124–130. https://doi.org/10.46984/sebatik.v25i1.1297

Rustam, F., Siddique, M. A., Siddiqui, H. U. R., Ullah, S., Mehmood, A., Ashraf, I., & Choi, G. S. (2021). Wireless capsule endoscopy bleeding images classification using CNN based model. IEEE Access, 9, 33675–33688. https://doi.org/10.1109/ACCESS.2021.3061592

Sadewa, B. A., & Yamasari, Y. (2024). Implementasi deep transfer learning untuk klasifikasi nominal uang kertas rupiah. Journal of Informatics and Computer Science (JINACS), 5(4), 543–551. https://doi.org/10.26740/jinacs.v5n04.p543-551

Tugas, M. A. F. A., Ramadhani, K. N., & Sthevanie, F. (2020). Klasifikasi ras pada kucing menggunakan algoritma convolutional neural network (CNN). e-Proceeding of Engineering, 7(2), 6523–6530.

Wardani, K. R., & Leonardi, L. (2023). Klasifikasi penyakit pada daun anggur menggunakan metode convolutional neural network. Jurnal Tekno Insentif, 17(2), 112–126. https://doi.org/10.36787/jti.v17i2.1130

Wasil, M., Dewi, P. P., & Arafah, A. P. (2022). The influence of ROA, ROE, and DER on stock price with dividend policy as an intervening variable. Indonesia Accounting Research Journal, 10(2), 48–56. https://doi.org/10.35335/iarj.v10i2.8