

Classification Of Facial Skin Problems Using Convolutional Neural Networks (CNN) And Content-Based Filtering For Skincare Product Recommendation

Mila Cahyani ¹⁾ Sefrika Entas ²⁾; Faisal ³⁾

^{1,2,3)} Study Program of Information Systems, Faculty of Engineering and Informatics, Universitas Bina Sarana Informatika

Email: ¹⁾ milachyn05@gmail.com

How to Cite :

Cahyani, M. (2026). Classification of Facial Skin Problems Using Convolutional Neural Networks (CNN) and Content-Based Filtering for Skincare Product Recommendation. Jurnal Media Computer Science. 5 (4).

ARTICLE HISTORY

Received [22 September 2026]

Revised [23 Oktober 2026]

Accepted [26 Oktober 2026]

KEYWORDS

Klasifikasi Kulit Wajah, ResNet50V2, Transfer Learning, Content-Based Filtering, Skincare.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Banyak konsumen kesulitan mengidentifikasi masalah kulit wajah secara mandiri akibat keterbatasan akses terhadap layanan dermatologi. Penelitian ini bertujuan mengklasifikasikan tujuh masalah kulit wajah menggunakan CNN ResNet50V2 dan menghasilkan rekomendasi produk skincare berbasis Content-Based Filtering menggunakan TF-IDF dan Cosine Similarity. Dataset terdiri atas 2.450 citra kulit wajah dengan jumlah 350 citra untuk setiap kelas. Model dilatih melalui tiga fase progressive fine-tuning dengan kepala klasifikasi Dual Pooling dan Test-Time Augmentation, serta dilengkapi validasi input melalui deteksi wajah dan ambang confidence score. Hasil pengujian menunjukkan model mencapai akurasi 82,53% dengan macro F1-score sebesar 0,82. Kelas jerawat memperoleh performa terbaik dengan F1-score 0,89, sedangkan kelas kulit kusam/noda hitam memperoleh F1-score terendah sebesar 0,78 yang berkaitan dengan kemiripan karakteristik visual dengan tanda-tanda penuaan. Sistem rekomendasi menghasilkan rekomendasi produk dengan nilai similarity 0,278–0,321 berdasarkan kesesuaian atribut dan kandungan bahan aktif. Pengujian black box terhadap fungsi sistem menunjukkan seluruh skenario pengujian dinyatakan valid.

ABSTRACT

Many consumers find it difficult to independently identify their facial skin problems due to limited access to dermatological services. This study aims to classify seven facial skin problems using a CNN with ResNet50V2 and generate skincare product recommendations using Content-Based Filtering with TF-IDF and Cosine Similarity. The dataset consists of 2,450 facial skin images, with 350 images for each class. The model was trained through three progressive fine-tuning phases using a Dual Pooling classification head and Test-Time Augmentation, complemented by input validation through face detection and a confidence-score threshold. The results show that the model achieved a test accuracy of 82.53% and a macro F1-score of 0.82. The acne class achieved the highest performance with an F1-score of 0.89, while the dull skin/dark spots class obtained the lowest F1-score of 0.78, which was associated with visual similarities to signs of aging. The recommendation system generated product recommendations with similarity scores ranging from 0.278 to 0.321 based on the relevance of product attributes and active ingredients. Black-box testing showed that all tested system scenarios were valid.

PENDAHULUAN

Industri kecantikan di Indonesia tumbuh pesat seiring meningkatnya daya beli masyarakat, perkembangan platform digital/*e-commerce*, dan perhatian masyarakat terhadap kesehatan kulit. Pasar kosmetik nasional tumbuh *double digit*, sekitar Rp35,6 triliun pada 2025 dan diproyeksikan naik 4,73% per tahun, dengan kategori perawatan kulit menyumbang lebih dari separuh penjualan FMCG di *e-commerce* (Kemenko Perekonomian, 2025).

Namun, pemilihan produk *skincare* yang tepat bergantung pada pemahaman kondisi kulit individu, sementara banyak konsumen kesulitan mengidentifikasi masalah kulitnya secara mandiri—prevalensi penyakit kulit di Indonesia mencapai 12,95% dari populasi (Khani & Rakasiwi, 2025), sedangkan konsultasi dermatolog tidak selalu terjangkau karena keterbatasan waktu, biaya, dan layanan. Kondisi ini memunculkan kebutuhan sistem otomatis untuk identifikasi masalah kulit wajah sekaligus rekomendasi produk *skincare* yang relevan dan objektif.

Deep learning, khususnya *Convolutional Neural Network* (CNN), terbukti efektif menganalisis citra kulit wajah, namun penelitian terdahulu umumnya berfokus pada kondisi kulit dengan karakteristik visual yang relatif berbeda antar kelas. Klasifikasi tujuh masalah kulit wajah sehari-hari (jerawat, kulit kering/dehidrasi, kulit kusam/noda hitam, kulit sensitif/iritasi, pori-pori besar, produksi minyak berlebih, dan tanda-tanda penuaan) lebih kompleks karena perbedaan antarkelas ditentukan oleh tekstur, warna, dan pola sebaran noda, bukan bentuk objek global, karakteristik yang sejalan dengan efektivitas ResNet50V2 pada klasifikasi penyakit daun padi (Saragih & Kurniawan, 2025) dan pneumonia pada citra X-ray (Anwar, 2025), serta perbandingan ResNet50V2, InceptionV3, dan DenseNet121 pada klasifikasi ekspresi wajah yang menunjukkan ResNet50V2 paling efektif (Adi et al., 2025). Meskipun demikian, akurasi klasifikasi tidak hanya bergantung pada kekuatan arsitektur, tetapi juga karakteristik visual data yang diklasifikasikan (Ramdhana & Pratiwi, 2023).

Penelitian terdahulu telah mengeksplorasi klasifikasi kondisi kulit dengan ResNet-50/ResNet50V2 (Anisa, 2024; Anshori et al., 2025; Anwar, 2025; Imaniyah et al., 2026), arsitektur CNN lain (Irryanto et al., 2024; Saputro et al., 2022), maupun sistem rekomendasi *skincare* berbasis *Content-Based Filtering* (Iqbal & Pratama, 2024; Nouvalina & Hati, 2024; Yusuf et al., 2026), namun umumnya hanya berfokus pada salah satu aspek secara terpisah dan belum mengintegrasikan klasifikasi tujuh kategori masalah kulit dengan rekomendasi produk berbasis literatur dermatologi. Pendekatan CBF dengan TF-IDF dan Cosine Similarity dipilih karena mampu merekomendasikan berdasarkan kemiripan kueri dan atribut produk tanpa data historis interaksi (Sulami et al., 2024).

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sistem terintegrasi yang bertujuan untuk: (1) mengembangkan model CNN berbasis ResNet50V2 untuk klasifikasi masalah kulit wajah; (2) mengidentifikasi dan mengklasifikasikan tujuh jenis masalah kulit wajah; (3) mengembangkan sistem rekomendasi berbasis *Content-Based Filtering* untuk kandungan bahan aktif dan produk *skincare* yang sesuai; serta (4) mengevaluasi kinerja model menggunakan accuracy, precision, recall, dan F1-score. Kontribusi penelitian mencakup: (1) justifikasi teknis penggunaan ResNet50V2 pada domain kulit wajah melalui *residual connection*; (2) pemetaan rekomendasi bahan aktif berlandaskan literatur dermatologi, bukan penilaian subjektif; serta (3) evaluasi menyeluruh terhadap keterbatasan sistem, termasuk potensi bias representasi warna kulit dan pola kesalahan klasifikasi antarkelas yang mirip visual.

LANDASAN TEORI

Convolutional Neural Network dan Arsitektur ResNet50V2

ResNet50V2 merupakan varian *Residual Network* dengan susunan *pre-activation* (normalisasi dan aktivasi sebelum konvolusi) sehingga aliran gradien lebih stabil. Koneksi residualnya relevan untuk tekstur kulit wajah karena mempertahankan *identity mapping* yang meneruskan informasi

tekstur tingkat rendah (mikro-kontras, sebaran noda, gradien kecerahan) tanpa degradasi, mengurangi *vanishing gradient*, dan mendukung perbedaan antarkelas kulit yang mirip secara visual.

ResNet50V2 telah diterapkan efektif pada domain lain yang perbedaan kelasnya ditentukan tekstur dan warna, seperti klasifikasi penyakit daun padi (Saragih & Kurniawan, 2025) dan pneumonia pada X-ray (Anwar, 2025), yang berbagi tantangan serupa dengan kulit wajah. Studi lain juga menunjukkan ResNet50V2 paling unggul dibanding InceptionV3 dan DenseNet121 pada ekspresi wajah (Adi et al., 2025), meski akurasi tetap dipengaruhi karakteristik visual data, bukan semata arsitektur (Ramdhana & Pratiwi, 2023).

Content-Based Filtering, TF-IDF, dan Cosine Similarity

Content-Based Filtering (CBF) menghasilkan rekomendasi berdasarkan kemiripan atribut antara kueri (kelas masalah kulit) dengan atribut produk *skincare*, tanpa data historis interaksi sehingga dapat langsung melayani pengguna baru (*cold-start*). TF-IDF mengubah atribut tekstual produk menjadi vektor numerik yang memberi bobot lebih tinggi pada istilah jarang namun informatif, sedangkan *cosine similarity* mengukur kemiripan sudut antar vektor. Pendekatan ini transparan karena berbasis atribut produk yang jelas (jenis, tipe kulit, masalah kulit, bahan aktif) (Sulami et al., 2024).

Dasar Literatur Dermatologi untuk Pemetaan Bahan Aktif


Pemetaan bahan aktif pada sistem rekomendasi dilandaskan pada literatur dermatologi. Niacinamide telah menunjukkan potensi dalam membantu mengurangi hiperpigmentasi pada penggunaan topikal, sebagaimana ditunjukkan melalui penelitian klinis pada pasien dengan melasma (Rocio et al., 2025). Salicylic acid juga telah digunakan dalam penanganan jerawat dan menunjukkan perbaikan terhadap kondisi lesi jerawat dalam penelitian klinis (Oglio et al., 2019).

METODE PENELITIAN

Kerangka Penelitian

Penelitian ini menggunakan metode kuantitatif eksperimen yang menggabungkan klasifikasi citra kulit wajah berbasis CNN ResNet50V2 dengan sistem rekomendasi *skincare* berbasis *Content-Based Filtering*. Kerangka penelitian meliputi input citra wajah, preprocessing, pelatihan model CNN, klasifikasi masalah kulit, pemetaan ke basis data *skincare*, hingga proses CBF, sebagaimana pada Gambar 1.

Gambar 1. Kerangka Metode Penelitian



Dataset dan Pembagian Data

Dataset citra diperoleh dari Kaggle dan Roboflow, diseleksi untuk kualitas dan kesesuaian label. Dataset terdiri atas 2.450 citra (350/kelas, tujuh kelas) untuk menghindari *class imbalance*, dibagi menjadi *training set* (75%), *validation set* (12,5%), dan *test set* (12,5%) dengan *random seed* tetap agar *reproducible* (Tabel 1). Disusun pula dataset 215 produk *skincare* beserta atribut jenis produk, tipe kulit sasaran, masalah kulit, dan bahan aktif sebagai basis sistem rekomendasi.

Karena data bersifat sekunder, label pada citra Kaggle mengikuti anotasi penyedia dataset, sedangkan citra tambahan diseleksi dan diverifikasi manual oleh peneliti berdasarkan kriteria visual acuan tiap kelas (misalnya papul/pustula untuk jerawat, garis halus untuk tanda penuaan). Pemeriksaan visual dilakukan untuk mengecek dominasi ekstrem satu rentang warna kulit, namun

masih kualitatif dan belum menggunakan skala standar seperti *Fitzpatrick Skin Type Scale*, sehingga diakui sebagai keterbatasan yang berpotensi menyebabkan performa tidak merata. Sebagai mitigasi, augmentasi data (variasi kecerahan, kontras, saturasi) diterapkan pada preprocessing. Proses pelabelan juga belum melibatkan validasi dermatolog bersertifikat, berpotensi bias interpretasi visual, sebagaimana disoroti (Alipour et al., 2024).

Tabel 1. Distribusi Dataset Citra Masalah Kulit Wajah

Kelas	Train	Val	Test	Σ
Jerawat	263	43	44	350
Kulit Kering/Dehidrasi	263	43	44	350
Kulit Kusam/Noda Hitam	263	43	44	350
Kulit Sensitif/Iritasi	263	43	44	350
Pori-Pori Besar	263	43	44	350
Produksi Minyak Berlebih	262	44	44	350
Tanda-Tanda Penuaan	262	44	44	350
Total	1.834	301	315	2.450

Preprocessing Data

Tahap preprocessing meliputi: (1) resize citra menjadi 256×256 piksel; (2) normalisasi piksel ke rentang [-1, 1] melalui `preprocess_input()` sesuai standar ResNet50V2; (3) augmentasi (rotasi, flipping, zooming, variasi kecerahan/kontras/saturasi) menggunakan TensorFlow ImageDataGenerator untuk mengurangi *overfitting*; serta (4) seleksi dan pembersihan data untuk menghapus citra buram/duplikat. Kualitas preprocessing berpengaruh signifikan terhadap performa CNN dan kemampuan generalisasi model (Apriyani et al., 2025).

Arsitektur Model CNN

Model klasifikasi menggunakan ResNet50V2 sebagai *backbone* dengan bobot *pre-trained* ImageNet melalui *transfer learning*. Classifier head menggabungkan *Global Average Pooling* (GAP) dan *Global Max Pooling* (GMP) via *concatenate (Dual Pooling)* menghasilkan 4.096 fitur, diteruskan ke tiga lapisan *fully connected* (1024, 512, 256 neuron, aktivasi ReLU) dengan *Batch Normalization*, *Dropout*, dan regularisasi L2 (1×10^{-4}), sebelum output *Softmax* 7 neuron. Model memiliki 28.440.583 parameter, dengan 4.864.519 parameter *trainable* pada tahap awal *transfer learning*.

Pemilihan ResNet50V2 didasarkan pada bukti efektivitasnya pada domain bertekstur sejenis (Landasan Teori), bukan hasil perbandingan empiris langsung dengan arsitektur lain (VGG16, MobileNetV2, EfficientNet) pada dataset yang sama—perbandingan ini menjadi arah penelitian lanjutan pada bagian Kesimpulan dan Saran.

Validasi Input

Sistem menerapkan dua lapis validasi sebelum menampilkan prediksi. Lapis pertama, deteksi wajah (*face detection*) dijalankan sebelum citra diteruskan ke model; jika tidak ada wajah terdeteksi, permintaan ditolak. Lapis kedua, ambang *confidence score*, jika probabilitas softmax tertinggi di bawah ambang, sistem menampilkan peringatan *low-confidence*, mengurangi risiko *false-confidence*. Kedua lapis ini meningkatkan keandalan sistem terhadap masukan *out-of-distribution*.

Strategi Pelatihan

Pelatihan menggunakan strategi *progressive fine-tuning* tiga fase dengan optimizer Adam, augmentasi Mixup, *label smoothing loss* ($\epsilon = 0,1$), *Cosine Annealing learning rate scheduler*, pembekuan *Batch Normalization* selama *fine-tuning*, serta *callback EarlyStopping* dan *ModelCheckpoint*. Fase 1:

seluruh layer *backbone* dibekukan, hanya *classifier head* dilatih (LR 0,002, maks. 15 epoch). Fase 2: blok *conv5_block* dibuka (LR 0,00005, maks. 20 epoch). Fase 3: blok *conv4_block* dan *conv5_block* dibuka untuk *deep fine-tuning* (LR 0,00001), dihentikan *EarlyStopping*. Pada inferensi diterapkan *Test-Time Augmentation* (TTA) 10 varian, dirata-ratakan untuk stabilitas keluaran (Tabel 2).

Tabel 2. Perbandingan Strategi Progressive Fine-Tuning

Fase	Layer Dilatih	LR	Epoch	Akurasi Val.
Fase 1	Classifier Head	0,002	15	73,09%
Fase 2	+ Conv5 Block	0,00005	20	82,39%
Fase 3	+ Conv4 Block	0,00001	9*	84,05%

Sistem Rekomendasi Content-Based Filtering

Setelah kelas masalah kulit diperoleh dari model CNN, sistem merekomendasikan produk *skincare* berbasis CBF. Empat atribut produk (jenis produk, tipe kulit sasaran, masalah kulit, tipe bahan aktif) digabungkan menjadi satu dokumen teks per produk, divektorisasi TF-IDF (*ngram_range*=(1,2), *min_df*=1) agar frasa seperti “*salicylic acid*” tertangkap utuh. Setiap kelas prediksi dipetakan ke keyword pencarian (Tabel 3) yang divektorisasi menjadi *query vector*, dihitung *cosine similarity*-nya terhadap setiap vektor produk (Persamaan 5), lalu lima produk teratas ditampilkan. Pemetaan bahan aktif utama untuk kelas jerawat, kulit kusam/noda hitam, dan tanda penuaan. Pada korpus dokumen pendek seperti dataset ini (215 produk, deskripsi ringkas), nilai *cosine similarity* TF-IDF cenderung rendah-moderat karena selisih bobot antar-term tidak besar. Oleh karena itu, sistem mengandalkan peringkat relatif (*ranking*) antarproduk, bukan nilai absolut *similarity score*, sebagai dasar rekomendasi.

Tabel 3. Pemetaan Keyword Kelas Prediksi ke Query TF-IDF

Kelas	Keyword Utama
Jerawat	salicylic acid, niacinamide, tea tree
Kering/Dehidrasi	moisturizing, ceramide, hyaluronic acid
Kusam/Noda Hitam	brightening, vitamin C, kojic acid, arbutin
Sensitif/Iritasi	calming, centella asiatica, ceramide
Pori-Pori Besar	pore minimizing, niacinamide, AHA/BHA
Minyak Berlebih	oil control, niacinamide, salicylic acid, clay
Tanda Penuaan	anti-aging, retinol, peptide, vitamin C

Metode Evaluasi

Kinerja model klasifikasi dievaluasi menggunakan *accuracy*, *precision*, *recall*, dan *F1-score* yang dihitung dari *confusion matrix* (Guna et al., 2024), sebagaimana dirumuskan pada Persamaan (1)-(4).

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \dots\dots\dots (1)$$

$$Precision = TP / (TP + FP) \dots\dots\dots (2)$$

$$Recall = TP / (TP + FN) \dots\dots\dots (3)$$

$$F1-score = 2 \times (Precision \times Recall) / (Precision + Recall) \dots\dots\dots (4)$$

$$\cos(A,B) = (A \cdot B) / (\|A\| \times \|B\|) \dots\dots\dots (5)$$

Di mana TP dan TN masing-masing menyatakan jumlah prediksi benar pada kelas positif dan negatif, sedangkan FP dan FN menyatakan prediksi keliru. Sistem rekomendasi dievaluasi kualitatif berdasarkan relevansi kandungan produk, dan fungsionalitas pipeline diverifikasi melalui black box testing tujuh skenario. Latensi inferensi diukur untuk membandingkan waktu tanpa dan dengan TTA guna menilai kelayakan *real-time*.

HASIL DAN PEMBAHASAN

Hasil

Hasil Pelatihan Model

Strategi *progressive fine-tuning* tiga fase meningkatkan akurasi validasi bertahap dari 73,09% (Fase 1) menjadi 82,39% (Fase 2) dan 84,05% (Fase 3), naik 11,30% dari fase pertama ke ketiga. Kurva training (Gambar 2) menunjukkan loss menurun konsisten tanpa gap signifikan antara data latih dan validasi, mengindikasikan model tidak *overfitting*. Pada data uji (315 citra) yang terisolasi penuh, model memperoleh akurasi 82,53% dengan macro F1-score 0,82, selisih kecil terhadap akurasi validasi (83,39%), menunjukkan generalisasi baik.

Gambar 2. Kurva Training dan Validasi Akurasi serta Loss ResNet50V2 (Tiga Fase)



Evaluasi Per Kelas dan Analisis Confusion Matrix

Tabel 5 menyajikan precision, recall, dan F1-score ketujuh kelas. Kelas jerawat memperoleh F1-score tertinggi (0,89) karena ciri visualnya (papul, pustula, kemerahan terlokalisasi) relatif distingtif, sementara kulit kusam/noda hitam terendah (0,78). Confusion matrix menunjukkan kesalahan terkonsentrasi pada pasangan kelas dengan kemiripan tekstur/warna tinggi: kulit kusam/noda hitam dengan tanda penuaan, kulit sensitif/iritasi dengan produksi minyak berlebih, dan pori-pori besar dengan produksi minyak berlebih.

Tabel 4. Hasil Evaluasi Precision, Recall, F1-score Per Kelas

Kelas	Precision	Recall	F1	Support
Jerawat	0,87	0,91	0,89	44
Kering/Dehidrasi	0,82	0,80	0,81	44
Kusam/Noda Hitam	0,79	0,77	0,78	44
Sensitif/Iritasi	0,81	0,84	0,82	44
Pori-Pori Besar	0,84	0,82	0,83	44
Minyak Berlebih	0,86	0,84	0,85	44
Tanda Penuaan	0,80	0,79	0,79	44
Macro Avg	0,83	0,82	0,82	308


Hasil Sistem Rekomendasi Skincare

Sistem CBF menghasilkan lima produk teratas relevan berdasarkan kesesuaian bahan aktif untuk setiap kelas prediksi. Gambar 3 menampilkan contoh untuk citra jerawat, dengan model memprediksi confidence 95,2% (TTA 10x), merekomendasikan produk ber kandungan ceramide,

salicylic acid, dan niacinamide. Similarity score berkisar 0,278-0,321, tergolong rendah secara absolut karena karakteristik umum TF-IDF pada dataset berdokumen pendek, namun peringkat relatif antarproduk tetap konsisten menempatkan kandungan paling relevan di posisi teratas. Relevansi ini didasarkan pada kesesuaian atribut tekstual produk dengan kelas hasil klasifikasi serta pemetaan bahan aktif berlandaskan literatur dermatologi, bukan hasil uji klinis.

Sebagai evaluasi tambahan, dari lima belas produk rekomendasi pada tiga kelas ilustratif (jerawat, kulit kering/dehidrasi, tanda penuaan), seluruh produk memiliki atribut “Masalah Kulit” yang sesuai kelas klasifikasi, similarity score 0,278-0,321. Evaluasi ini masih terbatas pada tiga dari tujuh kelas dan hanya mengukur kecocokan atribut tekstual, sehingga evaluasi lebih menyeluruh (validasi ahli dermatologi/farmasi) menjadi arah penelitian selanjutnya.

Gambar 3. Contoh Hasil Prediksi Model dan Rekomendasi Produk Skincare (Kelas: Jerawat, Confidence: 95,2%)



Hasil Pengujian Black Box

Fungsionalitas pipeline sistem, dari input citra hingga keluaran rekomendasi, diverifikasi melalui black box testing terhadap tujuh skenario. Tabel 6 merangkum indikator, hasil, dan keterangan tiap skenario dan seluruh skenario dinyatakan valid.

Tabel 5. Hasil Pengujian Black Box Sistem

No	Indikator pengujian	Hasil	Keterangan
1	Unggah citra wajah dengan kondisi kulit yang jelas	Sistem menampilkan kelas masalah kulit terprediksi beserta confidence score	Valid, prediksi sesuai kelas uji
2	Unggah citra tanpa wajah terdeteksi	Sistem menolak permintaan dan menampilkan pesan wajah tidak terdeteksi	Valid, citra non-wajah ditolak
3	Unggah citra dengan confidence score di bawah ambang batas	Sistem menampilkan peringatan low-confidence, bukan hasil prediksi	Valid, sesuai mekanisme validasi input
4	Sistem menghasilkan rekomendasi produk untuk kelas terprediksi	Lima produk teratas ditampilkan sesuai kesesuaian bahan aktif	Valid, produk relevan dengan kelas
5	Pengguna melihat detail	Rincian jenis produk, tipe kulit	Valid, informasi lengkap dan

No	Indikator pengujian	Hasil	Keterangan
	kandungan produk yang direkomendasikan	sasaran, dan bahan aktif ditampilkan	sesuai
6	Sistem memproses citra dengan variasi pencahayaan/kualitas rendah	Sistem tetap menghasilkan prediksi tanpa galat (error) sistem	Valid, sistem stabil
7	Alur end-to-end dari unggah citra hingga tampilan rekomendasi	Seluruh tahapan pipeline berjalan berurutan tanpa kegagalan	Valid, seluruh alur berfungsi baik

Pembahasan

Faktor yang Memengaruhi Performa Model

Performa model dipengaruhi tiga faktor: (1) *transfer learning* ResNet50V2 dengan three-phase *fine-tuning* yang meminimalkan risiko rusaknya bobot pretrained; (2) *Dual Pooling Head* yang menggabungkan fitur tekstur menyeluruh (GAP) dan fitur lokal diskriminatif seperti lesi jerawat (GMP); serta (3) *label smoothing* ($\epsilon = 0,1$) yang menekan overconfidence. Meski seimbang antarkelas, jumlah dataset (2.450 citra) tergolong kecil untuk CNN sekompleks ResNet50V2, sejalan dengan temuan (Uddin & Lu, 2024) bahwa karakteristik dataset turut memengaruhi performa model, bukan semata arsitektur. Keterbatasan ini membatasi performa terutama pada kelas dengan karakteristik visual halus dan tumpang tindih. TTA (10x) terbukti menstabilkan prediksi terhadap variasi pencahayaan dan sudut gambar.

Analisis Kesalahan Klasifikasi: Kulit Kusam/Noda Hitam vs. Tanda-Tanda Penuaan

Kulit kusam/noda hitam dan tanda penuaan bukan kondisi identik secara visual, namun tumpang tindih pada ruang fitur. Noda hitam lebih terlokalisasi dengan tepi dapat dikenali, sedangkan kekusaman bersifat difus. Mekanisme optisnya juga berbeda noda hitam dari akumulasi melanin terlokalisasi, kekusaman dari penurunan reflektansi permukaan kulit akibat sel kulit mati, namun keduanya menghasilkan efek mirip di tingkat piksel (penurunan kecerahan dan saturasi), diperkuat pencahayaan tidak merata pada dataset. Kondisi ini merupakan keterbatasan *visual discriminability* akibat pencahayaan tidak seragam, bukan kelemahan arsitektur model.

Evaluasi Latensi Test-Time Augmentation

TTA dengan 10 varian meningkatkan stabilitas prediksi namun juga waktu komputasi karena tiap citra memerlukan 10 kali *forward pass*. Trade-off ini perlu dipertimbangkan untuk skenario *real-time*, di mana pengurangan jumlah varian TTA dapat menjadi kompromi akurasi dan waktu respons.

Keunggulan Sistem Rekomendasi Berbasis CBF

Content-Based Filtering unggul karena tidak bergantung pada data historis interaksi sehingga dapat langsung melayani pengguna baru, serta lebih transparan karena berbasis atribut produk yang jelas dan pemetaan bahan aktif berlandaskan literatur dermatologi.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini berhasil mengembangkan sistem terintegrasi yang menggabungkan klasifikasi masalah kulit wajah berbasis CNN ResNet50V2 dengan sistem rekomendasi *skincare* berbasis *Content-Based Filtering*. Model dengan *progressive fine-tuning* tiga fase, *Dual Pooling Head*, dan validasi input dua lapis mencapai akurasi uji 82,53% dan macro F1-score 0,82 pada tujuh kelas, dengan jerawat terbaik (F1 0,89) dan kulit kusam/noda hitam terendah (F1 0,78) akibat tumpang tindih visual

dengan tanda penuaan. Sistem rekomendasi berbasis TF-IDF dan *cosine similarity*, dengan pemetaan bahan aktif berlandaskan literatur dermatologi, menghasilkan produk relevan (similarity 0,278-0,321), dan seluruh tujuh skenario black box dinyatakan valid. Seluruh tujuan penelitian telah tercapai, dengan keterbatasan berupa representasi warna kulit yang belum diverifikasi kuantitatif serta pendekatan single-label yang belum mengakomodasi kondisi kulit ganda.

Saran

Berdasarkan temuan dan keterbatasan tersebut, penelitian selanjutnya disarankan untuk mengaudit distribusi warna kulit menggunakan skala *Fitzpatrick Skin Type Scale* serta memperkaya variasi dataset, meliputi warna kulit, tingkat keparahan, dan etnis. Selain itu, penelitian selanjutnya dapat menerapkan klasifikasi multi-label dengan *multi-hot label encoding*, aktivasi *sigmoid*, dan *binary cross-entropy loss* yang dievaluasi menggunakan *Hamming Loss* dan *Jaccard Index*. Optimasi jumlah varian *Test-Time Augmentation* (TTA) juga dapat dilakukan untuk menyeimbangkan akurasi dan latensi pada penggunaan *real-time*. Perbandingan ResNet50V2 dengan arsitektur mutakhir, seperti EfficientNetV2, ConvNeXt, dan *Vision Transformer*, juga dapat dieksplorasi untuk mengetahui performa model pada dataset yang lebih beragam. Pada sistem rekomendasi, penggunaan *word embedding* seperti BERT dapat dikaji untuk meningkatkan representasi teks dan relevansi rekomendasi. Selanjutnya, pelibatan ahli dermatologi dan penerapan *User Acceptance Testing* (UAT) dapat dilakukan untuk mendukung validitas klinis serta mengevaluasi pengalaman pengguna.

DAFTAR PUSTAKA

- Adi, S., Mola, S., Orison, B., Kana, D., & Kenlopo, A. N. (2025). Perbandingan Arsitektur ResNet50V2 , InceptionV3 , dan DenseNet121 Dalam Klasifikasi Pengenalan Ekspresi Wajah Comparison of ResNet50V2 , InceptionV3 , and DenseNet121 Algorithms in Facial Expression Recognition Classification. 2, 285–294. <https://doi.org/10.26798/jiko.v9i2.1584>
- Alipour, N., Burke, T., & Courtney, J. (2024). Skin Type Diversity in Skin Lesion Datasets: A Review. *Current Dermatology Reports*, 13(3), 198–210. <https://doi.org/10.1007/s13671-024-00440-0>
- Anisa, D. (2024). JURNAL RISET SISTEM INFORMASI KLASIFIKASI CITRA JENIS KULIT WAJAH DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) RESNET-50. 1(3), 2–8. <https://doi.org/10.69714/13sbby24>
- Anshori, M. I., Yaqin, R. A., Ali, M., Sidiq, Z., & Agung, W. P. (2025). Klasifikasi Jenis Jerawat Secara Otomatis Dengan Convolutional Neural Network Menggunakan Arsitektur Resnet-50 Automatic Acne Type Classification with Convolutional Neural Network Using Resnet-50 Architecture. 15(April), 73–84. <https://doi.org/10.34010/jamika.v15i1.13712>
- Anwar, M. A. (2025). Klasifikasi Pneumonia pada Citra X-Ray Menggunakan CNN ResNet50V2 dengan Transfer Learning. 15(1), 126–135. <https://doi.org/10.32664/smatika.v15i01.1538>
- Apriyani, S., Lestari, N., Hasanah, T., Aviani, B., & Daulay, N. K. (2025). Deteksi Dini Penyakit Kulit Pada Wajah Berdasarkan Citra Dengan Pendekatan Convolutional Neural Network (CNN). 4(1), 129–136. <https://doi.org/10.70609/jusifor.v4i1.7058>
- Guna, E. A., Sihombing, E. F., Pasaribu, M. N., Syahputra, H., & Ramadhani, F. (2024). TINGKAT KEPARAHAN JERAWAT PADA WAJAH. 8(4), 5778–5782. <https://doi.org/10.36040/jati.v8i4.10010>
- Imaniyah, S. A., Dewanto, F. M., Latifah, N., & Mutiara, D. (2026). Facial Skin Disease Classification Using Swin Transformer V2 and ResNet-50 in a Flask-Based System. 28(1), 50–58. <https://doi.org/10.31294/p.v28i1.12381>
- Iqbal, S. M., & Pratama, I. (2024). Penerapan Metode Content Based Filtering pada Sistem Rekomendasi Pemilihan Produk Skincare Application of Content Based Filtering Method on Skincare Product Selection Recommendation System. 13(105), 663–675.

- Irjanto, N. S., Kiswanto, R. H., Sabra, I. S., & Rahman, F. (2024). Sistem Pengenalan Penyakit Kulit Berbasis Computer Vision Dengan Metode Convolutional Neural Network (CNN). *Techno.Com*, 23(3), 716–728. <https://doi.org/10.62411/tc.v23i3.11355>
- Kemenko Perekonomian. (2025). Tumbuh Double Digit, Pemerintah Dukung Penguatan Ekosistem Industri Kecantikan. <https://www.ekon.go.id/publikasi/detail/6712/tumbuh-double-digit-pemerintah-dukung-penguatan-ekosistem-industri-kecantikan>
- Khani, N. I., & Rakasiwi, S. (2025). Edumatic: Jurnal Pendidikan Informatika Penerapan Convolutional Neural Network dengan ResNet-50 untuk Klasifikasi Penyakit Kulit Wajah Efektif. 9(1), 217–225. <https://doi.org/10.29408/edumatic.v9i1.29572>
- Nouvalina, D. A., & Hati, K. (2024). Sistem Rekomendasi Produk Skin Care Berdasarkan Permasalahan Kulit Wajah dengan Metode Content Based Filtering. *X*(2), 60–67.
- Oglio, F. D., Fabbrocini, G., Tedeschi, A., Chiodini, P., & Micali, G. (2019). Licochalcone A in Combination with Salicylic Acid as Fluid Based and Hydroxy-Complex 10 % Cream for the Treatment of Mild Acne : A Multicenter Prospective Trial. 961–967.
- Ramdhana, A. C., & Pratiwi, N. (2023). Edumatic: Jurnal Pendidikan Informatika Perbandingan Kinerja Model Convolutional Neural Network pada Klasifikasi Kanker Kulit. 7(2), 197–206. <https://doi.org/10.29408/edumatic.v7i2.19823>
- Rocio, J., Christophe, J., Mukta, P., Natalia, S., Claire, K., & Bensmaine, D. (2025). Evaluation of the Efficacy of a Serum Containing Niacinamide , Tranexamic Acid , Vitamin C , and Hydroxy Acid Compared to 4 % Hydroquinone in the Management of Melasma. 1–9. <https://doi.org/10.1111/jocd.70097>
- Saputro et al. (2022). Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network (Studi Kasus: Melanoma). 2(1), 52–57.
- Saragih, N. N., & Kurniawan, R. (2025). Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2. *Journal of Computer Engineering, System and Science*, 10(1), 299–311.
- Sulami, A., Atina, V., Studi, P., Informatika, T., Duta, U., Surakarta, B., & Rekomendasi, S. (2024). PENERAPAN METODE CONTENT BASED FILTERING DALAM. 9(2).
- Yusuf, A., Prayoga, I., Taka, D., Perdana, D., & Informatika, T. (2026). Sistem Klasifikasi Tipe Kulit Wajah Menggunakan Convolutional Neural Network dengan Rekomendasi Tahap Perawatan Kulit. 5, 255–268.