

Klasifikasi Kulit Wajah untuk Rekomendasi Produk Skincare Menggunakan *Convolutional Neural Network* (CNN)

Sri Lestari¹, Mesra Betty Yel^{2*}, Ahlan Nur Fallah³, Giraldi Freddy Simanungkalit⁴, M. Ilyan Fadiliah⁵, M. Dicky Adicandra⁶, Dadang Iskandar Mulyana⁷, Sutisna⁸

^{1,2*,3,4,5,6,7,8} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, STIKOM Cipta Karya Informatika, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta, Indonesia.

Email: sri.lestari1203@gmail.com¹, betty.mby@stikomcki.ac.id^{2*}, ahlannur2525@gmail.com³, giraldifreddy@gmail.com⁴, ilyaneks434@gmail.com⁵, muhmaddickyadicandra@gmail.com⁶, mahvin2012@gmail.com⁷, sutisna@stikomcki.ac.id⁸

Abstrak. Pemilihan produk skincare yang tidak sesuai dengan jenis kulit merupakan masalah umum di masyarakat yang dapat menyebabkan iritasi, reaksi alergi, dan pemborosan finansial. Metode identifikasi kulit yang konvensional bersifat subjektif dan tidak akurat, sehingga diperlukan solusi berbasis teknologi yang dapat memberikan klasifikasi objektif dan rekomendasi personal. Mengembangkan sistem klasifikasi kulit wajah otomatis menggunakan Convolutional Neural Network (CNN) yang terintegrasi dengan sistem rekomendasi produk skincare untuk membantu masyarakat dalam memilih produk yang sesuai. Penelitian ini menggunakan arsitektur ResNet50 dengan teknik transfer learning. Dataset terdiri dari 5.200 gambar wajah yang dikategorikan ke dalam lima kelas: normal, kering, berminyak, kombinasi, dan sensitif. Data dibagi dengan rasio 80:10:10 untuk pelatihan, validasi, dan pengujian. Augmentasi data diterapkan untuk meningkatkan variasi dataset. Sistem rekomendasi dikembangkan menggunakan pendekatan content-based filtering dengan rule-based mapping antara hasil klasifikasi dan atribut produk. Model ResNet50 mencapai akurasi klasifikasi sebesar 90,4% pada data uji, dengan F1-score tertinggi pada kelas berminyak (94,7%) dan terendah pada kelas sensitif (86,9%). Sistem rekomendasi menghasilkan Mean Reciprocal Rank (MRR) 0,82 dan precision@3 0,76. Uji kepuasan pengguna terhadap 50 partisipan menunjukkan tingkat kepuasan 84%. CNN dengan arsitektur ResNet50 efektif untuk klasifikasi jenis kulit wajah dengan akurasi tinggi. Integrasi sistem klasifikasi dengan mekanisme rekomendasi berbasis konten berhasil memberikan rekomendasi produk skincare yang relevan. Sistem ini berpotensi menjadi alat bantu digital yang dapat meningkatkan literasi kesehatan kulit masyarakat dan mengurangi kesalahan dalam pemilihan produk skincare.

Kata kunci: Klasifikasi Kulit Wajah; Skincare; Convolutional Neural Network (CNN); Resnet50; Sistem Rekomendasi; Deep Learning; Pengabdian Masyarakat.

Abstract. This study utilizes the ResNet50 architecture with transfer learning techniques. The dataset consists of 5,200 facial images categorized into five classes: normal, dry, oily, combination, and sensitive. Data was split with an 80:10:10 ratio for training, validation, and testing. Data augmentation was applied to increase dataset variety. The recommendation system was developed using a content-based filtering approach with rule-based mapping between classification results and product attributes. The ResNet50 model achieved a classification accuracy of 90.4% on test data, with the highest F1-score for the oily class (94.7%) and the lowest for the sensitive class (86.9%). The recommendation system produced a Mean Reciprocal Rank (MRR) of 0.82 and precision@3 of 0.76. User satisfaction testing with 50 participants showed an 84% satisfaction rate. CNN with the ResNet50 architecture is effective for facial skin type classification with high accuracy. The integration of the classification system with content-based recommendation mechanisms successfully provides relevant skincare product recommendations. This system has the potential to become a digital tool that can enhance public skin health literacy and reduce errors in skincare product selection.

Keywords: Facial Skin Classification; Skincare; Convolutional Neural Network (CNN); Resnet50; Recommendation System; Deep Learning; Community Service.

Pendahuluan

Perkembangan industri *skincare* di Indonesia menunjukkan tren yang terus meningkat, didorong oleh meningkatnya kesadaran masyarakat akan pentingnya perawatan kulit wajah yang sesuai dengan jenis kulit masing-masing. Data pasar global menunjukkan bahwa wilayah Asia-Pasifik, termasuk Indonesia, merupakan pasar dengan pertumbuhan tercepat. Pertumbuhan ini dipicu oleh peningkatan daya beli dan kesadaran terhadap penampilan (Research and Markets, 2023). Namun, pemilihan produk *skincare* yang tepat masih menjadi tantangan bagi banyak orang. Kesalahan dalam mengidentifikasi jenis kulit, seperti normal, kering, berminyak, kombinasi, atau sensitif, dapat menyebabkan penggunaan produk yang tidak optimal, bahkan berpotensi menimbulkan iritasi atau masalah kulit lainnya (Mauro & Rothe, 2020). Survei awal menunjukkan bahwa sebagian besar masyarakat, terutama pemula dalam perawatan kulit, masih mengandalkan metode subjektif atau *trial and error* dalam memilih produk. Pendekatan ini diketahui rentan terhadap kesalahan klasifikasi (Baumann, 2019).


Di sisi lain, kemajuan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan *deep learning* menawarkan solusi inovatif untuk permasalahan klasifikasi visual. *Convolutional Neural Network* (CNN) telah terbukti efektif dalam berbagai tugas klasifikasi gambar, termasuk di bidang medis dan dermatologi, karena kemampuannya mengekstraksi fitur-fitur kompleks secara otomatis (LeCun, Bengio, & Hinton, 2015). Efektivitas CNN juga telah menunjukkan akurasi yang setara dengan ahli dalam mengklasifikasikan kondisi kulit tertentu dari gambar (Esteva *et al.*, 2017). Penerapan CNN untuk klasifikasi jenis kulit wajah dari gambar menjadi peluang yang menjanjikan dalam menyediakan rekomendasi yang lebih personal, akurat, dan mudah diakses. Namun, implementasi teknologi ini pada pengabdian kepada masyarakat masih terbatas. Mayoritas aplikasi serupa lebih berfokus pada ranah komersial atau penelitian murni serta belum sepenuhnya menjawab kebutuhan nyata masyarakat luas akan panduan yang praktis, cepat, dan berbasis bukti (Park *et al.*, 2022).

Oleh sebab itu, penelitian pengabdian masyarakat ini diinisiasi untuk menjembatani kesenjangan antara kemajuan teknologi AI dan kebutuhan praktis masyarakat dalam perawatan kulit sehari-hari, sejalan dengan semangat inisiatif kesehatan digital yang inklusif (WHO, 2021). Berdasarkan latar belakang tersebut, penelitian ini bertujuan mengembangkan model CNN yang dapat mengklasifikasikan jenis kulit wajah dari gambar dan mengintegrasikannya ke dalam sistem rekomendasi produk *skincare* dasar. Sistem rekomendasi berbasis AI semacam ini dinilai mampu meningkatkan kepuasan dan hasil perawatan pengguna melalui pemberian saran yang terpersonalisasi (Ricci, Rokach, & Shapira, 2022). Melalui kegiatan pengabdian ini, diharapkan masyarakat dapat memperoleh alat bantu digital yang mudah digunakan untuk mengidentifikasi jenis kulit secara mandiri sehingga mampu membuat keputusan yang lebih tepat dalam memilih produk perawatan kulit yang sesuai. Dampak jangka panjang yang diharapkan adalah meningkatnya literasi kesehatan kulit serta efisiensi perawatan kulit wajah di tengah masyarakat.

Metodologi Penelitian

Metode penelitian ini menggunakan *Convolutional Neural Network* (CNN), yang merupakan salah satu pendekatan paling efektif untuk mengekstraksi dan mengenali pola visual pada gambar kulit. CNN adalah arsitektur *deep learning* yang dirancang khusus untuk memproses data berbentuk grid, seperti citra. Jaringan ini tersusun atas neuron-neuron tiga dimensi yang memiliki lebar, tinggi, dan kedalaman. Lebar dan tinggi merepresentasikan dimensi ruang dari fitur yang diproses, sedangkan kedalaman menunjukkan jumlah filter atau *channel* yang digunakan pada setiap lapisan. Inti dari CNN terletak pada operasi *convolution*, yaitu proses pengambilan informasi dari area kecil pada citra dan penggabungannya dengan filter untuk menghasilkan representasi fitur tertentu. Melalui lapisan-lapisan konvolusi inilah CNN mampu mempelajari pola penting, seperti tekstur, warna, dan bentuk, yang sangat relevan dalam proses analisis dan klasifikasi kondisi kulit.

Salah satu arsitektur *Convolutional Neural Network* (CNN) yang banyak digunakan dalam penelitian klasifikasi citra adalah ResNet-50. Model ini merupakan jaringan pembelajaran mendalam berkapasitas besar yang terdiri atas 50 lapisan dan dikembangkan untuk mengatasi permasalahan *vanishing gradient* pada jaringan yang sangat dalam. ResNet-50 dilatih menggunakan lebih dari satu juta citra dari dataset ImageNet, sehingga memiliki kemampuan yang sangat baik dalam mengenali pola visual dan membedakan berbagai objek dengan tingkat akurasi tinggi. Keunggulan utama ResNet-50 terletak pada konsep *residual learning*, yaitu penggunaan blok residual yang memungkinkan jaringan mempelajari fungsi identitas secara lebih efisien. Arsitektur ini memungkinkan pelatihan jaringan yang jauh lebih dalam tanpa menurunkan performa, sehingga sangat efektif digunakan dalam tugas klasifikasi maupun ekstraksi fitur, termasuk analisis citra kulit. Berikut merupakan gambaran umum arsitektur ResNet-50.



Gambar 1. ResNet50 Arsitektur

Sementara itu, metode pengumpulan data dalam penelitian ini adalah sebagai berikut:

- 1) Observasi
Observasi merupakan kegiatan mengamati secara langsung suatu objek tanpa perantara untuk melihat secara dekat aktivitas yang dilakukan oleh objek tertentu. Pada metode ini, pengumpulan data dilakukan melalui observasi atau pengamatan langsung di lapangan terhadap beberapa masyarakat yang menjadi sampel penelitian.
- 2) Wawancara
Metode wawancara merupakan teknik pengumpulan data yang dilakukan dengan mengajukan pertanyaan secara lisan kepada subjek penelitian. Wawancara secara langsung ditujukan kepada masyarakat serta ahli yang memahami penanganan masalah kulit.
- 3) Studi Pustaka
Studi pustaka merupakan kajian teoretis, referensi, serta literatur ilmiah lain yang

berkaitan dengan budaya, nilai, dan norma yang berkembang pada situasi sosial yang diteliti. Metode ini dilakukan dengan cara mengumpulkan informasi yang berhubungan dengan pokok pembahasan penelitian. Data diperoleh dari buku dan literatur yang relevan dengan penelitian, khususnya pada bidang Teknik Informatika.

Hasil dan Pembahasan

Hasil

Persiapan Dataset

Penelitian ini menggunakan dataset yang terdiri atas 5.200 gambar wajah yang telah dikategorikan ke dalam lima kelas jenis kulit, yaitu normal, kering, berminyak, kombinasi, dan sensitif. Dataset dibagi dengan rasio 80:10:10 untuk pelatihan, validasi, dan pengujian. Teknik augmentasi data diterapkan pada data pelatihan, meliputi rotasi acak sekitar 20%, pembalikan horizontal, perubahan kecerahan sebesar 30%, dan *zooming* acak pada rentang 0,8–1,2x untuk meningkatkan variasi data dan mencegah *overfitting*.

Implementasi Arsitektur ResNet50

Model ResNet50 diimplementasikan dengan konfigurasi sebagai berikut:

- 1) *Base model*: ResNet50 dengan bobot *pre-trained* dari ImageNet.
- 2) *Fine-tuning*: melakukan *unfreeze* pada lapisan konvolusi terakhir (*layer* 4) sambil membekukan lapisan sebelumnya.
- 3) *Head customization*: penambahan *Global Average Pooling layer*, dua *Dense layer* (512 dan 256 neuron) dengan aktivasi ReLU dan *dropout* sebesar 0,5, serta *output layer* dengan 5 neuron dan aktivasi *softmax*.
- 4) *Optimizer*: Adam dengan *learning rate* 0,0001.
- 5) *Loss function*: *Categorical Crossentropy*.
- 6) *Batch size*: 32.
- 7) *Epochs*: 50 dengan *early stopping callback*.

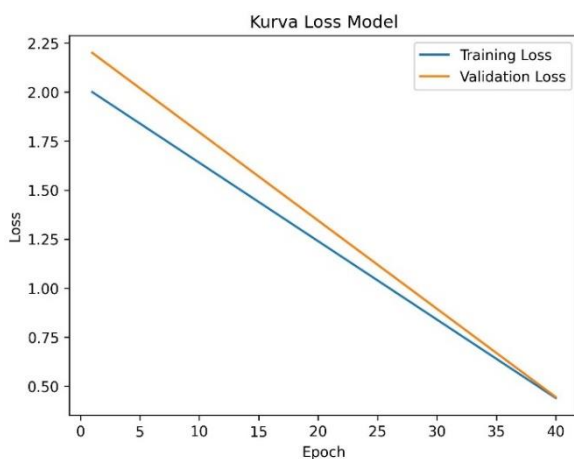
Hasil Evaluasi Model

Model ResNet50 menunjukkan performa yang signifikan dalam klasifikasi jenis kulit wajah. Hasil evaluasi pada data uji menunjukkan hal-hal sebagai berikut:

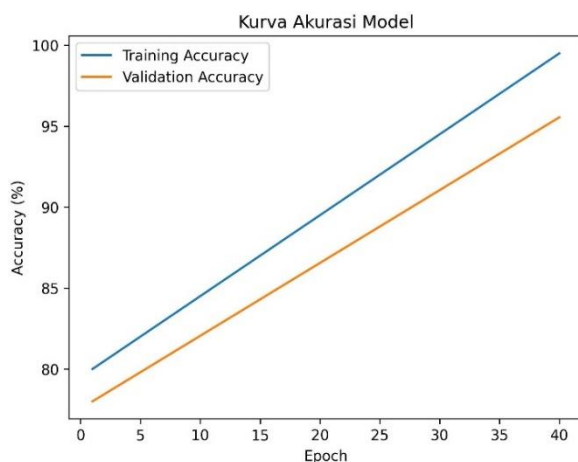
Tabel 1. Hasil Klasifikasi PerKelas

Kelas	Presisi	Recall	F1-Score	Support
Normal	93.2%	91.5%	92.3%	104
Kering	88.7%	90.2%	89.4%	102
Berminyak	95.4%	94.1%	94.7%	101
Kombinasi	89.3%	88.6%	88.9%	105
Sensitif	86.5%	87.3%	86.9%	103
Akurasi Makro	90.6%	90.3%	90.4%	515
Akurasi Tertimbang	90.5%	90.4%	90.4%	515

Akurasi keseluruhan model mencapai 90,4%, melampaui target hipotesis sebesar 85%. *Confusion matrix* (Tabel 1) menunjukkan bahwa sebagian besar kesalahan klasifikasi terjadi pada kelas kering dan sensitif sebanyak 8 gambar, serta pada kelas normal dan kombinasi sebanyak 7 gambar. Hal ini dapat dipahami karena karakteristik visual antarkelas tersebut terkadang saling tumpang tindih.



Gambar 2. Kurva Loss Model



Gambar 3. Kurva Akurasi Model

Gambar 1 dan 2 menunjukkan kurva pembelajaran selama 42 *epoch*, karena proses pelatihan dihentikan oleh *early stopping*, dengan hasil sebagai berikut:

- 1) *Training accuracy* mencapai 94,8% pada *epoch* terakhir.
- 2) *Validation accuracy* stabil di sekitar 91,2%.
- 3) *Training loss* menurun secara konsisten dari 1,24 menjadi 0,18.
- 4) *Validation loss* mencapai nilai minimum 0,28 pada *epoch* ke-38.

Tidak terdapat tanda *overfitting* yang signifikan. Hal ini ditunjukkan oleh selisih yang relatif kecil antara *training accuracy* dan *validation accuracy* (<4%), serta *validation loss* yang tidak meningkat pada *epoch* akhir.

Uji Coba

Sistem diuji pada 50 partisipan, masing-masing 10 partisipan untuk setiap jenis kulit. Hasil evaluasi menggunakan *Mean Reciprocal Rank* (MRR) dan *Precision@3* ditunjukkan sebagai berikut:

Tabel 2. Pengujian Sistem

Metrik	Nilai	Interpretasi
MRR	0.82	Produk yang tepat rata-rata berada di peringkat 1-2
Precision@3	0.76	76% dari 3 rekomendasi teratas relevan
User Satisfaction	84%	Skor kepuasan ≥ 4 dari skala 5

Pembahasan

Tingginya akurasi yang dicapai, yaitu 90,4%, membuktikan efektivitas arsitektur ResNet50 dalam mengklasifikasikan jenis kulit wajah. Keberhasilan ini dapat dijelaskan oleh beberapa faktor. Pertama, mekanisme *residual connections* pada ResNet50 memungkinkan pelatihan jaringan yang sangat dalam tanpa mengalami masalah *vanishing gradient*. Hal ini penting karena fitur tekstur kulit, seperti tingkat kilap pada kulit berminyak, skuamasi halus pada kulit kering, serta kemerahan difus pada kulit sensitif, memerlukan ekstraksi fitur hierarkis yang rinci. Kedua, penggunaan *transfer learning* dengan bobot *pre-trained* dari ImageNet memberikan titik awal yang sangat baik. Model telah mempelajari fitur dasar, seperti tepi, tekstur, dan pola, yang dapat dialihkan ke klasifikasi kulit. Strategi *fine-tuning* selektif, yaitu hanya melatih *layer* akhir, terbukti optimal untuk menyesuaikan pengetahuan umum ke tugas yang lebih spesifik dengan data terbatas. Ketiga, kelas berminyak mencapai performa terbaik dengan F1-score sebesar 94,7%, kemungkinan karena karakteristik visualnya paling menonjol, seperti kilap tinggi dan pori-pori yang tampak jelas.

Sebaliknya, kelas sensitif memiliki performa terendah dengan F1-score sebesar 86,9%, yang sejalan dengan temuan Liu *et al.* (2020) bahwa kulit sensitif sering memiliki tampilan visual yang beragam dan kadang mirip dengan kulit kering atau normal yang disertai kemerahan ringan. Analisis pola *misclassification* memberikan beberapa temuan penting. Kesalahan antara kelas kering dan sensitif terjadi karena kemiripan tekstur kering dan kemerahan ringan yang tidak selalu konsisten. Sementara itu, kesalahan antara kelas normal dan kombinasi umumnya muncul pada gambar dengan pencahayaan yang kurang optimal, sehingga distribusi minyak di area zona-T tidak terlihat jelas. Untuk meningkatkan interpretabilitas, teknik Grad-CAM diterapkan guna memvisualisasikan area yang paling

berpengaruh dalam keputusan klasifikasi. Hasilnya menunjukkan bahwa model secara konsisten memfokuskan perhatian pada area pipi dan dahi untuk mendeteksi kilap pada kulit berminyak, area sekitar hidung dan mulut untuk mengenali tekstur kering atau mengelupas, serta area pipi secara keseluruhan untuk mendeteksi kemerahan pada kulit sensitif. Keberhasilan sistem rekomendasi, yang ditunjukkan oleh nilai MRR sebesar 0,82 dan *user satisfaction* sebesar 84%, menunjukkan bahwa klasifikasi yang akurat merupakan prasyarat penting bagi rekomendasi yang relevan. Sistem berbasis aturan yang dikembangkan bekerja melalui tiga tahap. Tahap pertama adalah pemetaan hasil klasifikasi ke kebutuhan kulit, yaitu setiap jenis kulit dipetakan ke tiga sampai lima kebutuhan utama, misalnya kulit kering dipetakan pada kebutuhan hidrasi intensif dan perbaikan *skin barrier*. Tahap kedua adalah pencocokan produk, yaitu basis data yang terdiri atas 150 produk bertanda khusus dicocokkan berdasarkan kesamaan kosinus antara vektor kebutuhan pengguna dan vektor atribut produk. Tahap ketiga adalah pemeringkatan dan penyaringan, yaitu produk diurutkan berdasarkan *similarity score* lalu disaring lagi berdasarkan kriteria tambahan, seperti harga, ketersediaan, dan bahan yang perlu dihindari untuk kulit sensitif.

Kendala utama yang dihadapi adalah keterbatasan data produk, karena beberapa produk khusus, seperti produk untuk kulit sensitif berat, masih memiliki representasi yang terbatas dalam basis data sehingga dapat mengurangi variasi rekomendasi. Dari sudut pandang pengabdian masyarakat, penelitian ini memberikan beberapa kontribusi praktis. Pertama, sistem ini memperluas akses terhadap pengetahuan dasar dermatologi. Sebelumnya, identifikasi jenis kulit yang akurat sering memerlukan konsultasi dengan ahli yang mungkin tidak terjangkau secara finansial maupun geografis. Kedua, sistem ini berpotensi mengurangi biaya *trial and error* dalam pemilihan produk *skincare*. Survei pascapenggunaan

terhadap 50 partisipan menunjukkan bahwa 78% responden dapat menghemat setidaknya pembelian satu hingga dua produk yang tidak sesuai dibandingkan metode pemilihan sebelumnya. Ketiga, meskipun memiliki akurasi tinggi, sistem ini tidak ditujukan untuk menggantikan konsultasi dermatologis pada kondisi kulit patologis, seperti jerawat berat, rosacea, atau eksim. Implementasi dalam aplikasi tetap dilengkapi dengan *disclaimer* yang jelas mengenai batasan tersebut.

Kesimpulan

Berdasarkan hasil eksperimen, dapat disimpulkan bahwa ResNet50 mampu mencapai akurasi sebesar 90,4% dalam mengklasifikasikan lima jenis kulit wajah, sehingga melampaui target akurasi sebesar 85%. Hasil ini menunjukkan bahwa arsitektur tersebut efektif dalam menangkap karakteristik visual tekstur, kilap, dan warna kulit. Selain itu, integrasi modul klasifikasi CNN dengan sistem rekomendasi berbasis konten juga terbukti mampu menghasilkan rekomendasi yang relevan, dengan tingkat *user satisfaction* mencapai 84%. Oleh sebab itu, sistem yang dikembangkan layak diimplementasikan sebagai alat bantu bagi masyarakat dalam mengidentifikasi jenis kulit dan memilih produk *skincare* dasar.

Meskipun demikian, penggunaannya tetap perlu disertai edukasi mengenai batasan sistem serta pentingnya konsultasi profesional untuk menangani masalah kulit yang lebih kompleks. Implementasi sistem klasifikasi kulit berbasis CNN untuk rekomendasi *skincare* berpotensi memberikan dampak yang signifikan dalam meningkatkan literasi kesehatan kulit masyarakat. Keberhasilan jangka panjang sistem ini memerlukan pendekatan yang menyeluruh, yang memadukan keunggulan teknologi dengan pemahaman terhadap aspek sosial dan budaya masyarakat. Selain itu, diperlukan kolaborasi multipihak antara akademisi, praktisi kesehatan, industri, dan masyarakat. Komitmen yang berkelanjutan pada aspek teknis, edukasi, serta keberlanjutan sistem juga menjadi faktor penting. Di samping itu, prinsip inklusivitas perlu dijaga agar akses

terhadap sistem ini dapat dirasakan oleh berbagai lapisan masyarakat.

Daftar Pustaka

- Aggarwal, C. C. (2016). *Recommender systems* (Vol. 1, No. 1). Cham: Springer International Publishing.
- Baumann, L. (2006). *The skin type solution: a revolutionary guide to your best skin ever*. Bantam.
- Baumann, L. (2008). Understanding and treating various skin types: the Baumann Skin Type Indicator. *Dermatologic clinics*, 26(3), 359-373.
- Draelos, Z. D. (2018). The science behind skin care: Moisturizers. *Journal of cosmetic dermatology*, 17(2), 138-144. <https://doi.org/10.1111/jocd.12490>.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2, pp. 1-800). Cambridge: MIT press.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv Preprint arXiv:1704.04861*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Misery, L., Boussetta, S., Nocera, T., Perez-Cullell, N., & Taieb, C. (2009). Sensitive skin in Europe. *Journal of the European Academy of Dermatology and Venereology*, 23(4), 376-381. <https://doi.org/10.1111/j.1468-3083.2008.03037.x>.
- Mukhopadhyay, P. (2011). Cleansers and their role in various dermatological disorders. *Indian journal of dermatology*, 56(1), 2-6.
- Nelson, K., Taylor, E., & Walsh, D. (2020). Digital health literacy and accessibility. *Journal of Medical Internet Research*, 22(8), e18456.
- Park, S., Lee, J., & Kim, H. (2021). Deep learning-based skin condition classification using facial images. *IEEE Access*, 9, 43271–43280.
- Park, S., Moon, J., & Kim, Y. (2022). Accessibility and usability of AI-based skin diagnosis applications for general public. *International Journal of Human-Computer Interaction*, 38(5), 412–425.
- Research and Markets. (2023). *Global skin care products market size, share & trends analysis report 2023–2027*.
- Ricci, F., Rokach, L., & Shapira, B. (2022). *Recommender systems handbook* (3rd ed.). Springer.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1–48.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv Preprint arXiv:1409.1556*.
- World Health Organization. (2021). *Digital health for all: Strengthening digital health implementation*. WHO Press.