

Pengujian Metode Inception V3 dalam Klasifikasi Penyakit Kulit Dermatitis Atopik dan Psoriasis

Dwi Mei Rita Sari¹, Desti Destiansari Istinabiyah², Iga Apria³

^{1,2,3}Manajemen Informatika, Politeknik Negeri Sriwijaya, Palembang, Indonesia

Email: ¹dwimrs@polsri.ac.id, ²desti.istinabiyah@polsri.ac.id, ³igaapria@polsri.ac.id

Email Penulis Korespondensi: ¹dwimrs@polsri.ac.id

Abstrak– Penelitian ini bertujuan untuk menguji performa arsitektur *Convolutional Neural Network* (CNN) menggunakan metode Inception V3 dalam mengklasifikasikan dua jenis penyakit kulit, yaitu dermatitis atopik dan psoriasis. Metode Inception V3 digunakan sebagai *feature extractor* melalui pendekatan *transfer learning* untuk meningkatkan akurasi klasifikasi citra penyakit kulit. Dataset yang digunakan terdiri dari citra dermatitis atopik dan psoriasis yang telah melalui tahap pra-pemrosesan, meliputi *resizing*, augmentasi data, digitalisasi, dan *feature scaling*. Hasil pengujian terbaik menunjukkan bahwa metode Inception V3 mencapai akurasi sebesar 84%, dengan nilai presisi 82% dan *recall* 80%. Hasil ini menunjukkan bahwa arsitektur Inception V3 mampu memberikan performa klasifikasi yang baik pada kasus penyakit kulit dengan tingkat kemiripan visual yang tinggi.

Kata Kunci: Inception V3, CNN, *Deep Learning*, Dermatitis Atopik, Psoriasis

Abstract– This study aims to evaluate the performance of the *Convolutional Neural Network* (CNN) architecture using the Inception V3 method to classify two types of skin diseases, namely atopic dermatitis and psoriasis. The Inception V3 model was employed as a *feature extractor* through a *transfer learning* approach to improve the accuracy of skin disease image classification. The dataset consisted of images of atopic dermatitis and psoriasis that underwent preprocessing stages, including resizing, data augmentation, digitalization, and *feature scaling*. The experimental results show that the proposed method achieved an accuracy of 84%, with precision and recall values of 82% and 80%, respectively. These results indicate that the Inception V3 architecture performs effectively in classifying skin diseases with high visual similarity.

Keywords: Inception V3, CNN, *Deep Learning*, Atopic Dermatitis, Psoriasis

1. PENDAHULUAN

Kulit merupakan organ tubuh terbesar pada manusia yang mencakup lebih dari 10% massa tubuh dan berfungsi sebagai pelindung utama terhadap faktor lingkungan eksternal. Secara anatomis, kulit tersusun atas beberapa lapisan, yaitu stratum korneum, epidermis viable, dermis, dan jaringan subkutan [1]. Selain berperan sebagai pelindung mekanis, kulit juga berfungsi sebagai penghalang biologis terhadap patogen seperti bakteri, virus, dan agen inflamasi yang dapat memicu berbagai penyakit.

Penyakit kulit merupakan salah satu masalah kesehatan yang paling umum dijumpai di seluruh dunia. Lebih dari 100 juta orang mengalami berbagai jenis penyakit kulit, dengan prevalensi yang signifikan pada layanan kesehatan primer [2], [3]. Penyakit kulit dapat menyebabkan ruam, luka, peradangan, gatal, dan penyebab lainnya. Penyakit kulit merupakan salah satu gejala utama yang paling sering ditemukan dalam perawatan primer, dengan 8–36% pasien menunjukkan setidaknya satu penyakit kulit [3]. Beberapa penyakit kulit yang ditemukan pada manusia sederhana dan dapat segera diobati, tetapi tidak sedikit pula penyakit kulit yang sangat berbahaya dan mungkin tidak dapat disembuhkan [4]. Tantangan utama dalam penanganan penyakit kulit terletak pada proses diagnosis yang masih sangat bergantung pada keahlian klinis dokter serta pemeriksaan biopsi, yang memerlukan waktu dan biaya relatif tinggi [5].

Tantangan diagnosis menjadi semakin kompleks ketika dua atau lebih penyakit kulit menunjukkan karakteristik visual dan gejala klinis yang serupa. Dermatitis atopik dan psoriasis merupakan dua penyakit kulit inflamasi kronis yang memiliki kemiripan signifikan dalam aspek morfologi, distribusi lesi, dan manifestasi klinis. Kesamaan ini sering menyebabkan terjadinya kesalahan diagnosis yang berpotensi berdampak pada ketidaktepatan terapi dan meningkatnya beban biaya pengobatan bagi pasien [5], [6]. Oleh karena itu, diperlukan pendekatan diagnostik yang lebih akurat, objektif, dan efisien untuk membedakan kedua penyakit tersebut.

Diagnosis penyakit dan layanan perawatan kesehatan telah lama menjadi permintaan tinggi dan menghadapi tantangan yang signifikan. Hambatan biaya, waktu, dan lokasi membatasi kualitas layanan, dan pasien tidak dapat menerima layanan yang mereka peroleh. Penyakit kulit memengaruhi sekitar 1,9 miliar orang. 1 Jenis penyakit ini memerlukan tindak lanjut dengan dokter kulit, dan sebagian besar berlangsung lama, yang membuat hambatan yang disebutkan di atas lebih menantang. Teknologi memainkan peran penting dalam menyediakan solusi yang lebih cerdas dan kuat dan dapat mengatasi hambatan tersebut. *Artificial intelligence* (AI), *machine learning* (ML), dan *deep learning* (DL) menawarkan berbagai solusi yang kuat [7], [8]. Secara khusus, kondisi dermatologi bergantung pada fitur morfologi dan dapat didiagnosis di seluruh citra pasien. Diagnosis otomatis ini terutama didasarkan pada pengenalan pola visual. Alat dan teknologi pencitraan kulit menyediakan berbagai gaya dan desain yang telah menjadi penting untuk diagnosis klinis penyakit kulit.

Deep learning adalah bagian dari metode pembelajaran mesin yang terdiri dari beberapa lapisan untuk mengekstrak fitur tingkat tinggi dari data masukan mentah. *Deep learning* didasarkan pada jaringan yang mampu mempelajari data tanpa pengawasan (*unsupervised data*) yang tidak terstruktur atau tidak berlabel. Oleh karena itu, pembelajaran ini disebut *deep neural learning* atau *deep neural network*. *deep neural learning* telah digunakan di berbagai domain, termasuk kedokteran[9]. Deep Learning untuk analisis citra medis telah dibahas secara komprehensif oleh Litjens *et al.* [9], mencakup konsep, teknik, arsitektur, serta aplikasi seperti klasifikasi, deteksi, segmentasi, dan pembangkitan citra medis. *Deep Learning* biasanya berfokus pada sistem klasifikasi, deteksi, segmentasi, dan pembangkitan citra medis. *Deep Learning* terbagi atas *supervised learning*, *weakly supervised learning*, dan *unsupervised learning*. Perbedaan utama antara ketiga skema pembelajaran ini terletak pada proporsi dan perbedaan granularitas label beranotasi yang menggerakkan model. Jaringan saraf dalam yang umum terutama direpresentasikan oleh jaringan saraf konvolusional (CNN), jaringan saraf rekuren (RNN), dan jaringan adversarial generatif (GAN).

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI), khususnya machine learning dan deep learning, telah membuka peluang baru dalam bidang diagnosis medis berbasis citra. Deep learning, terutama melalui Convolutional Neural Network (CNN), terbukti efektif dalam mengekstraksi fitur visual kompleks dari citra medis dan telah banyak diterapkan pada tugas klasifikasi, deteksi, dan segmentasi citra dermatologi [9]. Namun demikian, sejumlah penelitian sebelumnya melaporkan bahwa akurasi CNN dalam klasifikasi lesi kulit masih berada pada tingkat sedang, umumnya di bawah 80%, terutama ketika dihadapkan pada variasi citra yang tinggi dan kemiripan fitur antar kelas [10].

Keterbatasan tersebut menunjukkan adanya kesenjangan penelitian (research gap), khususnya dalam pemanfaatan arsitektur CNN yang lebih dalam dan kompleks untuk meningkatkan akurasi klasifikasi penyakit kulit yang memiliki kemiripan visual tinggi. Salah satu arsitektur CNN yang berpotensi mengatasi permasalahan tersebut adalah Inception V3, yang dirancang untuk mengekstraksi fitur multi-skala secara lebih efektif melalui kombinasi berbagai ukuran kernel konvolusi dalam satu modul.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menguji performa arsitektur Inception V3 berbasis transfer learning dalam mengklasifikasikan dua penyakit kulit yang sulit dibedakan secara visual, yaitu dermatitis atopik dan psoriasis. Kontribusi utama penelitian ini adalah memberikan evaluasi empiris terhadap efektivitas Inception V3 pada skenario klasifikasi dermatologi yang spesifik, sekaligus menganalisis tantangan yang muncul, seperti indikasi overfitting, sebagai dasar pengembangan penelitian lanjutan.

2. METODOLOGI PENELITIAN

2.1 Data Preparation

Dataset yang digunakan pada pengujian ini diperoleh dari website resmi DermIs, DermNet, dan DermatoWeb [13]. Total dataset yang digunakan adalah 3.376 citra penyakit kulit Dermatitis atopik dan psoriasis. Dataset terbagi atas 2.640 citra untuk set pelatihan, 661 citra untuk set pengujian, dan 75 citra untuk data yang tidak terlihat. Resolusi citra yang akan digunakan dalam penelitian ini adalah 224 X 224. Resolusi ini digunakan karena ukuran citra input default pada arsitektur Inception V3 adalah 224 X 224.



Gambar 1. Dataset

2.2 Data Preprocessing

Data preprocessing dilakukan untuk mempersiapkan data citra sebelum dimasukkan ke dalam model CNN. Hal ini dilakukan agar proses pelatihan berjalan lebih efektif dan hasil prediksi lebih akurat. Pada proses ini, tahap augmentasi data digunakan untuk meningkatkan jumlah data tanpa kehilangan esensi data. Data augmentasi yang dilakukan pada pengujian ini meliputi rotasi, flipping, zoom dan shear. Augmentasi data dilakukan secara otomatis menggunakan generator data citra yang akan mengubah data dari citra mentah menjadi citra augmented.

Hasil dari augmentasi data, didapatkan 1.569 citra untuk kasus dermatitis atopik dan 1.807 citra untuk kasus psoriasis. Setelah menerapkan semua transformasi, setiap citra di digitalisasi. Proses selanjutnya yaitu pembagian dataset



menjadi 2.640 citra (80% dari total dataset) yang digunakan sebagai set pelatihan dan 661 citra (20% dari seluruh dataset) digunakan sebagai set pengujian. Selain itu juga ada 75 citra yang digunakan sebagai data yang tidak terlihat.

Tabel 1. Transformasi yang diterapkan pada Proses Augmentasi Data

<i>Transformasi</i>	<i>Probabilitas</i>
Rotation	20 ⁰
Random Zoom	0.2
Shear	0.2
Vertical Flip	0.5
Horizontal Flip	0.5
Horizontal Shift	0.2
Vertical Shift	0.2

2.3 Convolutional Neural Network

Tahap pengklasifikasian *Convolutional Neural Network* (CNN) atau Jaringan Saraf Tiruan merupakan inti dari proses klasifikasi penyakit kulit dermatitis atopik dan psoriasis pada penelitian ini. Proses ini memanfaatkan metode *transfer learning* dengan menerapkan metode *Inception V3*. Metode tersebut digunakan sebagai *feature extractor* utama yang mampu mengekstraksi pola visual secara mendalam dari citra dermatologi, sehingga memungkinkan sistem mengenali karakteristik khusus dari kedua jenis penyakit kulit. Tahapan pengklasifikasian CNN mencakup tiga proses utama, yaitu proses pelatihan, proses pengujian, dan proses pengujian dengan data *unseen*.

Pada proses pelatihan (*training process*), model CNN menerima input berupa citra yang telah melalui tahap pra-pemrosesan, termasuk digitalisasi, resizing, dan augmentasi. Selama proses ini, model melakukan operasi *forward pass* untuk menghasilkan prediksi sementara, yang kemudian dibandingkan dengan label sebenarnya untuk memperoleh nilai error. Nilai error tersebut dikembalikan ke jaringan melalui mekanisme *backpropagation* guna memperbarui bobot pada lapisan konvolusional maupun *fully-connected*. Proses ini berlangsung secara iteratif sehingga model mampu mempelajari representasi fitur yang relevan serta meningkatkan akurasi prediksi pada setiap epoch. Penggunaan teknik *transfer learning* sekaligus memungkinkan pemanfaatan bobot awal dari model yang telah dilatih pada dataset berskala besar, sehingga mempercepat proses konvergensi dan mengurangi risiko *overfitting*.

Selanjutnya, pada tahap pengujian (*testing process*), model dievaluasi menggunakan 20% data yang tidak disertakan dalam pelatihan. Evaluasi dilakukan untuk mengetahui kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya, serta untuk menilai konsistensi performa model dari hasil pelatihan. Pada tahap ini, berbagai metrik evaluasi digunakan, seperti akurasi dan presisi, serta kurva akurasi dan kurva loss. Selain itu, *confusion matrix* dianalisis untuk mengidentifikasi distribusi prediksi benar dan prediksi salah pada masing-masing kelas. Tahap pengujian ini memberikan gambaran awal mengenai performa model dan kestabilannya dalam membedakan citra dermatitis atopik dan psoriasis.

Tahap terakhir adalah pengujian menggunakan data *unseen*, yaitu data baru yang tidak termasuk dalam dataset pelatihan maupun pengujian. Tahapan ini bertujuan untuk memperoleh estimasi performa yang lebih objektif dan realistis terhadap kemampuan model menghadapi keragaman citra di dunia nyata.

2.4 Validasi

Validasi merupakan tahapan untuk mengukur kinerja suatu sistem klasifikasi. Kinerja sistem klasifikasi menggambarkan seberapa baik sistem tersebut dalam mengklasifikasikan data. Metode yang digunakan untuk mengukur kinerja sistem klasifikasi pada pengujian ini yaitu *confusion matrix*. Pada dasarnya *confusion matrix* berisi informasi yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya [11]. Dalam pengukuran kinerja menggunakan *confusion matrix* terdapat 4 (empat) istilah sebagai representasi dari hasil proses klasifikasi. Keempat istilah tersebut adalah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). Nilai *True Negative* (TN) merupakan banyaknya data negatif yang terdeteksi dengan benar, sedangkan *False Positive* (FP) merupakan data negatif tetapi terdeteksi sebagai data positif. Sedangkan *True Positive* (TP) merupakan data positif yang terdeteksi dengan benar. *False Negative* (FN) merupakan kebalikan dari *True Positive*, sehingga datanya positif, tetapi terdeteksi sebagai data negatif. Pada jenis klasifikasi biner yang hanya memiliki 2 kelas keluaran, *confusion matrix* dapat disajikan seperti pada Tabel 2 [12].

Tabel 2. Confusion Matrix

Class	Positive Classified	Negatif Classified
Positive	TP (True Positive)	FN (False Negative)





Negative	FP (False Positive)	TN (True Negative)
----------	---------------------	--------------------

Nilai akurasi, presisi dan recall dapat diperoleh berdasarkan nilai *True Negative* (TN), *False Positive* (FP), *False Negative* (FN), dan *True Positive* (TP). Nilai akurasi menggambarkan seberapa akurat sistem dapat mengklasifikasikan data dengan benar. Dengan kata lain, nilai akurasi merupakan perbandingan antara data yang terklasifikasi dengan benar dengan seluruh data. Nilai akurasi menggambarkan proporsi total prediksi yang benar terhadap keseluruhan data. Nilai akurasi dihitung menggunakan Persamaan (1):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \tag{1}$$

Presisi menunjukkan proporsi data kategori positif yang berhasil diprediksi dengan benar dibandingkan seluruh data yang diprediksi positif. Nilai presisi dihitung menggunakan Persamaan (2):

$$Precision = \frac{TP}{TP + FP} \times 100\% \tag{2}$$

Recall (atau Sensitivitas) mengukur kemampuan sistem dalam mengenali seluruh data kategori positif yang sebenarnya. Nilai recall dihitung menggunakan Persamaan (3):


$$Recall = \frac{TP}{TP + FN} \times 100\% \tag{3}$$

3. HASIL DAN PEMBAHASAN

Pada proses pengklasifikasian *Convolutional Neural Network* (CNN), metode *Inception V3* digunakan pada proses pelatihan dan pengujian untuk klasifikasi biner antara penyakit kulit dermatitis atopik dengan psoriasis. Metode *Inception V3* diuji dengan learning rate 10^{-3} dan 50 epoch menggunakan fungsi aktivasi ReLU serta *loss function binary cross entropy*.

3.1 Hasil Akurasi

Pada pengujian ini, proses pelatihan dilakukan dengan memanfaatkan arsitektur *Inception V3*. Seluruh bobot pada jaringan *pre-trained* dipertahankan dan tidak mengalami pembaruan selama pelatihan, karena. Pelatihan dilakukan dengan menerapkan fungsi aktivasi ReLU pada lapisan *fully connected*, sementara lapisan keluaran menggunakan fungsi aktivasi sigmoid. Proses optimasi menggunakan fungsi *loss binary cross entropy*, algoritma optimisasi Adam dengan *learning rate* 10^{-3} , serta jumlah pelatihan sebanyak 50 *epoch*. Visualisasi akurasi dan nilai *loss* dari proses pelatihan dan pengujian untuk metode *Inception V3* sebagai ekstraktor fitur ditampilkan pada Gambar 2 dan Gambar 3.



Gambar 2. Grafik Akurasi dengan menggunakan arsitektur *Inception V3*



Gambar 3. Grafik Loss dengan menggunakan arsitektur Inception V3

Hasil pengujian menunjukkan bahwa arsitektur Inception V3 yang diterapkan sebagai feature extractor dengan pendekatan transfer learning mampu mencapai akurasi sebesar 84% pada data uji dan 82% pada data unseen. Nilai presisi sebesar 82% dan recall sebesar 80% menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengidentifikasi citra dermatitis atopik sebagai kelas positif, meskipun masih terdapat sejumlah kesalahan klasifikasi.

Jika dibandingkan dengan penelitian-penelitian sebelumnya yang menggunakan arsitektur CNN konvensional untuk klasifikasi penyakit kulit, hasil yang diperoleh pada penelitian ini menunjukkan peningkatan performa. Beberapa studi terdahulu melaporkan akurasi klasifikasi lesi kulit di bawah 80%, yang dipengaruhi oleh keterbatasan ukuran dataset, variasi citra, serta kedalaman jaringan yang menyebabkan permasalahan vanishing gradient [10]. Peningkatan akurasi pada penelitian ini mengindikasikan bahwa arsitektur Inception V3 dengan mekanisme ekstraksi fitur multi-skala mampu menangkap karakteristik visual yang lebih representatif pada citra dermatitis atopik dan psoriasis.

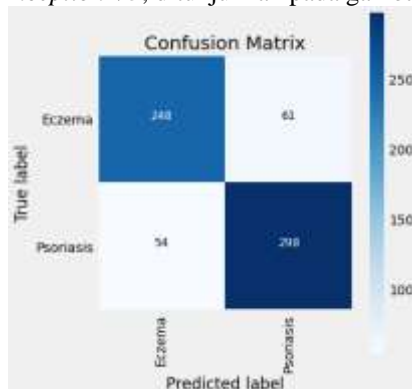
Meskipun demikian, hasil visualisasi kurva akurasi dan loss menunjukkan adanya indikasi *overfitting*, yang ditandai dengan perbedaan kinerja antara data pelatihan dan data pengujian. Kondisi ini mengindikasikan bahwa model masih cenderung menyesuaikan diri secara berlebihan terhadap data pelatihan. Fenomena ini sejalan dengan temuan pada penelitian sebelumnya yang menyatakan bahwa klasifikasi citra dermatologi dengan variasi tinggi memerlukan strategi pra-pemrosesan dan regularisasi yang lebih kuat [10]. Hasil penelitian ini tidak hanya menunjukkan efektivitas Inception V3 dalam meningkatkan akurasi klasifikasi penyakit kulit, tetapi juga menegaskan pentingnya pengembangan lebih lanjut pada tahap pra-pemrosesan data, seperti augmentasi yang lebih variatif, penyeimbangan kelas, serta penerapan teknik regularisasi tambahan. Hasil proses pelatihan dengan menggunakan model pre-trained Inception V3 sebagai ekstraktor fitur ditunjukkan pada Tabel 3.

Tabel 3. Hasil Kinerja Metode Inception V3

Models	Learning Rate	Epoch	Accuracy	Presisi	Recall
Inception V3	10^{-3}	50	0,84	0,82	0,80

3.2 Hasil Confusion Matrix

Metode *confusion matrix* digunakan untuk mengukur kinerja sistem klasifikasi pada pengujian ini. Sebanyak 661 citra digunakan sebagai dataset pengujian. *Confusion Matrix* untuk klasifikasi penyakit kulit dermatitis atopik dan psoriasis dengan menggunakan metode arsitektur Inception V3, ditunjukkan pada gambar 4.



Gambar 3. Pengujian Confusion Matrix dengan menggunakan metode Inception V3

Evaluasi melalui *confusion matrix* menunjukkan bahwa dari 661 citra data yang diuji, sebanyak 248 citra berhasil diklasifikasi sebagai penyakit Dermatitis atopik dan 298 citra berhasil diklasifikasi sebagai penyakit Psoriasis. Hal ini memperlihatkan bahwa metode Inception V3 mampu mendeteksi sebagian besar citra dermatitis atopik maupun psoriasis, meskipun masih terdapat kesalahan klasifikasi terutama pada bagian *false negative*.



4. KESIMPULAN

Berdasarkan hasil pengujian yang telah dilakukan, dapat disimpulkan bahwa arsitektur Inception V3 berbasis transfer learning mampu memberikan performa yang baik dalam klasifikasi penyakit kulit dermatitis atopik dan psoriasis dengan tingkat akurasi mencapai 84%. Temuan ini menunjukkan bahwa Inception V3 efektif dalam mengekstraksi fitur visual multi-skala pada citra dermatologi yang memiliki kemiripan karakteristik tinggi. Meskipun masih ditemukan indikasi *overfitting*, hasil penelitian ini memberikan dasar empiris yang kuat bagi pengembangan sistem pendukung diagnosis penyakit kulit berbasis citra, khususnya pada layanan kesehatan primer, serta membuka peluang penelitian lanjutan melalui penguatan strategi pra-pemrosesan dan regularisasi model.

UCAPAN TERIMAKASIH

Penulis menyampaikan penghargaan dan ucapan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah memberikan dukungan dalam penyelesaian penelitian ini. Penulis secara khusus mengucapkan terima kasih kepada repositori citra dermatologi DermNet, DermIS, dan DermatoWeb yang telah menyediakan dataset terbuka sehingga penelitian ini dapat dilaksanakan dengan baik.

Penulis juga menyampaikan apresiasi kepada rekan-rekan peneliti yang telah memberikan arahan, masukan konstruktif, dan dukungan berkelanjutan selama proses penelitian berlangsung. Tidak lupa, penulis berterima kasih kepada institusi terkait yang telah menyediakan fasilitas, layanan teknis, dan sumber daya komputasi yang sangat membantu dalam pelaksanaan eksperimen dan analisis data pada penelitian ini.

REFERENCES

- [1] S. L. Prescott *et al.*, "The skin microbiome: impact of modern environments on skin ecology, barrier integrity, and systemic immune programming," *World Allergy Organization Journal*, vol. 10, p. 29, 2017, doi: <https://doi.org/10.1186/s40413-017-0160-5>.
- [2] R. J. Hay *et al.*, "The Global Burden of Skin Disease in 2010: An Analysis of the Prevalence and Impact of Skin Conditions," *Journal of Investigative Dermatology*, vol. 134, no. 6, pp. 1527–1534, 2014, doi: <https://doi.org/10.1038/jid.2013.446>.
- [3] E. T. Anwar *et al.*, "Skin Diseases and their Treatment Strategies in Sub-Saharan African Regions," *Infect. Disord. Drug Targets*, vol. 22, no. 2, pp. 41–54, 2022, doi: <https://doi.org/10.2174/1871526521666210927120334>.
- [4] A. Gadre, W. Enbiale, L. K. Andersen, and S. J. Coates, "The effects of climate change on fungal diseases with cutaneous manifestations: A report from the International Society of Dermatology Climate Change Committee," *The Journal of Climate Change and Health*, vol. 6, p. 100156, 2022, doi: <https://doi.org/10.1016/j.joclim.2022.100156>.
- [5] D. Y. M. Leung and E. Guttman-Yassky, "Deciphering the complexities of atopic dermatitis: Shifting paradigms in treatment approaches," *Journal of Allergy and Clinical Immunology*, vol. 134, no. 4, pp. 769–779, 2014, doi: <https://doi.org/10.1016/j.jaci.2014.08.008>.
- [6] B. E. Rosenbaum *et al.*, "Dermatology in Ghana: A retrospective review of skin disease at the Korle Bu Teaching Hospital Dermatology Clinic," *Pan African Medical Journal*, vol. 26, Mar. 2017, doi: [10.11604/pamj.2017.26.125.10954](https://doi.org/10.11604/pamj.2017.26.125.10954).
- [7] S. Aman, M. Nadeem, K. Mahmood, and M. B. Ghaffoor, "Pattern of skin diseases among patients attending a tertiary care hospital in Lahore, Pakistan," *J. Taibah Univ. Med. Sci.*, vol. 12, no. 5, pp. 392–396, 2017, doi: <https://doi.org/10.1016/j.jtumed.2017.04.007>.
- [8] Z. Apalla, D. Nashan, R. B. Weller, and X. Castellsagué, "Skin Cancer: Epidemiology, Disease Burden, Pathophysiology, Diagnosis, and Therapeutic Approaches," *Dermatol. Ther. (Heidelb)*, vol. 7, no. 1, pp. 5–19, 2017, doi: [10.1007/s13555-016-0165-y](https://doi.org/10.1007/s13555-016-0165-y).
- [9] G. Litjens *et al.*, "A survey on deep learning in medical image analysis," *Med. Image Anal.*, vol. 42, pp. 60–88, 2017, doi: <https://doi.org/10.1016/j.media.2017.07.005>.
- [10] H. Zhou, F. Xie, Z. Jiang, J. Liu, S. Wang, and C. Zhu, "Multi-classification of skin diseases for dermoscopy images using deep learning," in *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, 2017, pp. 1–5. doi: [10.1109/IST.2017.8261543](https://doi.org/10.1109/IST.2017.8261543).
- [11] J. M. G. Aglibut, L. L. Alonzo, M. F. B. Coching, J. L. Torres, and N. B. Linsangan, "Skin Disease Identification System using Gray Level Co-occurrence Matrix," in *Proceedings of the 9th International Conference on Computer and Automation Engineering*, in ICCAE '17. New York, NY, USA: Association for Computing Machinery, 2017, pp. 136–140. doi: [10.1145/3057039.3057044](https://doi.org/10.1145/3057039.3057044).
- [12] L. C. De Guzman, R. P. C. Maglaque, V. M. B. Torres, S. P. A. Zapido, and M. O. Cordel, "Design and Evaluation of a Multi-model, Multi-level Artificial Neural Network for Eczema Skin Lesion Detection," in *2015 3rd International Conference on Artificial Intelligence, Modelling and Simulation (AIMS)*, 2015, pp. 42–47. doi: [10.1109/AIMS.2015.17](https://doi.org/10.1109/AIMS.2015.17).
- [13] DermNet New Zealand, "DermNet NZ," *DermNet*, Accessed: Dec. 2, 2025. Available: <https://dermnetnz.org/>