

PERBANDINGAN *BALANCING DATA* ANTARA AUGMENTASI, *CLASS WEIGHT* DAN KOMBINASI AUGMENTASI + *CLASS WEIGHT* DALAM KLASIFIKASI MULTI-KELAS LESI KULIT BERBASIS CITRA DERMATOSKOPIK MENGGUNAKAN *SWIN TRANSFORMER*

Skripsi

Oleh

**FATUR ROZAK
NPM. 2217031138**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

ABSTRACT

COMPARISON OF DATA BALANCING TECHNIQUES BETWEEN AUGMENTATION, CLASS WEIGHT, AND A COMBINATION OF AUGMENTATION AND CLASS WEIGHT IN MULTI-CLASS SKIN LESION CLASSIFICATION BASED ON DERMOSCOPIC IMAGES USING SWIN TRANSFORMER

By

Fatur Rozak

Skin lesion classification based on dermoscopic images is an important approach to support the early detection of skin cancer. However, imbalanced data often becomes a major challenge in multi-class classification, as it can degrade model performance, particularly in recognizing minority classes. This study aims to analyze the effect of data balancing techniques on the performance of a Transformer-based skin lesion classification model using the HAM10000 dataset, which consists of seven skin lesion classes. The model employed is the Swin Transformer with four training scenarios: (1) without any balancing technique, (2) using data augmentation, (3) using class weights, and (4) a combination of data augmentation and class weights. The experimental results show that the model using the combined balancing technique of data augmentation and class weights achieves the best and most balanced performance across evaluation metrics, with an accuracy of 88.77%, precision of 83.28%, sensitivity of 83.42%, specificity of 97.07%, F1-score of 83.10%, and an AUC value of 99.04%. These results indicate that the combination of data variation and penalty through weighting enables the Swin Transformer model to learn the data effectively while minimizing errors compared to training without balancing, with data augmentation only, or with class weights only. Furthermore, this study demonstrates that the choice of data balancing techniques significantly affects model performance, especially for multi-class imbalanced datasets such as HAM10000.

Keywords: Skin Lesion, Classification, Augmentation, Class Weight, Comparison, Balancing Data.

ABSTRAK

PERBANDINGAN *BALANCING DATA* ANTARA AUGMENTASI, *CLASS WEIGHT* DAN KOMBINASI AUGMENTASI + *CLASS WEIGHT* DALAM KLASIFIKASI MULTI-KELAS LESI KULIT BERBASIS CITRA DERMATOSKOPIK MENGGUNAKAN *SWIN TRANSFORMER*

Oleh

Fatur Rozak

Klasifikasi lesi kulit berbasis citra dermatoskopi merupakan pendekatan penting dalam mendukung deteksi dini kanker kulit. Namun, *imbalanced data* sering menjadi tantangan utama dalam klasifikasi multi-kelas karena dapat menurunkan performa model, khususnya dalam mengenali kelas minoritas. Penelitian ini bertujuan untuk menganalisis pengaruh teknik *balancing data* terhadap performa model klasifikasi lesi kulit berbasis *Transformer* menggunakan dataset HAM10000 yang terdiri dari tujuh kelas lesi kulit. Model yang digunakan adalah *Swin Transformer* dengan empat skenario pelatihan, yaitu: (1) tanpa teknik *balancing*, (2) menggunakan augmentasi data, (3) menggunakan *class weight*, dan (4) kombinasi augmentasi dan *class weight*. Hasil eksperimen menunjukkan bahwa model dengan teknik *balancing* gabungan antara augmentasi + *class weight* memberikan performa terbaik dan seimbang untuk metrik evaluasinya dengan *accuracy* mencapai 88,77%, *precision* 83,28%, *sensitivity* 83,42%, *specificity* 97,07%, *f1-score* 83,10% dan nilai AUC sebesar 99,04%. Hasil tersebut menunjukkan kombinasi variasi dan penalti oleh bobot menjadikan model *Swin Transformer* mampu mempelajari data dengan baik dengan meminimalisir kesalahan dibanding tanpa *balancing*, dengan augmentasi saja dan dengan *class weight* saja. Hasil ini juga membuktikan bahwa pemilihan teknik *balancing* dapat mempengaruhi performa model terutama untuk data *imbalance* multi-kelas seperti data HAM10000.

Kata-kata kunci: Lesi Kulit, Klasifikasi, Augmentasi, *Class Weight*, Perbandingan, *Balancing Data*.

PERBANDINGAN *BALANCING DATA* ANTARA AUGMENTASI, *CLASS WEIGHT* DAN KOMBINASI AUGMENTASI + *CLASS WEIGHT* DALAM KLASIFIKASI MULTI-KELAS LESI KULIT BERBASIS CITRA DERMATOSKOPIK MENGGUNAKAN *SWIN TRANSFORMER*

FATUR ROZAK

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

Judul Skripsi

: **PERBANDINGAN *BALANCING DATA* ANTARA *AUGMENTASI, CLASS WEIGHT* DAN KOMBINASI *AUGMENTASI + CLASS WEIGHT* DALAM KLASIFIKASI MULTI-KELAS LESI KULIT BERBASIS CITRA DERMATOSKOPIK MENGGUNAKAN *SWIN TRANSFORMER***

Nama Mahasiswa

: **Fatur Rozak**

Nomor Pokok Mahasiswa : **2217031138**

Program Studi

: **Matematika**

Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing


Dr. Dian Kurniasari, S.Si., M.Sc.
NIP 198406272006042001


Dr. Purnomo Husnul Khotimah, M.T.
NIP 198003232005022002

2. Ketua Jurusan Matematika


Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

I. Tim Penguji


Ketua

: **Dr. Dian Kurniasari, S.Si., M.Sc.**




Sekretaris

: **Dr. Purnomo Husnul Khotimah,
M.T.**



Penguji

Bukan Pembimbing : **Ir. Warsono, M.S., Ph.D.**




2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi: **29 Januari 2026**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Fatur Rozak**

Nomor Pokok Mahasiswa : **2217031138**

Jurusan : **Matematika**

Judul Skripsi : **PERBANDINGAN PENYEIMBANGAN DATA ANTARA AUGMENTASI, CLASS WEIGHT DAN KOMBINASI AUGMENTASI + CLASS WEIGHT DALAM KLASIFIKASI MULTI-KELAS LESI KULIT BERBASIS CITRA DERMATOSKOPIK MENGGUNAKAN SWIN TRANSFORMER**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 29 Januari 2026

Pennulis



Fatur Rozak

RIWAYAT HIDUP

Fatur Rozak lahir di Negara Saka, Kabupaten Pesawaran, pada 18 Desember 2003. Penulis merupakan anak dari pasangan Bapak Ridwan dan Ibu Siti Maimunah. Pendidikan penulis dimulai di MIN 2 Pesawaran (2010-2016), dilanjutkan ke SMP SWADHIPA 1 Natar (2016–2019), dan SMA SWADHIPA Natar (2019-2022).

Pada tahun 2022, penulis melanjutkan pendidikan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN). Selama masa perkuliahan, penulis aktif dalam kegiatan organisasi kemahasiswaan, antara lain sebagai anggota Bidang Keilmuan Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) pada tahun 2023, serta menjabat sebagai Kepala Bidang Finansial Pusat Informasi dan Konseling (PIK) R RAYA tahun 2024.

Selain aktif berorganisasi, penulis juga mengikuti berbagai perlombaan dan kegiatan akademik. Pada tahun 2024, penulis meraih Juara Favorit Lomba Fotografi di Universitas Brawijaya, Juara Harapan I Lomba Esai Universitas Hasanuddin, dengan karya yang dipublikasikan sebagai artikel ilmiah berjudul *“Safe Breath: A Concept for Air Quality Monitoring App using Internet of Things and Early Detection to Support Tuberculosis Elimination by 2030”*. Penulis pernah menjadi peserta lomba GEMASTIK dan Satria Data tahun 2024 dan 2025 dengan peraihan tertinggi menjadi Finalis Top 15 Lomba *Statistic Essay Competition* (SEC) Satria Data tahun 2025 yang diselenggarakan oleh Belmawa. Sebagai bentuk pengimplementasian ilmu, penulis melaksanakan Praktik Kerja Lapangan di PT Regional Office Bank Rakyat Indonesia (Persero) Tbk (Desember 2024-Januari 2025), serta mengikuti program Magang MBKM Mandiri di BRIN KST Samaun Samadikun (Februari-Juli 2025) dan Kantor Perwakilan Bank Indonesia Provinsi Lampung (Oktober-Desember 2025).

KATA INSPIRASI

“Orang lain gak akan bisa paham struggle dan masa sulitnya kita, yang mereka ingin tahu hanya bagian success storiesnya. Berjuanglah untuk diri sendiri. Walaupun ga ada yang tepuk tangan, kelak diri kita di masa depan akan sangat bangga dengan apa yang kita perjuangkan hari ini, TETAP BERJUANG YA!”

(Fardi Yandi)

“Perang telah usai, aku bisa pulang. Kubaringkan panah dan berteriak MENANG”

(Nadin Amizah)

”Rasa takut memang pasti datang, tetapi jangan pernah biarkan ia menjadi alasan untuk menyerah”

”Tanam hari ini, petik hasil di kemudian hari”

PERSEMBAHAN

Dengan mengucapkan Alhamdulillah dan syukur kepada Allah SWT atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan Bahagia, saya persembahkan rasa terima kasih saya kepada:

Papah, Mamah dan Saudariku

Terima kasih kepada orang tua dan saudariku atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Terima kasih telah memberikan pelajaran berharga kepada anak/adik/kakakmu ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi banyak orang.

Dosen Pembimbing dan Pembahas

Terima kasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

Sahabat-sahabatku

Terima kasih kepada semua teman yang telah memberikan pengalaman, semangat, motivasinya, doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

Almamater Tercinta

Universitas Lampung

SANWACANA

Alhamdulillah, puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul “Perbandingan Penyeimbangan Data Antara Augmentasi, *Class Weight* dan Kombinasi Augmentasi + *Class Weight* dalam Klasifikasi Multi-Kelas Lesi Kulit Berbasis Citra Dermatoskopik Menggunakan *Swin Transformer*” dengan baik dan lancar serta tepat pada waktu yang telah ditentukan. Shalawat serta salam semoga senantiasa tercurahkan kepada Nabi Muhammad SAW. Penulis ingin mengucapkan terima kasih kepada:

1. Ibu Dr. Dian Kurniasari, S.Si., M.Sc., selaku Dosen Pembimbing I yang senantiasa memberikan bimbingan, arahan, saran, serta motivasi yang diberikan selama proses penyusunan skripsi ini. Kesabaran dan ketelitian beliau dalam membimbing penulis sangat membantu dalam menyelesaikan penelitian ini dengan baik. Penulis juga berterima kasih atas waktu dan perhatian yang telah diberikan, sehingga skripsi ini dapat diselesaikan sesuai dengan ketentuan yang berlaku.
2. Ibu Dr. Purnomo Husnul Khotimah, M.T., selaku Dosen Pembimbing II yang senantiasa memberikan bimbingan, masukan, serta saran yang konstruktif selama proses penyusunan skripsi ini. Dukungan dan arahan yang diberikan beliau sangat berarti dalam memperbaiki kualitas penulisan dan penyempurnaan skripsi ini.
3. Bapak Ir. Warsono, M.S., Ph.D., selaku Dosen Penguji atas saran, kritik, serta masukan yang konstruktif selama proses ujian skripsi. Masukan yang diberikan sangat membantu penulis dalam memperbaiki dan menyempurnakan skripsi ini.
4. Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

5. Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Ibu Dr. Fitriani, S.Si., M.Sc., selaku Dosen Pembimbing Akademik yang telah memberikan bimbingan kepada penulis selama perkuliahan.
7. Keluargaku tercinta, dengan penuh rasa hormat dan cinta, penulis mengucapkan terima kasih yang tak terhingga kepada kedua orang tua tercinta, Bapak Ridwan dan Ibu Siti Mainunah. Terima kasih atas setiap doa yang tidak pernah terputus, atas kesabaran yang tak pernah mengeluh, serta atas pengorbanan yang sering kali tidak terucap dengan kata-kata. Segala lelah dan perjuangan yang Bapak dan Ibu berikan menjadi alasan terbesar bagi penulis untuk terus bertahan dan menyelesaikan skripsi ini. Penulis juga menyampaikan rasa terima kasih yang mendalam kepada Kiay Riana, Kakak Mega Lestari dan Adik Sang Diah Pita Loka, atas doa, nasihat, dan ketenangan yang selalu diberikan, khususnya di saat penulis merasa ragu dan lelah dalam menjalani proses penyusunan skripsi ini.
8. Teman-teman seperbimbingan dan teman-teman magang di BRIN KST Samaun Samadikun, Tama, Erin, Anita, Fadillah, Mei, Nadia, Khusni, Benaya, Rizki, Nazla, Annisa, Puone dan Naufal yang telah menemani, membantu dan memberikan dukungan selama mengerjakan skripsi.
9. Keluarga besar organisasi UKM PIK R RAYA Periode 2024, HIMATIKA Bidang Keilmuan periode 2023 dan MOKA 6 yang selalu memberikan semangat dan dukungan kepada penulis.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 29 Januari 2026

Fatur Rozak
NPM. 2217031138

DAFTAR ISI

Halaman

DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xv
DAFTAR GAMBAR.....	xvi
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
II TINJAUAN PUSTAKA	6
2.1 Penelitian Terkait	6
2.2 Lesi Kulit	10
2.3 Citra Digital	17
2.4 Klasifikasi	19
2.5 <i>Deep Learning</i>	20
2.5.1 <i>Swin Transformer</i>	21
2.6 <i>Image Pre-processing</i>	24
2.6.1 <i>Splitting Data</i>	25
2.6.2 <i>Resize</i>	25
2.6.3 <i>Balancing Data</i>	26
2.6.4 <i>Normalisasi ImageNet</i>	27
2.6.5 <i>Hyperparameter Tuning</i>	28
2.7 Metrik Evaluasi	29
III METODOLOGI PENELITIAN	36
3.1 Waktu dan Tempat Penelitian	36
3.1.1 Tempat Penelitian	36
3.1.2 Waktu Penelitian	36

3.2	Data dan Alat	37
3.2.1	Data	37
3.2.2	Alat	40
3.3	Metode Penelitian	42
IV	HASIL DAN PEMBAHASAN.....	45
4.1	Input Data	45
4.2	<i>Pre-processing Data</i>	46
4.2.1	<i>Splitting Data</i>	46
4.2.2	<i>Resize</i>	47
4.2.3	<i>Balancing Data</i>	47
4.2.4	<i>Normalization Imagenet</i>	50
4.3	<i>Hyperparameter Tuning</i>	54
4.4	Hasil Evaluasi Model Swin Transformer	55
4.4.1	Evaluasi Model Tanpa Teknik <i>Balancing Data</i>	55
4.4.2	Evaluasi Model Menggunakan <i>Balancing Data</i> (Teknik Augmentasi)	66
4.4.3	Evaluasi Model Menggunakan <i>Balancing Data</i> (Teknik <i>Class Weight</i>)	78
4.4.4	Evaluasi Model Menggunakan <i>Balancing Data</i> (Teknik Augmentasi + <i>Class Weight</i>)	90
4.4.5	Perbandingan Hasil Model	103
4.4.6	Perbandingan Hasil Model dengan Penelitian Terdahulu	105
V	KESIMPULAN DAN SARAN.....	108
5.1	Kesimpulan	108
5.2	Saran	110
	DAFTAR PUSTAKA.....	111

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait	6
2. Contoh Informasi Data	37
3. Distribusi Kelas Dataset HAM10000	40
4. Jenis dan Nilai Parameter	54
5. Hasil Kombinasi <i>Hyperparameter Tuning</i>	54
6. Hasil Model Tanpa <i>Balancing</i>	66
7. Hasil Model Menggunakan <i>Balancing Data</i> (Augmentasi)	78
8. Hasil Model Menggunakan <i>Balancing Data</i> (Teknik <i>Class Weight</i>)	90
9. Hasil Model Menggunakan Teknik Augmentasi + <i>Class Weight</i>	102
10. Perbandingan Hasil Metrik Evaluasi	103
11. Hasil Perbandingan Penelitian Terdahulu	105

DAFTAR GAMBAR

Gambar	Halaman
1. Lesi Kulit AKIEC	12
2. Lesi Kulit BCC	13
3. Lesi Kulit BKL	14
4. Lesi Kulit DF	14
5. Lesi Kulit MEL	16
6. Lesi Kulit NV	17
7. Lesi Kulit DF	17
8. Ilustrasi Arsitektur <i>Deep Learning</i>	21
9. Pergeseran Jendela <i>Swin Transformer</i> (Liu dkk., 2021)	22
10. Perbedaan <i>Swin Transformer</i> dan ViT (Liu dkk., 2021)	23
11. Arsitektur <i>Swin Transformer</i> (Liu dkk., 2021)	23
12. <i>Confusion Matrix</i> (Markoulidakis dkk., 2021)	29
13. Sampel Gambar Lesi Kulit	39
14. Diagram Alur Penelitian	43
15. Diagram Alur Penelitian	45
16. Hasil <i>Splitting Data</i>	46
17. Tampilan Sebelum dan Sesudah <i>Resize</i>	47
18. Sampel Data Augmentasi	48
19. Perbandingan Data Sebelum dan Sesudah Augmentasi	49
20. Sampel Nilai Intensitas Piksel	51
21. Hasil Normalisasi dengan <i>ImageNet</i>	53
22. <i>Confusion Matrix</i> Tanpa Teknik <i>Balancing Data</i>	55
23. Grafik ROC-AUC Tanpa <i>Balancing</i>	65
24. Grafik <i>Accuracy-Loss</i> Tanpa <i>Balancing</i>	66

25. <i>Confusion Matrix</i> Menggunakan Teknik <i>Balancing</i> (Augmentasi)	67
26. Grafik ROC-AUC Menggunakan <i>Balancing Data</i> (Teknik Augmentasi) .	76
27. Grafik <i>Accuracy-Loss</i> Menggunakan <i>Balancing Data</i> (Teknik Augmentasi)	77
28. <i>Confusion Matrix</i> dengan Teknik <i>Balancing (Class Weight)</i>	79
29. Grafik ROC-AUC menggunakan Teknik <i>Balancing (Class weight)</i>	88
30. Grafik <i>Accuracy-Loss</i> menggunakan Teknik <i>Balancing (Class weight)</i> . .	89
31. <i>Confusion Matrix</i> dengan Teknik <i>Balancing</i> (Augmentasi + <i>Class Weight</i>)	91
32. Grafik ROC-AUC Menggunakan Teknik <i>Balancing</i> Augmentasi + <i>Class Weight</i>	100
33. Grafik ROC-AUC Menggunakan Teknik <i>Balancing</i> Augmentasi + <i>Class Weight</i>	102

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Kulit merupakan organ terbesar pada tubuh manusia yang memiliki fungsi penting dalam melindungi tubuh dari berbagai faktor eksternal seperti mikroorganisme, sinar *ultraviolet* (UV), serta bahan kimia berbahaya (Jin dkk., 2022). Selain berfungsi secara fisiologis, kulit juga memiliki nilai estetika yang tinggi karena menjadi bagian utama dalam penampilan seseorang (Costeris dkk., 2021). Oleh karena itu, perawatan kulit tidak hanya berkaitan dengan kecantikan dan kepercayaan diri, tetapi juga dengan kesehatan.

Badan Pengawas Obat dan Makanan (BPOM) Republik Indonesia (BPOM, 2025), mencatat bahwa pada periode pengawasan 10-18 Februari 2025 ditemukan sebanyak 205.133 produk kosmetik ilegal (4.334 varian) dengan nilai ekonomi mencapai Rp31,7 miliar, di mana 79,9% kosmetik tanpa izin edar, 17,4% mengandung bahan dilarang/berbahaya, termasuk skincare beretiket biru tidak sesuai ketentuan, 2,6% kosmetik kedaluwarsa, dan 0,1% merupakan kosmetik injeksi. BPOM juga melaporkan bahwa sebagian produk ilegal tersebut mengandung bahan kimia berbahaya seperti merkuri dan hidrokuinon, yang dapat menyebabkan perubahan warna kulit (*ochronosis*) atau munculnya lesi kulit, hiperpigmentasi, iritasi, gangguan ginjal serta meningkatkan risiko kanker kulit akibat pemakaian jangka panjang. Efek ini terjadi karena hidrokuinon bekerja menghambat pembentukan pigmen melanin dan menghasilkan senyawa beracun yang dapat merusak sel dan *Deoxyribonucleic Acid* (DNA) kulit (Bamidele dkk., 2023).

Selain akibat penggunaan produk berbahaya, paparan sinar UV juga menjadi salah satu penyebab utama gangguan kulit (Nafiah dkk., 2023). Baik anak-anak

maupun orang dewasa berisiko mengalami masalah kulit akibat paparan sinar UV berlebihan tanpa perlindungan. Demikian juga, tingkat kesadaran masyarakat terhadap pentingnya perlindungan kulit medis masih rendah (Nafiah dkk., 2023). Faktor-faktor tersebut lah yang dapat memicu timbulnya permasalahan kulit yang bersifat ringan hingga berat, mulai dari lesi jinak hingga kanker kulit. Lesi kulit sendiri merupakan perubahan abnormal pada warna, bentuk, atau tekstur kulit yang dapat disebabkan oleh beragam faktor, termasuk paparan sinar UV berlebihan, penggunaan bahan kimia tertentu, maupun kelainan genetik (Shetty dkk., 2022; Patel & Nixon, 2022). Terdapat jenis-jenis lesi kulit antara lain *actinic keratoses*, *basal cell carcinoma*, *benign keratosis*, *dermatofibroma*, *melanoma*, *melanocytic nevi*, dan *vascular lesions* (Septhya dkk., 2024).

Berdasarkan penelitian Wang dkk. (2024), secara global tercatat 331.722 kasus baru kanker kulit *melanoma* dengan 58.667 kematian, serta 1.234.533 kasus kanker kulit *non-melanoma* dengan 69.416 kematian. Kondisi serupa juga terjadi di Indonesia, berdasarkan *Global Cancer Observatory* (IARC, 2024), mencatat sebanyak 1.716 kasus baru *melanoma* dengan 774 kematian, serta 7.841 kasus baru kanker kulit *non-melanoma* dengan 2.451 kematian. Jumlah tersebut memang lebih kecil dibandingkan jenis kanker lain seperti kanker payudara, yang mencapai 66.271 kasus baru dan 22.598 kematian. Meskipun demikian, angka kejadian kanker kulit tetap memerlukan perhatian serius, mengingat dampaknya yang signifikan terhadap kesehatan masyarakat apabila tidak dideteksi dan ditangani sejak dini.

Diagnosis penyakit kulit umumnya dilakukan melalui pemeriksaan visual oleh tenaga ahli dermatologi menggunakan alat seperti dermatoskop (Harrison, 2024). Namun, metode ini membutuhkan waktu yang cukup lama, biaya tinggi, dan bergantung pada tingkat keahlian dokter (Lu dkk., 2023). Oleh karena itu, diperlukan sistem pendukung keputusan berbasis teknologi yang mampu membantu proses klasifikasi atau diagnosis lesi kulit secara cepat dan akurat.

Salah satu pendekatan yang banyak digunakan dalam bidang *computer vision* adalah penerapan model klasifikasi citra berbasis *Convolutional Neural Network* (CNN) menggunakan metode *transfer learning* *VGG16*, *ResNet50*, *MobileNetV2*, dan *InceptionV3* (Agus dkk., 2025). Misalnya, penelitian oleh Septhya dkk. (2024) yang mengklasifikasikan 9 jenis lesi kulit menggunakan model *VGG16* dan *DenseNet121* dengan memperoleh *accuracy* sebesar 73% dan 78% masing-masing. Penelitian lain oleh Dimililer & Sekeroglu (2023), mengklasifikasikan lesi kulit dengan

membandingkan 2 kelas dan 6 kelas menggunakan *pretained* CNN dan *transfer learning* tanpa melakukan augmentasi, menghasilkan rata-rata *accuracy* sebesar 68% (*binary-CNN*), 86% (*binary-transfer learning*), 67% (*multi-CNN*) dan 86% (*multi-transfer learning*). Hasil tersebut menunjukkan bahwa meskipun model CNN *transfer learning* mampu melakukan klasifikasi, tingkat *accuracy* cenderung menurun seiring dengan meningkatnya jumlah kelas (*multi-class*).

Sebagai alternatif, model berbasis *transformer* mulai dikembangkan untuk pengenalan citra, salah satunya adalah *Swin Transformer*. *Swin Transformer* merupakan arsitektur *vision transformer* yang menggunakan mekanisme jendela (*shifted windows*) untuk mengekstraksi fitur secara hierarkis dan efisien (Prastyo dkk., 2025). *Swin Transformer* dirancang untuk mempelajari citra secara bertingkat, di mana model mampu mengidentifikasi detail-detail kecil pada area tertentu sekaligus memahami hubungan antarbagian dalam gambar (Liu dkk., 2021). Pendekatan ini memungkinkan *Swin Transformer* untuk menangkap informasi lokal dan keseluruhan citra secara efektif, sehingga meningkatkan akurasi pada berbagai tugas klasifikasi. Penelitian oleh Ranjeet dkk. (2024), menunjukkan bahwa penggunaan *Swin Transformer* untuk klasifikasi lesi kulit menghasilkan *accuracy* yang lebih tinggi dibandingkan model CNN (*ResNet-50*) dengan masing-masing *accuracy* sebesar 87% dan 82%

Meskipun demikian, tantangan lain muncul dalam penggunaan model *Swin Transformer*, yaitu *balancing data* (Pacal dkk., 2024). Jumlah citra pada setiap kelas lesi kulit sering kali *inbalance*, yang dapat menyebabkan model bias terhadap kelas mayoritas. Beberapa penelitian mencoba mengatasi hal ini menggunakan teknik augmentasi data, namun pendekatan ini berisiko menyebabkan *overfitting* jika data minoritas terlalu sering direplikasi (Tang dkk., 2024). Salah satu solusi yang dapat diterapkan adalah penggunaan *class weight*, yaitu metode pemberian bobot pada kelas minoritas agar model tidak bias dalam proses pelatihan (Nguyen dkk., 2022).

Penelitian ini berfokus pada *balancing data* dengan 2 metode yaitu augmentasi dan *class weight* dalam model *Swin Transformer* untuk *balancing data* pada klasifikasi citra lesi kulit. Hasil penelitian diharapkan dapat menjadi rekomendasi dalam membantu tenaga medis melakukan diagnosis awal, serta memberikan kontribusi ilmiah dalam penerapan teknik *deep learning* pada bidang kesehatan kulit.

1.2 Rumusan Masalah

Berdasarkan pemaparan latar belakang tersebut, adapun rumusan masalah dalam penelitian ini diantaranya:

1. Menganalisis klasifikasi lesi kulit dengan lebih dari 2 kelas atau multi-kelas.
2. Menganalisis performa model *Transformer* dalam klasifikasi lesi kulit untuk membantu tenaga medis membuat keputusan diagnosis.
3. Menilai pengaruh penambahan data hasil augmentasi gambar dan teknik *class weight* serta kombinasi antara augmentasi dan *class weight* dalam mengklasifikasikan jenis lesi kulit.

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Melakukan klasifikasi multi-kelas (7 jenis lesi kulit) menggunakan data HAM 10000.
2. Menerapkan model *Swin Transformer* sebagai model klasifikasi untuk meningkatkan *accuracy* diagnosis lesi kulit.
3. Perbandingan teknik augmentasi, *class weight* dan kombinasi antara augmentasi + *class weight* dalam *balancing data* untuk mengevaluasi pengaruh (*imbalanced data*) terhadap performa model.

1.4 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan hasil klasifikasi yang akurat untuk mendeteksi 7 jenis lesi kulit, sehingga dapat menjadi rekomendasi tenaga medis dan pengembang sistem dalam mendiagnosis lesi kulit.

2. Menunjukkan efektivitas model *Swin Transformer* dalam mengklasifikasi lesi kulit, sekaligus menjadi referensi bagi pengembangan model berbasis *transformer* pada bidang medis.
3. Mengevaluasi teknik *balancing data* antara augmentasi, *class weight* dan kombinasi augmentasi + *class weight* yang tepat dalam mengklasifikasi lesi kulit mengenai pengaruh *inbalance data* terhadap performa model.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian yang dilakukan menggunakan beberapa penelitian terdahulu yang digunakan sebagai referensi. Penelitian tersebut berguna untuk mendukung penelitian ini dan mencari gap sebagai kebaharuan penelitian ini. Tabel 1. menunjukkan penelitian terdahulu.

Tabel 1. Penelitian Terkait

No.	Judul Penelitian	Metode	Hasil
1.	<i>Skin Lesion Classification Using CNN-based Transfer Learning Model</i> (Dimililer & Sekeroglu, 2023).	Klasifikasi lesi kulit dengan membandingkan <i>binary</i> (2 kelas) dan <i>multi-class</i> (6 kelas) tanpa melakukan <i>pre-processing</i> dan augmentasi.	• <i>Accuracy</i>: 68% (<i>binary-CNN</i>), 86% (<i>binary-transfer learning</i>). • <i>Specificity</i>: 66% (<i>binary-CNN</i>), 88% (<i>binary-transfer learning</i>). • <i>Precision (multi-class)</i>: 70% (<i>multi-CNN</i>), 90% (<i>multi-transfer learning</i>). • <i>Recall</i>: 70% (<i>binary-CNN</i>), 81% (<i>binary-transfer learning</i>); 64% (<i>multi-CNN</i>), 83% (<i>multi-transfer learning</i>). • <i>F1-Score (multi-class)</i>: 67% (<i>multi-CNN</i>), 86% (<i>multi-transfer learning</i>).

No.	Judul Penelitian	Metode	Hasil
2.	<i>Skin Cancer Classification Using Fine-Tuned Transfer Learning of DenseNet-121</i> (Bello dkk., 2024).	Implementasi augmentasi pada CNN, Support Vector Machine, Random Forest, serta beberapa arsitektur <i>deep learning</i> .	• <i>Accuracy</i>: CNN 82%, SVM 83%, RFC 81%, EfficientNetB0 84%, ResNet-34 82%, VGG16 85%, Inception_v3 81%, DenseNet-121 87%. • <i>Precision</i>: CNN 80%, SVM 83%, RFC 81%, EfficientNetB0 84%, ResNet-34 81%, VGG16 85%, Inception_v3 81%, DenseNet-121 87%. • <i>Recall</i>: CNN 81%, SVM 83%, RFC 82%, EfficientNetB0 84%, ResNet-34 81%, VGG16 85%, Inception_v3 80%, DenseNet-121 86%. • <i>F1-Score</i>: CNN 78%, SVM 81%, RFC 79%, EfficientNetB0 83%, ResNet-34 79%, VGG16 84%, Inception_v3 77%, DenseNet-121 84%.
3.	<i>Skin Cancer Detection using Swin Transformer Model</i> (Ranjeet dkk., 2024).	Perbandingan model CNN (<i>ResNet-50</i>) dan <i>Swin Transformer</i> .	• <i>Accuracy</i>: ResNet-50 82%, Swin Transformer 87%. • <i>Precision</i>: ResNet-50 84%, Swin Transformer 88%. • <i>Recall</i>: ResNet-50 81%, Swin Transformer 86%. • <i>F1-Score</i>: ResNet-50 82%, Swin Transformer 87%.
4.	<i>Deep Ensemble Learning for Multiclass Skin Lesion Classification</i> (Chiu dkk., 2025).	Perbandingan antara model <i>Transfer Learning</i> , <i>Vision Transformer (ViT)</i> , dan <i>Swin Transformer</i> untuk klasifikasi lesi kulit multi-kelas.	• <i>Accuracy EfficientNetB4</i>: 81,6%. • <i>Accuracy ViT</i>: 84%. • <i>Accuracy Swin Transformer</i>: 84,9%.

No.	Judul Penelitian	Metode	Hasil
5.	<i>Skin Lesion Classification on Imbalanced Data Using Deep Learning with Soft Attention</i> (Nguyen dkk., 2022).	Perbandingan model menggunakan augmentasi dan kombinasi augmentasi + <i>class weight</i> .	• Augmentasi: InceptionResNetV2 79%, DenseNet201 84%, ResNet50 76%, ResNet152 81%, NasNetLarge 56%, MobileNetV2 83%, MobileNetV3Small 83%, MobileNetV3Large 85%, NasNetMobile 84%. • Augmentasi + <i>class weight</i>: InceptionResNetV2 90%, DenseNet201 89%, ResNet50 70%, ResNet152 57%, NasNetLarge 84%, MobileNetV2 81%, MobileNetV3Small 78%, MobileNetV3Large 86%, NasNetMobile 86%.

Penjelasan dari penelitian pada Tabel 1. sebagai berikut:

1. Penelitian Pertama (Dimililer & Sekeroglu, 2023)

Penelitian ini membahas terkait klasifikasi lesi kulit menggunakan CNN dan *transfer learning*. Dataset yang digunakan adalah PAD-UFES-20 dari *Federal University of Esp rito Santo* (UFES), Brasil. Dataset ini dirilis untuk mendukung penelitian *Computer-Aided Diagnosis* (CAD) berbasis gambar kulit dari smartphone, bukan dermatoskop, sehingga cocok untuk penerapan di daerah dengan keterbatasan alat medis sebanyak 5.312 gambar yang terbagi menjadi 6 kelas yaitu *actinic keratosis* - penyakit kulit, *nevus* - penyakit kulit jinak, *seborrheic keratosis* - penyakit kulit, *basal cell carcinoma* - kanker kulit, *melanoma* - kanker kulit dan *squamous cell carcinoma* - kanker kulit.

Penelitian ini menggunakan 2 skema penelitian yaitu *binary* dan *multi-class* tapi tidak melakukan *pre-processing* dan augmentasi guna melihat kemampuan *Transfer Learning* (TL). Hasilnya untuk *binary* rata-rata *accuracy* 68% (*binary-CNN*) dan 86% (*binary-TL*). Sedangkan untuk *multi-class* nilai *f1-score* sebesar 67% (*multi-CNN*) dan 86% (*multi-TL*). Hasil tersebut menunjukkan bahwa penggunaan TL lebih unggul dibanding CNN biasa.

Namun, hal yang perlu disoroti juga adalah ketidakkonsistenan data jika tidak di augmentasi dapat menyebabkan performa yang kurang baik.

2. Penelitian Kedua (Bello dkk., 2024)

Penelitian ini dilakukan oleh Bello dkk. (2024), yang melakukan klasifikasi lesi kulit ke dalam 2 kelas *benign* dan *malignant*. Dataset yang digunakan dalam studi ini merupakan gabungan dari dua subset: *Human Against Machine* (HAM10000) dan *International Skin Imaging Collaboration* (ISIC 2020), keduanya diperoleh dari *Kaggle*. Total data yang dipakai sebanyak 3297 gambar yang terbagi menjadi 2 kelas 1.800 *benign* dan 1.497 *malignant*. Lalu, data tersebut di bagi menjadi data *training*, *validation* dan *testing*. *Benign* (*training* 1534, *testing* 186 dan *validation* 80) dan *malignant* (*training* 1284, *testing* 144 dan *validation* 69).

Selanjutnya diterapkan teknik augmentasi karena data tidak seimbang pada data *training*. Augmentasi yang dipakai meliputi rotasi 90 derajat, pergeseran horizontal dan vertikal sejauh 15%, pemutaran gambar secara horizontal dan vertical, dan mengatur kecerahan dari 0,8 hingga 1,1, sehingga data menjadi *benign* 3.086 dan *malignant* sebanyak 2.568 gambar. Model yang digunakan adalah CNN, SVM, *Random Forest Classifier*, *EfficientNetB0*, *ResNet-34*, *VGG16*, *Inception_v3*, dan *DenseNet121*. Hasilnya, model *DenseNet121* lebih unggul dibanding dengan model lain dengan *accuracy* sebesar 87%.

3. Penelitian Ketiga (Ranjeet dkk., 2024)

Penelitian ini memanfaatkan model *transformer* yaitu *Swin Transformer* yang dibandingkan dengan CNN TL (*ResNet-50*) untuk mengklasifikasi lesi kulit. Data yang dipakai adalah HAM10000, data tersebut di normalisasi menggunakan ke rentang standar (biasanya 0 dan 1 atau -1 dan 1). Selanjutnya dilakukan augmentasi menggunakan 4 teknik yaitu *shear*, *zoom in*, *reflection* dan *rotation*. Hasil dari penelitian ini adalah *Swin Transformer* lebih unggul dibanding *ResNet-50* dengan masing-masing akurasi sebesar 87% dan 82%. Keunggulan ini disebabkan model *Swin Transformer* dapat menangkap gambar dengan bantuan *patch* yang kecil sehingga dapat menangkap gambar secara jelas.

4. Penelitian Keempat (Chiu dkk., 2025).

Penelitian ini berfokus pada perbandingan model untuk mengklasifikasikan jenis lesi kulit menggunakan 18 model *transfer learning*, 4 varian VIT dan 3

varian *Swin Transformer*. Data yang digunakan adalah gambar dermoskopik pada *Chung Shan Medical University Hospital* (CSMUH) sebanyak 666 data yang terbagi menjadi 7 kelas yaitu *malignant melanoma*, *melanocytic nevus*, *basal cell carcinoma*, *actinic keratosis*, *benign keratosis*, *dermatofibroma* dan *vascular*.

Hasil menunjukkan bahwa untuk *transfer learning* model yang lebih unggul adalah *EfficientNetB4* dengan *accuracy* sebesar 81,6%, VIT (L32) 84% dan *Swin Transformer (Swin Large)* sebesar 84,9%. Secara keseluruhan model *Swin Transformer* lebih baik dibanding dengan model yang lain.

5. Penelitian Kelima (Nguyen dkk., 2022)

Penelitian ini berfokus pada penanganan data yang *inbalance*, dengan membandingkan data yang di augmentasi dengan augmentasi + *class weight*. Data yang digunakan adalah data HAM10000 dengan total keseluruhan sebanyak 10.015 yang terbagi menjadi 7 kelas.

Evaluasi yang dilakukan menggunakan bermacam model TL yaitu *InceptionResNetV2*, *DenseNet201*, *ResNet50*, *ResNet152*, *NasNetLarge*, *MobileNetV2*, *MobileNetV3Small*, *MobileNetV3Large*, dan *NasNetMobile*. Hasilnya rata-rata *accuracy* lebih tinggi dengan mengombinasikan antara teknik augmentasi dengan *class weight*. Model dengan *accuracy* tertinggi adalah *InceptionResNetV2* dengan *accuracy* 79% dengan augmentasi dan 90% hasil kombinasi augmentasi + *class weight*.

2.2 Lesi Kulit

Menurut Piatek (2023), lesi kulit merupakan perubahan abnormal pada jaringan kulit yang berbeda dari kulit normal di sekitarnya, baik dalam hal warna, tekstur, maupun struktur anatomis. Lesi kulit dapat bersifat primer, yaitu muncul langsung pada kulit yang sebelumnya normal, atau sekunder yang berkembang dari lesi primer atau akibat manipulasi terhadap lesi primer tersebut. Lesi kulit merupakan manifestasi dari berbagai kondisi dermatologis yang sangat beragam, mulai dari yang bersifat *benign* hingga *malignant*, dan dapat disebabkan oleh faktor genetik, lingkungan, infeksi, maupun proses degeneratif sel (Brutti dkk., 2023). Secara

praktik klinis, pemahaman mendalam tentang karakteristik lesi kulit sangat penting untuk menentukan diagnosis yang tepat dan strategi penatalaksanaan yang sesuai. Klasifikasi lesi kulit tidak hanya membantu dalam identifikasi penyakit kulit, tetapi juga dalam menentukan prognosis dan potensi keganasan suatu lesi.

Penyebab lesi kulit terjadi karena paparan bahan kimia berbahaya yang terkandung dalam beberapa produk perawatan kulit, seperti hidrokuinon, merkuri, dan arsenik. Penggunaan bahan-bahan tersebut, terutama dalam produk pemutih kulit, dapat menimbulkan iritasi, gangguan pigmentasi, hingga perubahan ganas pada jaringan kulit. Kandungan zat berbahaya ini sering kali melebihi batas aman dan terbukti berisiko menyebabkan lesi kulit pada pengguna (Bamidele dkk., 2023).


Lesi kulit juga disebabkan oleh paparan sinar UV merupakan faktor risiko utama bagi berbagai jenis lesi kulit, baik jinak maupun ganas. Radiasi UV dapat merusak DNA pada sel kulit, dan jika proses perbaikannya gagal, kerusakan tersebut dapat berkembang menjadi mutasi dan memicu perubahan ganas. Paparan sinar UV yang kuat dalam waktu singkat namun terjadi sesekali, seperti saat seseorang berjemur atau terbakar matahari dapat meningkatkan risiko *melanoma*. Sementara itu, paparan sinar UV yang berlangsung terus-menerus dalam jangka panjang lebih sering menyebabkan *actinic keratoses* dan *basal cell carcinoma* (Soares dkk., 2023).

Penyebab lain adalah faktor genetik atau pewarisan dalam keluarga. Beberapa orang memiliki kecenderungan genetik yang membuat mereka lebih mudah mengalami pertumbuhan sel kulit tidak normal, seperti munculnya tanda lahir atau benjolan yang bersifat jinak seperti *melanocytic nevi/nevus* maupun berpotensi ganas seperti melanoma (Azimi & Fernandez-Peñas, 2023). Agar penjelasan lesi kulit lebih jelas, beberapa macam lesi kulit sebagai berikut:

1. *Actinic Keratoses* (AKIEC)

Actinic keratoses (AKIEC) merupakan lesi prakanker (kondisi sebelum kanker) yang ditandai dengan *displasia keratinosit* (pertumbuhan abnormal sel-sel kulit) pada epidermis (lapisan terluar kulit) akibat akumulasi kerusakan *Deoxyribonucleic Acid* (DNA) yang diinduksi radiasi UV (Balcere dkk., 2022). Secara klinis, AKIEC tampak sebagai bercak atau benjolan kecil berwarna kemerahan berdiameter 3-10 mm dengan permukaan kasar dan bersisik, umumnya muncul pada area yang sering terpapar sinar UV seperti wajah, kulit kepala, lengan, dan punggung tangan (Abreu-Velez dkk., 2018).

Jika dilihat di bawah mikroskop, tampak pertumbuhan sel-sel kulit yang tidak normal dengan inti sel yang berbeda-beda ukurannya dan berwarna lebih gelap pada lapisan dasar kulit. Gambar AKIEC dapat dilihat pada Gambar 1.




Gambar 1. Lesi Kulit AKIEC

2. *Basal Cell Carcinoma (BCC)*

Basal Cell Carcinoma (BCC) adalah kanker kulit yang paling sering ditemukan, berasal dari sel-sel di lapisan paling bawah kulit (lapisan basal epidermis) atau kantung akar rambut (Chmiel dkk., 2022). BCC merupakan bentuk kanker kulit paling umum, dengan berbagai variasi tampilan klinis mulai dari yang tumbuh lambat hingga yang sangat agresif. Jika dilihat di bawah mikroskop, tampak sel-sel kecil berwarna gelap dengan inti sel yang besar, tersusun rapi di tepi seperti pagar. Tampilan di kulit bervariasi: tipe *nodular* (benjolan mengkilap dengan pembuluh darah kecil terlihat), *superfisial* (bercak datar), *morfea* (plak keras seperti bekas luka), hingga tipe berpigmen (berwarna coklat/hitam) (Vallini dkk., 2023).

Penyebab utama BCC adalah kerusakan pada gen, yaitu bagian kecil dari DNA yang berfungsi seperti “petunjuk” untuk mengatur bagaimana sel tubuh tumbuh dan bekerja. Paparan sinar UV dalam waktu lama dapat menyebabkan mutasi gen-gen ini sehingga sel kulit tumbuh tidak terkendali (Gambini dkk., 2022). Salah satu jalur pengatur pertumbuhan sel yang paling sering terganggu disebut *Hedgehog signaling pathway*, yakni jalur yang membantu mengatur kapan sel harus tumbuh atau berhenti. Dua gen penting dalam jalur ini adalah *PTCH1 (Patched-1)* dan *SMO (Smoothed)*; ketika gen-gen ini mengalami mutasi, pengendalian pertumbuhan sel menjadi kacau dan dapat memicu terbentuknya kanker kulit (Miller dkk., 2023). BCC dapat dilihat pada Gambar 2.




Gambar 2. Lesi Kulit BCC

3. *Benign Keratosis* (BKL)

Menurut Belmorida dkk. (2021), *Benign Keratosis* (BKL) merupakan tumor jinak, yaitu pertumbuhan sel yang tidak berbahaya dan tidak menyebar ke bagian tubuh, kondisi ini sering ditemukan pada orang tua hampir semua orang berusia di atas 50 tahun memilikinya. Secara tampilan, BKL biasanya muncul sebagai plak atau benjolan berwarna coklat sampai hitam dengan permukaan kasar atau sedikit menonjol, tampak seperti “ditempelkan” di kulit. Ukurannya bisa bervariasi, mulai dari beberapa milimeter hingga beberapa sentimeter.

Penyebab BKL melibatkan mutasi aktivasi pada gen *FGFR3* (*Fibroblast Growth Factor Receptor 3*) dan *PIK3CA* (*Phosphatidylinositol-4,5-Bisphosphate 3-Kinase, Catalytic Subunit Alpha*) yang berperan dalam regulasi pertumbuhan dan pembelahan sel kulit (Lahbacha dkk., 2024). Selain itu, paparan sinar UV dan faktor usia lanjut diyakini sebagai pendorong terbentuknya mutasi-genetik ini. Meskipun demikian, BKL sepenuhnya jinak dan tidak berubah menjadi kanker, namun karena penampilannya kadang mirip dengan *melanoma*, pemeriksaan oleh dokter tetap dianjurkan, sementara pengobatan umumnya tidak diperlukan kecuali untuk alasan estetika atau jika lesi menimbulkan keluhan seperti gatal atau tersangkut pakaian, dengan pilihan terapi berupa krioterapi (pembekuan dengan nitrogen cair), kuretase (pengikisan), atau terapi laser bila diputuskan untuk dihilangkan (Muddebihal dkk., 2024). Tampilan BKL seperti pada Gambar 3.




Gambar 3. Lesi Kulit BKL

4. *Dermatofibroma* (DF)

Dermatofibroma atau *histiocytoma fibrosum* (DF) adalah benjolan jinak di lapisan dalam kulit yang terbentuk dari sel-sel jaringan ikat dan sel-sel peradangan (Pablo dkk., 2025). Lesi ini biasanya muncul di kaki atau lengan dan lebih sering ditemukan pada wanita; tampak sebagai benjolan keras di bawah kulit berukuran sekitar < 2 cm dengan warna coklat kemerahan, dan sering menunjukkan tanda khas berupa benjolan yang “cekung ke dalam” (*dimple sign*) saat kulit di sekitarnya dicubit (He & Wen, 2024).

Penyebab DF diduga merupakan reaksi kulit terhadap trauma kecil, gigitan serangga, atau peradangan kantung rambut, meskipun beberapa kasus muncul tanpa penyebab jelas (Pablo dkk., 2025). DF umumnya tidak menimbulkan gejala, namun kadang dapat terasa nyeri, nyeri tekan saat ditekan, atau gatal (Myers & Fillman, 2024). Diagnosis pasti memerlukan pemeriksaan jaringan di bawah mikroskop, dengan karakteristik pertumbuhan sel-sel berbentuk seperti gelendong di lapisan dermis. Pengobatan umumnya tidak diperlukan kecuali benjolan menimbulkan keluhan atau tampilan atipikal, dengan pengangkatan melalui operasi kecil sebagai pilihan (He & Wen, 2024). Tampilan DF seperti pada Gambar 4.



Gambar 4. Lesi Kulit DF

5. *Melanoma* (MEL)


Melanoma (MEL) merupakan adalah jenis kanker kulit ganas yang berasal dari sel melanosit, yaitu sel yang berfungsi menghasilkan pigmen atau warna kulit (Lopes dkk., 2022). Ketika sel-sel ini mengalami perubahan dan tumbuh tidak terkendali, terbentuklah MEL. Penyakit ini merupakan bentuk kanker kulit yang paling berbahaya dan mematikan, karena dapat tumbuh dengan cepat dan menyebar ke organ lain di tubuh dan kasus MEL terus meningkat di seluruh dunia (Liu dkk., 2021). Menurut Waseh & Lee (2023), secara tampilan, MEL sering terlihat seperti tahi lalat yang tampak tidak normal, dengan ciri-ciri yang dikenal sebagai aturan ABCDE, yaitu:

- A (*Asymmetry*): bentuknya tidak simetris,
- B (*Border*): tepinya tidak beraturan atau bergerigi,
- C (*Color*): warnanya tidak merata (campuran coklat, hitam, atau kemerahan),
- D (*Diameter*): ukurannya lebih besar dari 6 mm,
- E (*Evolving*): mengalami perubahan bentuk, ukuran, atau warna dari waktu ke waktu.

Penyebab utama MEL adalah paparan sinar UV dari matahari atau sumber buatan seperti *tanning bed*, yang dapat merusak DNA pada sel kulit. Kerusakan ini sering melibatkan mutasi genetik pada gen BRAF (*v-Raf murine sarcoma viral oncogene homolog B1*) dan NRAS (*neuroblastoma RAS viral oncogene homolog*), yang berperan penting dalam mengatur pertumbuhan dan pembelahan sel (Pino dkk., 2023). Ketika gen-gen ini mengalami kerusakan (mutasi), sel kulit kehilangan kendali pertumbuhan dan mulai berkembang tanpa batas.

MEL memiliki kemampuan tinggi untuk menyebar ke kelenjar getah bening dan organ penting seperti paru-paru atau hati jika tidak ditangani sejak dini (Muto dkk., 2025). Pengobatan utama untuk tahap awal adalah operasi pengangkatan dengan batas sayatan yang cukup lebar untuk memastikan seluruh sel abnormal terangkat. Untuk kasus lanjut, terapi dapat mencakup terapi target, yaitu obat yang dirancang untuk menghambat gen yang bermutasi seperti penghambat BRAF (Trojaniello dkk., 2023). Terdapat juga imunoterapi, yaitu obat yang membantu sistem kekebalan tubuh mengenali dan menghancurkan sel kanker. Dua jenis imunoterapi yang umum digunakan

adalah anti-PD-1 (*Programmed Cell Death Protein 1*) dan *anti-CTLA-4* (*Cytotoxic T-Lymphocyte-Associated Protein 4*) (Muto dkk., 2025). MEL dapat dilihat pada Gambar 5.




Gambar 5. Lesi Kulit MEL

6. *Melanocytic Nevi* (NV)

Melanocytic Nevi (NV) atau yang lebih dikenal sebagai tahi lalat merupakan pertumbuhan jinak dari sel-sel penghasil pigmen kulit (melanosit) (Kaya dkk., 2025). Secara tampilan, NV terlihat sebagai bercak datar atau benjolan kecil berpigmen coklat hingga hitam yang merata dan simetris (seimbang kiri-kanan), dengan ukuran umumnya kurang dari 6 mm. NV dapat hadir sejak lahir (kongenital) atau muncul kemudian (*acquired*/didapat), dengan sebagian besar tahi lalat didapat muncul pada usia anak-anak hingga remaja (Shreberk-Hassidim dkk., 2023).


Menurut Shreberk-Hassidim dkk. (2023), pembentukan NV melibatkan mutasi pada gen seperti BRAF dan NRAS yang cukup untuk memicu pembentukan tahi lalat, namun tidak cukup kuat untuk menyebabkan MEL. Perubahan NV menjadi kanker melanoma terjadi pada kurang dari 1% kasus. NV merupakan lesi jinak (bukan kanker), namun memiliki banyak tahi lalat (lebih dari 50) merupakan faktor risiko independen untuk berkembangnya MEL di kemudian hari. Pemantauan secara rutin dan pemeriksaan dengan dermoskopi (alat pembesar khusus kulit) direkomendasikan untuk NV yang tampak tidak biasa atau menunjukkan perubahan (Russo dkk., 2022). NV di ditampilkan pada Gambar 6.



Gambar 6. Lesi Kulit NV

7. *Vascular Lesions (VASC)*

Vascular Lesions (VASC) atau kelainan pembuluh darah pada kulit adalah kondisi di mana muncul lesi atau tanda di kulit yang berasal dari pembuluh darah yang bisa berupa benjolan, bercak merah, atau bercak kebiruan, dan biasanya jinak (tidak bersifat kanker) (Castillo-Rangel dkk., 2022). Penyebabnya bermacam-macam, termasuk kelainan pembuluh darah bawaan (*malformasi*), pertumbuhan sel pembuluh darah yang berlebihan (*hemangioma*), atau faktor lingkungan/trauma ringan (Fernandez-Flores dkk., 2023). VASC bersifat jinak dan biasanya tidak berbahaya, tetapi jika menimbulkan keluhan atau mengganggu penampilan, pemeriksaan oleh dokter disarankan (Choi & Oakley, 2021). VASC di tampilkan pada Gambar 7.



Gambar 7. Lesi Kulit DF

2.3 Citra Digital

Citra merupakan representasi visual dari suatu objek, pemandangan, atau fenomena yang dapat ditangkap dan direproduksi (Andika & Darwis, 2021). Contoh dalam kehidupan sehari-hari, dapat berupa foto, lukisan, gambar hasil scan, atau tampilan visual lainnya. Citra berfungsi sebagai media untuk menyampaikan informasi visual yang mengandung data tentang warna, bentuk, tekstur, dan karakteristik visual

lainnya dari objek yang direpresentasikan. Menurut Sarfraz (2020), citra dapat dikategorikan menjadi dua jenis yaitu:

1. Citra Analog (*Kontinu*): Citra yang memiliki nilai intensitas kontinu dalam domain spasial dan amplitudo. Contohnya adalah foto yang tercetak pada kertas, lukisan, atau gambar pada film fotografi. Pada citra analog, informasi visual bersifat kontinu tanpa adanya diskretisasi atau pembagian menjadi elemen-elemen terpisah.
2. Citra Digital (*Diskrit*): Citra yang telah mengalami proses digitalisasi, dimana informasi visual direpresentasikan dalam bentuk numerik diskrit. Citra digital terdiri dari elemen-elemen terkecil yang terpisah dan dapat diproses oleh komputer.

Menurut Annisa (2025), citra digital terbagi menjadi 3, yaitu:

1. Citra *biner*, yaitu jenis citra digital paling sederhana yang hanya memiliki dua nilai intensitas, yaitu 0 (hitam) dan 1 (putih). Citra biner biasanya dihasilkan dari proses thresholding pada citra grayscale dan sering digunakan untuk aplikasi pengenalan pola, pemrosesan dokumen, dan segmentasi objek sederhana.
2. Citra *grayscale*, yaitu citra yang memiliki gradasi tingkat keabuan dari hitam hingga putih. Citra jenis ini umumnya menggunakan 8 bit per piksel, sehingga memiliki $2^8 = 256$ tingkat keabuan dengan rentang nilai 0-255, dimana 0 menyatakan hitam (intensitas minimum), 255 menyatakan putih (intensitas maksimum) dan 1 – 254 menyatakan berbagai tingkat keabuan.
3. Citra berwarna RGB, citra ini menggunakan model warna aditif yang terdiri dari tiga kanal warna dasar: *Red* (Merah), *Green* (Hijau), dan *Blue* (Biru). Setiap kanal biasanya menggunakan 8 bit, sehingga total 24 bit per piksel (*True Color*), yang mampu merepresentasikan $2^{24} = 16.777.216$ kombinasi warna. Citra RGB dapat direpresentasikan sebagai tiga matriks terpisah atau sebagai tensor tiga dimensi:

$$I_{RGB}(x, y) = [R(x, y), G(x, y), B(x, y)] \quad (1)$$

dengan:

$$R(x, y) \in [0, 255], \quad \text{untuk kanal merah}$$

$$G(x, y) \in [0, 255], \quad \text{untuk kanal hijau}$$

$$B(x, y) \in [0, 255], \quad \text{untuk kanal biru}$$

2.4 Klasifikasi

Klasifikasi merupakan proses pengelompokan data ke dalam kategori tertentu berdasarkan fitur atau karakteristiknya (Prasetya dkk., 2025). Pada konteks *machine learning* dan *computer vision*, klasifikasi bertujuan memprediksi label dari suatu input dengan mempelajari pola pada data berlabel (*training data*) untuk kemudian mengenali dan memberi label pada data baru (Saifullah dkk., 2023). Misalnya, dalam klasifikasi lesi kulit, sistem akan menganalisis citra lesi untuk menentukan apakah lesi tersebut termasuk MEL, NV, atau jenis lesi lainnya.

Tujuan utama dari klasifikasi adalah untuk mengautomasi proses pengambilan keputusan yang sebelumnya dilakukan secara manual, sehingga dapat memproses data dalam jumlah besar dengan cepat, konsisten, dan mengurangi kemungkinan *human error* akibat kelelahan atau subjektivitas (Salem dkk., 2024). Manfaat klasifikasi sangat luas dalam berbagai bidang, contohnya di bidang kesehatan untuk screening massal penyakit, deteksi dini kanker, dan membantu diagnosis medis serta memungkinkan analisis data skala besar yang mempercepat proses penelitian dan pengembangan di berbagai bidang ilmu pengetahuan (An dkk., 2023). Menurut Dimililer dkk.(2023), klasifikasi terbagi menjadi 2, yaitu:

1. Klasifikasi Biner

Klasifikasi biner adalah jenis klasifikasi yang paling sederhana, dimana data hanya dikategorikan ke dalam dua kelas saja. Contohnya adalah menentukan apakah jenis lesi kulit termasuk kanker atau bukan, menentukan atau apakah tumor bersifat ganas atau jinak. Dalam klasifikasi biner, model mengeluarkan nilai probabilitas antara 0 dan 1, dimana nilai mendekati 0 menunjukkan kelas negatif dan nilai mendekati 1 menunjukkan kelas positif.

2. Klasifikasi Multi-Kelas

Klasifikasi multi-kelas adalah jenis klasifikasi dimana data dikategorikan ke dalam lebih dari dua kelas. Setiap data hanya dapat termasuk dalam satu kelas saja dari beberapa kelas yang tersedia. Contohnya adalah klasifikasi jenis lesi kulit ke dalam kategori AKIEC, BCC, BKL, DF, MEL, NV dan VASC. Contoh lainnya adalah klasifikasi digit tulisan tangan (0-9), pengenalan jenis hewan (kucing, anjing, burung, ikan), atau klasifikasi emosi dari ekspresi wajah (senang, sedih, marah, takut, terkejut, netral).


2.5 Deep Learning

Deep learning merupakan salah satu cabang dari *machine learning* yang meniru cara kerja otak manusia dalam memproses informasi (Mienye & Swart, 2024). Jika *machine learning* secara umum memerlukan rekayasa fitur secara manual (*feature engineering*), maka *deep learning* memiliki kemampuan untuk mengekstraksi dan mempelajari fitur-fitur penting secara otomatis melalui jaringan saraf tiruan berlapis (*artificial neural networks*) (Ayash dkk., 2025). Hal ini menjadikannya sangat unggul dalam menangani data berdimensi tinggi seperti citra, suara, dan teks. Secara arsitektural, *deep learning* tersusun atas tiga komponen utama, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layers*), dan lapisan keluaran (*output layer*) (Chan dkk., 2023).

- *Input layer*, komponen ini bertugas untuk menerima data mentah, misalnya citra kulit pada kasus klasifikasi lesi.
- *Hidden layers*, terdiri dari banyak *neuron* yang saling terhubung dan melakukan proses transformasi data. Setiap lapisan belajar mengenali pola yang lebih kompleks dari lapisan sebelumnya, seperti tepi, bentuk, hingga objek utuh.
- *Output layer*, komponen ini dapat menghasilkan hasil klasifikasi akhir, misalnya menentukan apakah citra termasuk kategori MEL, NV, atau DF.

Keunggulan utama *deep learning* sendiri mampu melakukan representasi dengan mengekstrak fitur otomatis tanpa perlu intervensi manusia, kinerja pada *deep learning* tinggi pada data besar sehingga performa model cenderung meningkat seiring bertambahnya data dan kapaistas komputasi dan terakhir genealisasi yang baik sehingga dapat diterapkan pada domain tertentu seperti pengenalan wajah, diagnosis

medis hingga pemrosesan bahasa alami (Zhang & Qie, 2023).



Gambar 8. Ilustrasi Arsitektur *Deep Learning*

Sebagai contoh, pada Gambar 8. ditunjukkan ilustrasi representasi *deep learning*. Lapisan pertama menerima citra masukan berupa wajah seseorang (*visible layer/input*). Lapisan-lapisan tersembunyi berikutnya mempelajari fitur bertingkat: lapisan pertama mengenali pola tepi (*edges*), lapisan kedua mengenali bentuk dan sudut (*corners and contours*), dan lapisan ketiga mengenali bagian objek (*object parts*). Akhirnya, lapisan keluaran menghasilkan identitas objek secara keseluruhan, seperti “manusia”, “hewan”, atau “kendaraan”. Ilustrasi ini memperlihatkan bahwa semakin dalam lapisan jaringan, semakin abstrak pula fitur yang dipelajari.


Perkembangan saat ini, muncul varian arsitektur *deep learning* yang mengandalkan mekanisme *attention*, salah satunya adalah *transformer*. Berbeda dari CNN, *transformer* memfokuskan perhatian pada hubungan antarbagian dalam data melalui konsep *self-attention*. Salah satu model *transformer* yang sedang banyak dibicarakan adalah model *Swin Transformer*.

2.5.1 *Swin Transformer*

Swin Transformer (*Shifted Window Transformer*) merupakan salah satu arsitektur *deep learning* berbasis *transformer* yang dirancang secara khusus untuk pemrosesan citra. Model ini pertama kali diperkenalkan oleh Liu dkk. (2021), melalui makalah berjudul “*Swin Transformer: Hierarchical Vision Transformer using Shifted Windows*.” *Swin Transformer* hadir sebagai pengembangan dari *Vision Transformer* (ViT) dengan tujuan meningkatkan efisiensi komputasi serta kemampuan representasi hierarkis pada data citra beresolusi tinggi.

Arsitektur ViT memproses citra dengan cara memecahnya menjadi potongan-potongan kecil yang disebut *patch*, di mana setiap *patch* dianggap sebagai satu token, mirip seperti kata dalam pemrosesan bahasa alami (Kurniasari dkk., 2025). Namun, pendekatan tersebut memiliki kelemahan dari sisi efisiensi karena perhitungan *self-attention* dilakukan secara global terhadap seluruh *patch* dalam citra, sehingga kompleksitas komputasinya meningkat secara kuadrat terhadap ukuran citra.

Swin Transformer mengatasi kelemahan ini dengan memperkenalkan mekanisme *Window-Based Multi-Head Self-Attention* (W-MSA), yaitu perhatian (*attention*) yang hanya dilakukan secara lokal di dalam jendela-jendela (*windows*) kecil. Selain itu, *Swin Transformer* juga memperkenalkan mekanisme *Shifted Window Multi-Head Self-Attention* (SW-MSA), yaitu pergeseran posisi jendela pada lapisan berikutnya. Kemampuan menggeser jendela perhatian, model dapat menghubungkan informasi antar area yang sebelumnya tidak berada dalam jendela yang sama. Pendekatan ini menjadikan *Swin Transformer* memiliki kompleksitas linier terhadap ukuran citra, namun tetap mampu menangkap konteks global secara bertahap. Kemampuan tersebut dapat dilihat pada Gambar 9.




Gambar 9. Pergeseran Jendela *Swin Transformer* (Liu dkk., 2021)

Perbedaan utama antara *Swin Transformer* dan ViT terletak pada cara keduanya memproses citra. ViT membagi citra menjadi *patch* berukuran tetap, misalnya 16×16 , dan menerapkan *self-attention* secara global pada seluruh *patch*, sehingga cocok untuk tugas klasifikasi sederhana namun kurang efisien untuk tugas yang membutuhkan pemahaman spasial seperti segmentasi atau deteksi objek.


Sebaliknya, *Swin Transformer* menggunakan pendekatan struktur bertingkat (*hierarkis*) dengan pembagian *patch* yang lebih kecil pada tahap awal (misalnya 4×4) dan secara bertahap menggabungkannya (*patch merging*) menjadi representasi

multi-skala. Pendekatan ini memungkinkan model memahami detail lokal sekaligus konteks global, sehingga lebih fleksibel untuk berbagai tugas *computer vision*. Perbedaan tersebut dapat dilihat pada Gambar 10.



Gambar 10. Perbedaan *Swin Transformer* dan ViT (Liu dkk., 2021)

Secara keseluruhan arsitektur *Swin Transformer* di tampilkan pada Gambar 11.



Gambar 11. Arsitektur *Swin Transformer* (Liu dkk., 2021)

Arsitektur *Swin Transformer* dirancang dengan struktur hierarkis bertingkat yang terdiri dari empat tahap (*stage*) utama, sebagaimana ditunjukkan pada Gambar 11. Setiap tahap memiliki peran khusus dalam mengekstraksi fitur dari tingkat detail rendah hingga representasi semantik tingkat tinggi sebagai berikut:

1. Pada tahap awal, citra input berukuran $H \times W \times 3$ (tinggi, lebar, dan 3 kanal warna RGB) diproses melalui modul *Patch Partition* yang membagi citra menjadi *patch-patch* kecil berukuran 4×4 piksel. Proses ini menghasilkan $\frac{H}{4} \times \frac{W}{4}$ *patch*, di mana setiap *patch* memiliki dimensi fitur sebesar 48 ($4 \times 4 \times 3$). Selanjutnya, modul linear *embedding* memproyeksikan setiap *patch* ke dalam dimensi fitur C yang lebih tinggi, menciptakan representasi awal yang kaya informasi.

2. *Stage 1*: Ekstraksi Fitur Lokal, terdiri dari beberapa *Swin Transformer Block* yang beroperasi pada resolusi $\frac{H}{4} \times \frac{W}{4}$ dengan dimensi fitur C. Pada tahap ini, model memproses fitur-fitur lokal dengan tingkat detail yang tinggi. Setiap *Swin Transformer Block* menerapkan mekanisme W-MSA dan SW-MSA secara bergantian untuk menangkap pola spasial lokal sambil membangun koneksi antar wilayah melalui pergeseran jendela.
3. *Stage 2-4*: Pembentukan Hierarki Fitur, sebelum memasuki stage berikutnya, modul *Patch Merging* menggabungkan *patch-patch* tetangga untuk mengurangi resolusi spasial sambil meningkatkan dimensi fitur. Pada *Stage 2*, resolusi menjadi $\frac{H}{8} \times \frac{W}{8}$ dengan dimensi 2C; *Stage 3* menghasilkan representasi $\frac{H}{16} \times \frac{W}{16}$ dengan dimensi 4C; dan *Stage 4* mencapai $\frac{H}{32} \times \frac{W}{32}$ dengan dimensi 8C. Pengurangan resolusi secara bertahap ini memungkinkan model menangkap konteks yang semakin global pada setiap *stage*.
4. *Swin Transformer Block*, setiap *Swin Transformer Block* terdiri dari dua *sub-block* yang beroperasi secara berurutan. *Sub-block* pertama menggunakan W-MSA, sementara *sub-block* kedua menggunakan SW-MSA. Kedua *sub-block* ini dilengkapi dengan *Layer Normalization* (LN) yang berfungsi menormalkan distribusi aktivasi di setiap layer dengan menghitung rata-rata dan variansi dari seluruh fitur dalam satu sampel, kemudian mentransformasikan nilai-nilai tersebut agar memiliki rata-rata nol dan variansi satu, *Multi-Layer Perceptron* (MLP) berperan sebagai *feed-forward network* yang melakukan transformasi non-linear pada fitur yang telah diproses oleh modul attention, memperkaya representasi fitur dengan kemampuan pemodelan yang lebih kompleks. Biasanya, dimensi *hidden layer* pada MLP diperbesar menjadi 4 kali lipat dari dimensi input untuk meningkatkan kapasitas representasi, dan koneksi residual (dilambangkan dengan simbol $\oplus$) untuk menjaga stabilitas pelatihan dan memfasilitasi aliran gradien.

2.6 Image Pre-processing

Pre-processing merupakan tahapan penting dalam pengolahan citra medis sebelum digunakan sebagai input pada model, yang bertujuan untuk meningkatkan kualitas data, menyeragamkan format input, dan mengatasi berbagai permasalahan yang dapat mempengaruhi performa model klasifikasi (Murcia-Gómez dkk., 2022).

2.6.1 *Splitting Data*

Splitting data merupakan proses membagi dataset menjadi beberapa subset yang berbeda untuk keperluan pelatihan, validasi, dan pengujian model *machine learning* (GeeksforGeeks, 2023). Proses ini menjadi langkah fundamental dalam memastikan bahwa model yang dikembangkan dapat bekerja dengan baik tidak hanya pada data pelatihan, tetapi juga pada data baru yang belum pernah dilihat sebelumnya. Tujuan utama dari *splitting data* adalah untuk mencegah terjadinya *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan sehingga gagal melakukan generalisasi pada data baru. Selain itu, *splitting data* juga memungkinkan evaluasi objektif terhadap performa model dan optimasi *hyperparameter* tanpa mengkompromikan integritas pengujian akhir.

Terdapat beberapa jenis *splitting data* yang umum digunakan dalam pengembangan model. Jenis pertama adalah *train-test split* yang membagi dataset menjadi dua subset dengan rasio umum 80:20 atau 70:30, di mana *training set* digunakan untuk melatih model dan *test set* untuk evaluasi akhir (Joseph, 2022). Jenis kedua adalah *train-validation-test split* yang membagi dataset menjadi tiga subset dengan rasio seperti 60:20:20, di mana *validation set* ditambahkan untuk monitoring dan *tuning hyperparameter* (Shah dkk., 2025).

Metode pembagian yang dapat diterapkan antara lain *random split* yang membagi data secara acak, *stratified split* yang mempertahankan proporsi setiap kelas di semua subset, serta *k-fold cross validation* yang membagi data menjadi *k* bagian dan melakukan pelatihan evaluasi sebanyak *k* kali untuk hasil yang lebih *robust* (GeeksforGeeks, 2023). Dalam konteks penelitian lesi kulit, *stratified split* sangat penting karena dataset medis sering mengalami *inbalance data*, dan perlu diperhatikan juga *patient-level splitting* untuk menghindari data *leakage* di mana gambar dari pasien yang sama tersebar di *training* dan *test set* (Huang dkk., 2025).

2.6.2 *Resize*

Resize atau pengubahan ukuran citra merupakan proses mengubah dimensi citra menjadi ukuran yang seragam (Olle dkk., 2025). Proses ini diperlukan karena model membutuhkan input dengan dimensi yang konsisten untuk setiap citra yang diproses.

Citra lesi kulit yang diperoleh dari berbagai sumber seringkali memiliki resolusi dan dimensi yang bervariasi, tergantung pada perangkat pengambilan gambar, jarak pengambilan, dan kondisi pemotretan, sehingga dapat menyebabkan inkonsistensi dalam proses pelatihan model (Hasan, 2024). Oleh karena itu, seluruh citra perlu di *resize* ke ukuran yang sama sebelum digunakan sebagai input model. Pemilihan ukuran target *resize* bergantung pada arsitektur model yang digunakan. Arsitektur populer seperti *Swin Transformer* umumnya menggunakan ukuran input standar seperti 224×224 piksel (Aksoy dkk., 2024).

2.6.3 *Balancing Data*

Menurut Bao (Bao, 2023), (*class imbalance*) merupakan permasalahan dimana jumlah sampel untuk setiap kelas tidak merata. Kondisi ini dapat menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan kelas minoritas, sehingga menurunkan performa klasifikasi secara keseluruhan.

2.6.3.1 *Augmentasi*

Terdapat beberapa teknik dalam *balancing data*, salah satunya adalah augmentasi. Augmentasi data merupakan teknik untuk meningkatkan jumlah dan variasi data *training* dengan cara membuat modifikasi pada citra yang sudah ada tanpa mengubah label kelasnya (Guerrero dkk., 2024). Teknik ini efektif untuk mengatasi *inbalance data* sekaligus meningkatkan kemampuan generalisasi model.

Menurut Yilmaz dkk. (2022), beberapa teknik augmentasi yang dapat diterapkan pada citra lesi kulit meliputi:

- Teknik *rotation* digunakan untuk memutar citra dalam rentang sudut tertentu sehingga model menjadi lebih robust terhadap perubahan orientasi objek.
- Teknik *zooming*, digunakan untuk memperbesar atau memperkecil sebagian area citra untuk mensimulasikan variasi jarak pengambilan gambar.
- Teknik *width shift range* dan *height shift range* menggeser posisi citra secara horizontal dan vertikal untuk meningkatkan kemampuan model mengenali objek yang tidak selalu berada di posisi tengah.

- Teknik *horizontal flip* dan *vertical flip* digunakan untuk membalik citra secara mendatar dan tegak, sehingga membantu model beradaptasi terhadap simetri dan arah tampilan yang berbeda.

2.6.3.2 Class Weight

Selain augmentasi, terdapat pula teknik *class weight*. *Class weight* merupakan pendekatan alternatif untuk menangani *inbalance* kelas dengan memberikan bobot yang berbeda pada setiap kelas selama proses *training* (Hakim dkk., 2021). Kelas minoritas diberikan bobot yang lebih tinggi sehingga kesalahan prediksi pada kelas tersebut akan memberikan penalti yang lebih besar pada fungsi *loss*. Menurut *Scikit-learn Developers* (Scikit-learn Developers, 2025), perhitungan *class weight* umumnya menggunakan formula sebagai berikut:

$$w_i = \frac{N_{\text{total}}}{n_{\text{classes}} \times n_i} \quad (2)$$

w_i adalah bobot untuk kelas ke- i , N_{total} adalah total jumlah data, n_{kelas} adalah jumlah kelas, dan n_i adalah jumlah sampel pada kelas ke- i .

2.6.4 Normalisasi ImageNet

Normalisasi adalah proses penskalaan nilai piksel citra ke dalam rentang tertentu untuk mempercepat konvergensi dan meningkatkan stabilitas *training* model (Musthafa dkk., 2024). Tugas *computer vision* seperti klasifikasi lesi kulit, citra RGB digunakan karena sebagian besar *pretrained models* dilatih menggunakan dataset RGB berskala besar, salah satunya *ImageNet* (Liu dkk., 2021). *ImageNet* merupakan dataset dengan lebih dari 14 juta citra dan 20.000 + kategori objek, dimana terdapat subset 1000 kelas. Dataset ini memungkinkan model mempelajari representasi fitur visual yang general dan dapat ditransfer ke domain lain melalui TL. Setiap citra berukuran bervariasi dan umumnya di *resize* ke 224×224 atau 299×299 piksel.

Model yang di *pretrained* dengan *ImageNet* seperti *VGG16*, *ResNet18*, dan *Swin Transformer* saat melakukan *pretrained* model, citra input harus dinormalisasi sesuai

ImageNet mean dan *standard deviation* (Zhu dkk., 2024;Liu dkk., 2021). Sehingga untuk model-model tersebut, citra input harus dinormalisasi sesuai nilai *mean* dan *standard deviation ImageNet* (Aksoy dkk., 2024). Nilai normalisasi didapat dari rumus berikut:

$$X_{\text{normalisasi}} = \frac{x - \mu}{\sigma} \quad (3)$$

dengan nilai μ dan σ sebagai berikut:

$$\mu = [0,485; 0,456; 0,406]$$

$$\sigma = [0,229; 0,224; 0,225]$$

2.6.5 Hyperparameter Tuning

Hyperparameter tuning merupakan proses pencarian kombinasi *hyperparameter* optimal untuk menghasilkan performa model terbaik (Ilembayo dkk., 2024). Terdapat beberapa teknik *hyperparameter tuning* yang umum digunakan dalam *machine learning*:

- *Grid Search*: mencoba semua kombinasi *hyperparameter* secara sistematis, sehingga menjamin menemukan kombinasi terbaik dalam *search space* yang ditentukan, namun membutuhkan waktu komputasi yang tinggi jika *search space* besar (Subaşı, 2024).
- *Random Search*: mengambil kombinasi *hyperparameter* secara acak dari distribusi yang ditentukan, sehingga lebih efisien dan dapat menjelajahi *search space* lebih luas, meskipun tidak memanfaatkan informasi dari percobaan sebelumnya sehingga kombinasi optimal bisa terlewat optimal (Rom dkk., 2024).
- Optuna adalah *framework* untuk *hyperparameter tuning* yang lebih cerdas dibandingkan metode acak atau sistematis. Algoritma utamanya, *Tree-structured Parzen Estimator*, memanfaatkan hasil percobaan sebelumnya untuk menebak kombinasi *hyperparameter* terbaik, sehingga pencarian lebih efisien (Akiba dkk., 2019). Optuna memiliki mekanisme *pruning* untuk menghentikan percobaan yang tidak menjanjikan, serta mendukung ruang *hyperparameter* yang dinamis. Namun, hasilnya bisa sedikit berbeda tergantung inisialisasi awal karena ada elemen acak dalam algoritma TPE, sehingga percobaan tidak selalu memberikan hasil yang sama setiap dijalankan.

2.7 Metrik Evaluasi

Confusion matrix merupakan salah satu metode evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dengan membandingkan prediksi model terhadap nilai sebenarnya dari data (Sathyanarayanan & Tantri, 2024). Pada klasifikasi multi-kelas seperti klasifikasi lesi kulit 7 kelas, *confusion matrix* berbentuk matriks $N \times N$, dimana N adalah jumlah kelas yang diprediksi. Setiap baris pada matriks merepresentasikan kelas aktual (*ground truth*), sedangkan setiap kolom merepresentasikan kelas yang diprediksi oleh model. Matriks $N \times N$ ditampilkan pada 12.

		Predicted Class			
		C_1	C_2	...	C_N
Actual Class	C_1	$C_{1,1}$	FP	...	$C_{1,N}$
	C_2	FN	TP	...	FN
	...	...	...	...	...
	C_N	$C_{N,1}$	FP	...	$C_{N,N}$

Gambar 12. *Confusion Matrix* (Markoulidakis dkk., 2021)

Mengingat permasalahan yang dihadapi merupakan klasifikasi multikelas, maka *confusion matrix* berukuran 7×7 selanjutnya dianalisis menggunakan pendekatan *one-vs-rest*, yaitu dengan memandang satu kelas sebagai kelas positif dan enam kelas lainnya sebagai kelas negatif. Pendekatan ini memungkinkan perhitungan metrik evaluasi secara konsisten untuk setiap kelas. Berdasarkan *confusion matrix* tersebut, diperoleh nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) untuk masing-masing kelas. Penjelasan sebagai berikut:

- TP_i : Jumlah data yang berasal dari kelas i dan berhasil diprediksi dengan benar sebagai kelas i oleh model.
- TN_i : Jumlah data yang tidak berasal dari kelas i dan diprediksi dengan benar sebagai bukan kelas i oleh model.
- FP_i : Jumlah data yang tidak berasal dari kelas i , namun secara keliru diprediksi sebagai kelas i oleh model.
- FN_i : Jumlah data yang berasal dari kelas i , tetapi diprediksi secara salah sebagai kelas selain i oleh model.

Keempat komponen tersebut pada dasarnya merepresentasikan frekuensi kejadian yang dapat digunakan untuk mengestimasi peluang bersyarat antara kelas aktual dan hasil prediksi (Purnomo dkk., 2023). Oleh karena itu, interpretasi kinerja model pada penelitian ini juga dikaitkan dengan Teorema Bayes sebagai kerangka matematis untuk menjelaskan hubungan probabilitas tersebut. Secara umum, rumus dari teorema bayes seperti pada persamaan (4) (Septyana & Fauzi, 2025).

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}, \quad P(B) \neq 0 \quad (4)$$

Keterangan:

- $P(A|B)$ = Peluang terjadinya kejadian A , dengan syarat B telah terjadi
- $P(B|A)$ = Peluang terjadinya kejadian B , dengan syarat A telah terjadi
- $P(A)$ = Peluang terjadinya kejadian A
- $P(B)$ = Peluang terjadinya kejadian B

Peluang bersyarat $P(B | A)$ didefinisikan sebagai persamaan (5).

$$P(B | A) = \frac{P(A \cap B)}{P(A)} \iff P(B | A)P(A) = P(A \cap B) \quad (5)$$

dengan $P(A \cap B)$ merupakan peluang kejadian A dan B terjadi secara bersamaan. Berdasarkan persamaan (5), Teorema Bayes dapat dijabarkan seperti pada persamaan (6)

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} = \frac{P(A \cap B)}{P(B)} \quad (6)$$

Selain itu terdapat metrik evaluasi dalam menilai peforma model, sebagai berikut:

1. *Accuracy*

Accuracy merupakan metrik evaluasi yang mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dilakukan oleh model. Metrik ini menunjukkan seberapa tepat model dalam memprediksi seluruh sampel data, baik yang positif maupun negatif. *Accuracy* dihitung menggunakan rumus seperti persamaan (7).

$$Accuracy = \frac{\sum_{i=1}^N TP_i}{N} \quad (7)$$

Perspektif probabilitas empiris menempatkan akurasi sebagai estimasi peluang bahwa hasil prediksi model sesuai dengan label sebenarnya. Peluang ini dinyatakan sebagai berikut:

$$Accuracy = P(\hat{Y} = Y) \quad (8)$$

di mana Y merupakan label sebenarnya dan $\hat{Y}$ merupakan label hasil prediksi model. Karena prediksi yang benar terjadi ketika model menghasilkan TP_i atau TN_i , maka peluang $P(\hat{Y} = Y)$ diestimasi menggunakan perbandingan jumlah TP_i dan TN_i terhadap total seluruh prediksi. Sehingga peluang yang menyatakan *accuracy* dapat ditulis seperti pada persamaan (9).

$$P(\hat{Y} = Y) \approx \frac{\sum_{i=1}^N TP_i}{N} \quad (9)$$

2. Precision

Precision merupakan metrik yang mengukur proporsi data yang benar-benar berasal dari kelas i di antara seluruh data yang diprediksi sebagai kelas i . Metrik ini menjawab pertanyaan "dari semua yang diprediksi kelas i , berapa banyak yang benar-benar kelas i ". Rumus *precision* perkelas dapat dilihat pada persamaan (10) dan untuk keseluruhan nilai *precision* menggunakan *macro avg* seperti persamaan (11).

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (10)$$

$$Precision_{macro} = \frac{1}{N} \sum_{i=1}^N Precision_i \quad (11)$$

Precision juga dapat dihitung dengan menggunakan konsep peluang bersyarat dalam Teorema Bayes, sehingga dapat dituliskan seperti pada persamaan (12).

$$\begin{aligned} Precision_i &= P(\text{Data Aktual}_i \mid \text{Data Prediksi}_i) \\ &= \frac{P(\text{Data Aktual}_i \cap \text{Data Prediksi}_i)}{P(\text{Data Prediksi}_i)} \end{aligned} \quad (12)$$

3. Sensitivity

Sensitivity (recall) merupakan metrik evaluasi untuk mengukur proporsi data yang berhasil diprediksi sebagai kelas i dibandingkan dengan seluruh data

yang benar-benar berasal dari kelas i . Nilai FN merepresentasikan data kelas i yang gagal dikenali oleh model, sehingga secara langsung memengaruhi nilai $sensitivity$. Metrik ini menjawab pertanyaan ”dari semua yang sebenarnya kelas i , berapa banyak yang berhasil diprediksi benar kelas i ?”. $Sensitivity$ sangat penting dalam aplikasi medis seperti deteksi lesi kulit, karena metrik ini mengukur kemampuan model untuk mendeteksi kasus positif (misalnya lesi berbahaya). Rumus $sensitivity$ perkelas dapat dilihat pada persamaan (13) dan untuk keseluruhan nilai $sensitivity$ menggunakan $macro\ avg$ seperti persamaan (14).

$$Sensitivity_i = \frac{TP_i}{TP_i + FN_i} \quad (13)$$

$$Sensitivity_{macro} = \frac{1}{N} \sum_{i=1}^N Sensitivity_i \quad (14)$$

$Sensitivity$ juga dapat dihitung dengan menggunakan konsep peluang bersyarat dalam Teorema Bayes, sehingga dapat dijabarkan pada persamaan (15).

$$\begin{aligned} Sensitivity_i &= P(\text{Data Prediksi}_i \mid \text{Data Aktual}_i) \\ &= \frac{P(\text{Data Prediksi}_i \cap \text{Data Aktual}_i)}{P(\text{Data Aktual}_i)} \end{aligned} \quad (15)$$

4. *Specificity*

Specificity merupakan metrik evaluasi yang mengukur seberapa baik model tidak salah menebak kelas i pada sampel yang sebenarnya bukan kelas i . Metrik ini menjawab pertanyaan ”dari semua yang sebenarnya bukan kelas i , berapa banyak yang berhasil diprediksi bukan kelas i ?”. Secara konteks medis, *specificity* mengukur kemampuan model untuk mengidentifikasi kasus non-penyakit dengan benar. Rumus *Specificity* perkelas dapat dilihat pada persamaan (16) dan untuk keseluruhan nilai *Specificity* menggunakan *macro avg* seperti persamaan (17).

$$Specificity_i = \frac{TN_i}{TN_i + FP_i} \quad (16)$$

$$Specificity_{macro} = \frac{1}{N} \sum_{i=1}^N Specificity_i \quad (17)$$

Specificity juga dapat dihitung dengan menggunakan konsep peluang bersyarat

dalam Teorema Bayes, sehingga dapat dijabarkan pada persamaan (18).

$$\begin{aligned} Specificity_i &= P(\text{Data Prediksi}_{\neq i} \mid \text{Data Aktual}_{\neq i}) \\ &= \frac{P(\text{Data Prediksi}_{\neq i} \cap \text{Data Aktual}_{\neq i})}{P(\text{Data Aktual}_{\neq i})} \end{aligned} \quad (18)$$

5. *F1-Score*

F1-Score merupakan metrik evaluasi yang menggabungkan *precision* dan *sensitivity* menjadi satu nilai tunggal menggunakan *harmonic mean*. Metrik ini sangat berguna ketika terdapat *trade-off* antara *precision* dan *recall*, atau ketika distribusi kelas *inbalance*. *F1-Score* memberikan bobot yang sama terhadap *precision* dan *sensitivity*, sehingga cocok digunakan ketika kedua metrik tersebut sama-sama penting. Rumus *F1-Score* perkelas dapat dilihat pada persamaan (11) dan untuk keseluruhan nilai *F1-Score* menggunakan *macro avg* seperti persamaan (12).

$$F1-Score_i = 2 \times \frac{Precision_i \times Sensitivity_i}{Precision_i + Sensitivity_i} \quad (19)$$

$$F1-Score_{macro} = \frac{1}{N} \sum_{i=1}^N F1-Score_i \quad (20)$$

F1-Score juga dapat dihitung dengan menggunakan konsep peluang bersyarat dalam Teorema Bayes, sehingga dapat dijabarkan pada persamaan (21).

$$F1-Score_i = 2 \times \frac{P(\text{Data Aktual}_i \mid \text{Data Prediksi}_i) \times P(\text{Data Prediksi}_i \mid \text{Data Aktual}_i)}{P(\text{Data Aktual}_i \mid \text{Data Prediksi}_i) + P(\text{Data Prediksi}_i \mid \text{Data Aktual}_i)} \quad (21)$$

Receiver Operating Characteristic (ROC) merupakan kurva yang merepresentasikan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai nilai *threshold*. Kurva ini digunakan untuk mengevaluasi kemampuan model dalam membedakan kelas positif dan negatif secara menyeluruh (Liao dkk., 2023). Nilai *Area Under the Curve* (AUC) berfungsi sebagai ukuran kuantitatif dari performa tersebut, di mana nilai AUC yang semakin mendekati satu menunjukkan kemampuan diskriminatif model yang semakin baik terhadap pola data (Arulanathan dkk., 2024). Metrik ROC–AUC dipilih karena tidak bergantung pada satu nilai *threshold* tertentu, relatif *robust* terhadap *inbalance* kelas, serta mampu menilai kualitas *ranking* probabilitas keluaran model. Karakteristik ini menjadikan

ROC–AUC sangat sesuai untuk tugas klasifikasi medis yang menuntut sensitivitas tinggi dalam membedakan karakteristik citra (Ali dkk., 2022).

Pada permasalahan klasifikasi *multiclass*, ROC–AUC dapat diterapkan melalui pendekatan *One-vs-Rest* (OvR) atau *One-vs-One* (OvO), sehingga kurva ROC dan nilai AUC tetap dapat dihitung secara sistematis untuk setiap kelas atau pasangan kelas. Pendekatan ini memastikan bahwa ROC–AUC tetap relevan dan informatif dalam mengevaluasi performa model *multiclass*, karena metrik tersebut tetap mampu menggambarkan kemampuan diskriminasi model terhadap lebih dari dua kelas (Giudici dkk., 2025).

Pada penelitian ini, pendekatan OvR digunakan dengan membangun satu model biner untuk setiap kelas, di mana satu kelas diperlakukan sebagai kelas positif dan seluruh kelas lainnya sebagai kelas negatif. Pendekatan ini menghasilkan kurva ROC dan nilai AUC yang merepresentasikan performa identifikasi masing-masing kelas secara individual serta memberikan interpretasi makro yang lebih jelas mengenai kemampuan pemisahan setiap kelas terhadap kelas lainnya (Giudici dkk., 2025). Sebaliknya, pendekatan OvO membangun model biner untuk setiap pasangan kelas, sehingga evaluasi yang dihasilkan bersifat *pairwise* dan lebih sensitif dalam menangkap perbedaan antar kelas yang memiliki kemiripan visual atau distribusi fitur yang saling berdekatan.

Selain itu terdapat juga grafik *accuracy* dan *loss* yang merupakan alat visualisasi yang sering digunakan dalam evaluasi pelatihan model *deep learning*, khususnya pada tugas klasifikasi citra medis seperti lesi kulit (Aksoy dkk., 2025). Selama pelatihan, kurva *training accuracy* dan *training loss* menunjukkan bagaimana model mempelajari pola dari data latih, sedangkan kurva *validation accuracy* dan *validation loss* menunjukkan kemampuan model untuk menggeneralisasi pada data yang tidak dilatih sebelumnya (Muhaba dkk., 2022). Ketika kurva *accuracy* naik dan *loss* turun secara konsisten pada kedua set, ini menunjukkan bahwa model berhasil menyesuaikan parameter dengan baik dan memiliki kemampuan generalisasi yang baik. Sebaliknya, perbedaan signifikan antara kurva pelatihan dan validasi, misalnya *accuracy* validasi yang stagnan sementara akurasi pelatihan terus meningkat, dapat mengindikasikan *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan dengan data latih sehingga performa pada data baru menurun. Analisis visual terhadap grafik ini membantu peneliti dalam mengidentifikasi fenomena *underfitting* maupun *overfitting* serta menilai kebutuhan akan teknik regulasi.

Studi-studi klasifikasi lesi kulit berbasis *deep learning* pada dekade ini umumnya menyajikan kurva *accuracy* dan *loss* untuk memperlihatkan pola konvergensi serta stabilitas model yang diusulkan, sehingga interpretasi metrik visual ini menjadi bagian fundamental dalam validasi performa model klasifikasi medis.

BAB III

METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

3.1.1 Tempat Penelitian

Penelitian ini dilaksanakan melalui studi literatur yang bertempat di Jurusan Matematika, Fakultas Matematika, dan Ilmu Pengetahuan Alam, Universitas Lampung. Berlokasi di Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedong Meneng, Bandar Lampung.

3.1.2 Waktu Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2025/2026 tepatnya bulan September 2025. Proses pengerjaan terbagi menjadi tiga tahap. Tahap pertama melakukan studi literatur, penentuan tema, pengumpulan data, dan penyusunan proposal. Tahap kedua merupakan tahap pengerjaan program yang dimulai dari *splitting data*, *pre-processing data*, dan pemodelan klasifikasi menggunakan model *Swin Transformer*. Tahap ketiga adalah penyusunan hasil penelitian dan kesimpulan penelitian.

3.2 Data dan Alat

3.2.1 Data

Data yang digunakan dalam penelitian ini berupa data citra lesi kulit yang diperoleh dari Kaggle melalui tautan <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>. Dataset tersebut merupakan data HAM10000 (*Human Against Machine with 10,000 training images*), yaitu kumpulan gambar dermatoskopi lesi kulit yang dikumpulkan dan dipublikasikan oleh Tschandl dkk. (Tschandl dkk., 2018). Dataset ini dirancang khusus untuk pengembangan dan evaluasi sistem klasifikasi lesi kulit berbasis *machine learning* dan telah menjadi salah satu dataset standar dalam penelitian deteksi lesi kulit. Pada dataset ini, data citra disimpan dalam dua direktori utama, yaitu HAM10000_images_part_1 dan HAM10000_images_part_2, yang berisi seluruh gambar lesi kulit dalam format .jpg dengan total ukuran sekitar 6 GB. Sementara itu, label dan informasi pendukung disediakan dalam file HAM10000_metadata.csv, sebagai contoh ditampilkan pada Tabel 2.


Tabel 2. Contoh Informasi Data

lesion_id	image_id	dx	dx_type	age	sex	localization
HAM_0002644	ISIC_0029417	akiec	histo	80	female	neck
HAM_0006002	ISIC_0029915	akiec	histo	50	female	face
HAM_0000781	ISIC_0028155	bcc	histo	50	male	back
HAM_0003220	ISIC_0034093	bcc	histo	80	female	face
HAM_0000118	ISIC_0027419	bkl	histo	80	male	scalp
HAM_0004453	ISIC_0031825	bkl	confocal	65	female	face
HAM_0005276	ISIC_0027008	df	histo	75	male	back
HAM_0005362	ISIC_0029824	df	consensus	50	male	lower extremity
HAM_0000871	ISIC_0025964	mel	histo	40	female	chest
HAM_0000871	ISIC_0030623	mel	histo	40	female	chest
HAM_0001751	ISIC_0024698	nv	consensus	70	male	face
HAM_0000559	ISIC_0024693	nv	follow_up	45	female	upper extremity
HAM_0006889	ISIC_0031197	vasc	histo	20	male	upper extremity
HAM_0004820	ISIC_0030722	vasc	consensus	45	female	abdomen


Kolom *lesion_id* merupakan identitas unik yang merepresentasikan satu lesi kulit, di mana satu lesi dapat memiliki lebih dari satu citra. Kolom *image_id* menunjukkan identitas unik untuk setiap citra lesi kulit yang digunakan sebagai input dalam proses

pemodelan. Kolom *dx* merepresentasikan diagnosis klinis lesi kulit dan digunakan sebagai label kelas dalam tugas klasifikasi. Kolom *dx_type* menjelaskan metode yang digunakan dalam penetapan diagnosis. Beberapa macam metode dalam kolom *dx_type* yaitu ada *histo*. Metode *histo* mengacu pada pemeriksaan histopatologi, yaitu diagnosis berdasarkan analisis jaringan lesi melalui biopsi dan pengamatan mikroskopis, yang memiliki tingkat keandalan tertinggi. Artinya dokter mengambil sedikit kulit yang sakit, lalu melihatnya dengan mikroskop. Karena dilihat langsung sampai ke sel-selnya, cara ini paling pasti dan paling benar. Lalu ada metode *confocal*, diagnosis yang ditetapkan menggunakan mikroskopi konfokal, yaitu teknik pencitraan *non-invasif* untuk melihat struktur kulit secara mendetail. *Confocal* berarti dokter melihat kulit dengan alat khusus, seperti kamera super canggih, tanpa melukai kulit. Dokter bisa melihat bagian dalam kulit, tapi tidak sedetail melihat jaringan langsung, jadi tingkat kepastiannya di bawah *histo*. Metode *consensus* merujuk pada diagnosis yang ditentukan berdasarkan kesepakatan beberapa dokter spesialis kulit. *Consensus* berarti beberapa dokter melihat gambar yang sama, lalu sepakat bersama tentang jenis penyakitnya. Jadi bukan satu dokter saja yang menentukan. Terakhir adalah metode *follow-up*, diagnosis yang diperoleh dari hasil pemantauan klinis pasien dalam jangka waktu tertentu. *follow-up* berarti dokter tidak langsung memastikan, tetapi mengamati lesi itu dalam waktu lama. Jika bentuknya tidak berubah atau berubah dengan cara tertentu, barulah dokter menyimpulkan jenis penyakitnya. Kolom selanjutnya adalah kolom *age* yang menunjukkan usia pasien dalam satuan tahun, sedangkan kolom *sex* merepresentasikan jenis kelamin pasien. Kolom *localization* menunjukkan lokasi anatomi lesi pada tubuh pasien

Dataset HAM10000 bersumber dari ISIC Archive (*International Skin Imaging Collaboration*), sebuah kolaborasi internasional yang bertujuan untuk mengumpulkan dan menyediakan data gambar kulit berkualitas tinggi guna mendukung penelitian dalam bidang dermatologi dan *computer vision*. ISIC didirikan untuk mengatasi tantangan dalam deteksi dini MEL dan kanker kulit lainnya melalui pendekatan teknologi digital. Dataset HAM10000 sendiri merupakan subset yang telah dikurasi dari ISIC Archive, dengan data tambahan yang berasal dari *Department of Dermatology, Medical University of Vienna, Austria*. Dataset HAM10000 terdiri dari 10.015 gambar dermatoskopi lesi kulit yang telah dibagi menjadi 7 kategori yaitu AKIEC, BCC, BKL, DF, MEL, NV dan VASC. Gambar 13. menunjukkan tampilan jenis lesi kulit tersebut.




(a)




(b)




(c)




(d)



(e)



(f)



(g)

Gambar 13. Sampel Gambar Lesi Kulit: (a) AKIEC; (b) BCC; (c) BKL; (d) DF; (e) MEL; (f) NV; (g) VASC

Dataset HAM10000 memiliki distribusi kelas yang (*imbalanced*), dengan kelas NV mendominasi jumlah sampel, sementara kelas DF memiliki jumlah sampel yang paling sedikit. *Inbalance* ini mencerminkan distribusi kasus yang sebenarnya terjadi dalam praktik klinis dermatologi. Distribusi kelas ditampilkan pada Tabel 3.

Tabel 3. Distribusi Kelas Dataset HAM10000

Nama Kelas	Jumlah Data
NV	6.702
MEL	1.113
BKL	1.099
BCC	514
AKIEC	327
VASC	142
DF	115
Total	10.015

3.2.2 Alat

Penelitian ini menggunakan beberapa alat sebagai penunjang, sebagai berikut:

1. Perangkat Keras (*Hardware*)

Perangkat yang digunakan dalam penelitian ini adalah laptop dengan merk HP Laptop 14s-dq4xxx dengan sistem operasi *Microsoft Windows 11 Home Single Language* 64-bit. Spesifikasi perangkat tersebut adalah sebagai berikut:

- Prosesor: 11th Gen Intel® Core™ i5-1155G7 @ 2.50GHz (4 Core, 8 Logical Processor)
- RAM: 8 GB
- Arsitektur Sistem: x64-based processor
- Mode BIOS: UEFI
- Versi BIOS: AMI F.33 (04 Oktober 2023)

2. Perangkat Lunak (*Software*)

Software yang digunakan untuk membantu penelitian ini, sebagai berikut:

(a) Sistem Operasi *Windows* 10 Pro 64-bit

Windows 10 Pro 64-bit adalah versi profesional dari sistem operasi *Windows* yang mendukung prosesor 64-bit. Versi ini memiliki

keunggulan dalam kecepatan, efisiensi, dan kemampuan menjalankan banyak program secara bersamaan, sehingga mendukung kinerja komputasi yang lebih optimal (Pro, 2025).

(b) *Overleaf (LaTeX – TeX Live 2024)*

Penulisan laporan penelitian ini dilakukan menggunakan LaTeX pada platform Overleaf. Overleaf merupakan editor daring berbasis TeX Live 2024 yang mendukung penyusunan dokumen ilmiah secara terstruktur, konsisten, dan sesuai dengan kaidah penulisan akademik. Penggunaan LaTeX membantu memastikan format laporan tetap rapi dan profesional (Fitriani dkk., 2024).

(c) *Google Colab*

Eksperimen dan pelatihan model dilakukan menggunakan *Google Colaboratory* (Colab), yaitu platform berbasis *cloud* yang menyediakan lingkungan *Python* dengan akses GPU secara gratis. Colab digunakan untuk menjalankan seluruh kode pemrosesan data, pelatihan model, serta evaluasi hasil klasifikasi (Octarina dkk., 2025).

(d) *Library Pandas 2.2.2*

Pandas merupakan *library Python* yang digunakan untuk pengolahan dan analisis data, seperti manipulasi tabel, pembersihan data, serta transformasi dataset (Candra, 2025).

(e) *Library NumPy 2.0.2*

NumPy digunakan untuk komputasi numerik dengan menyediakan objek *array* multidimensi serta berbagai fungsi matematika yang efisien untuk analisis data (Candra, 2025).

(f) *Library Matplotlib 3.10.0*

Matplotlib digunakan untuk visualisasi data melalui grafik, plot, maupun diagram. *Library* ini membantu peneliti dalam menampilkan hasil analisis data dalam bentuk visual yang mudah dipahami (Surbakti dkk., 2024).

(g) *Library Seaborn 0.13.2*

Seaborn merupakan *library* visualisasi berbasis *matplotlib* yang menyediakan tampilan grafik statistik dengan gaya yang lebih menarik dan informatif (Hafeez & Sial, 2021).

(h) *Library Scikit-Learn 1.6.1*

Scikit-Learn digunakan untuk menerapkan berbagai algoritma *machine learning*, seperti klasifikasi, regresi, dan *clustering*, serta menyediakan fungsi untuk evaluasi model (Fahmi, 2023).

(i) *Library PyTorch 2.8.0+cu126*

PyTorch adalah *framework deep learning* berbasis *Python* yang digunakan untuk komputasi tensor dan pembuatan model jaringan saraf tiruan. *PyTorch* mendukung pelatihan model berbasis GPU sehingga mempercepat proses komputasi (Hitchcock dkk., 2021).

(j) *Library TIMM 1.0.21*

PyTorch Image Models (TIMM) adalah *library* yang menyediakan berbagai model pra-latih (*pretrained*) untuk klasifikasi citra, termasuk *Swin Transformer*, *EfficientNet*, dan model modern lainnya. *Library* ini mempermudah penggunaan arsitektur mutakhir dalam tugas pengenalan citra (Wightman dkk., 2021).

(k) *Library Optuna 4.5.0*


Optuna digunakan untuk melakukan *hyperparameter tuning* secara otomatis dan efisien melalui pendekatan *Bayesian Optimization*. *Library* ini membantu menemukan kombinasi parameter terbaik untuk meningkatkan performa model (Akiba dkk., 2019).

(l) *Library Albumentations 2.0.8*

Albumentations digunakan untuk melakukan data augmentation pada gambar, seperti rotasi, *flipping*, zoom, dan transformasi warna. Tujuannya untuk memperbanyak variasi data pelatihan dan mencegah *overfitting* (Buslaev dkk., 2020).

3.3 Metode Penelitian

Penelitian ini membandingkan performa teknik *balancing* antara penggunaan augmentasi, *class weight* dan augmentasi + *class weight* dalam meningkatkan kinerja model klasifikasi *Swin Transformer* pada data lesi kulit. Langkah-langkah yang dilakukan dalam penelitian ini diilustrasikan pada Gambar 14.



Gambar 14. Diagram Alur Penelitian

Berdasarkan alur pengerjaan pada Gambar 14., berikut penjelasan setiap tahapannya:

1. Penginputan data menggunakan *Google Colab* sebagai tempat untuk menulis code *python*.
2. Data yang di input, di *splitting*/dibagi menjadi data *training*, *validation* dan *testing*. Pertama dari keseluruhan data, dibagi menjadi 80% data model dan 20% data testing. Selanjutnya data model tersebut dibagi menjadi 80% data training dan 20% data validation.
3. Data yang sudah di bagi, selanjutnya di *pre-procesing* yang bertujuan untuk mempersiapkan data agar lebih siap untuk digunakan. Semua data di *resize* menjadi 224x224 piksel karena model *Swin Transformer* di *pretained* dengan ukuran tersebut. Selanjutnya adalah tahap *balancing data* menggunakan augmentasi dan *class weight*, namun teknik tersebut hanya untuk data *training* saja. Terakhir, tahapan normalisasi menggunakan normalisasi *ImageNet* untuk semua data.
4. Data hasil *pre-processing* yang sudah siap digunakan, selanjutnya yaitu tahap mencari parameter terbaik pada model *Swin Transformer* menggunakan *frame work optuna*.

5. Setelah mendapatkan parameter yang bagus, selanjutnya digunakan untuk mempelajari pada model *Swin Transformer*, dan memprediksi kelas menggunakan data *testing*.
6. Pengukuran performa dilakukan dengan 5 metrik evaluasi yaitu *accuracy*, *precision*, *sensitiftity*, *spesivisity*, dan *f1-score* dan 2 grafik *accuracy-loss* dan ROC-AUC.
7. Terakhir adalah penarikan kesimpulan dari hasil yang didapat.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini melakukan perbandingan metode *balancing data* dengan memakai teknik augmentasi yang sering dipakai banyak peneliti dan teknik *class weight* yang jarang dipakai peneliti untuk melakukan klasifikasi lesi kulit menggunakan model *Swin Transformer*. Data yang dipakai pada penelitian ini adalah data HAM10000 yang terbagi menjadi 7 kelas. Kesimpulan dari penelitian ini sebagai berikut:

1. Pertama, penelitian ini berhasil menganalisis klasifikasi lesi kulit dalam skenario multi-kelas. Model mampu mengklasifikasikan lebih dari dua kelas lesi kulit dengan performa yang baik, yang ditunjukkan oleh nilai *accuracy* sebesar 88,77%, *precision* sebesar 83,28%, *sensitivity* sebesar 83,42%, *specificity* sebesar 97,07%, *F1-score* sebesar 83,10% dan AUC sebesar 99,04%. Hasil ini menunjukkan bahwa pendekatan multi-kelas dapat diterapkan secara efektif untuk membedakan berbagai jenis lesi kulit meskipun dataset yang digunakan memiliki distribusi kelas yang *inbalance*.
2. Kedua, hasil evaluasi menunjukkan bahwa model berbasis *Transformer*, khususnya *Swin Transformer*, memiliki performa yang kompetitif dibandingkan model CNN berbasis *transfer learning* yang banyak digunakan pada penelitian terdahulu. Model *Swin Transformer* mencapai nilai AUC sebesar 99,04%, yang mengindikasikan kemampuan diskriminasi kelas yang sangat baik dan sebanding. Selain itu, keseimbangan antara *sensitivity* sebesar 83,42% dan *specificity* sebesar 99,07% menunjukkan bahwa model mampu mengenali lesi kulit secara akurat sekaligus meminimalkan kesalahan klasifikasi pada kelas negatif, yang pada beberapa model CNN *transfer learning* masih menjadi kelemahan akibat *inbalance data*. Dengan capaian

metrik tersebut, *Swin Transformer* menunjukkan kemampuan generalisasi yang lebih stabil pada skenario multi-kelas dan berpotensi digunakan sebagai sistem pendukung keputusan (*decision support system*) untuk membantu tenaga medis dalam proses diagnosis lesi kulit, meskipun tidak dimaksudkan untuk menggantikan peran tenaga medis sepenuhnya.

3. Ketiga, hasil penelitian menunjukkan bahwa penanganan *inbalance* data memiliki pengaruh yang signifikan terhadap performa model. Penerapan teknik augmentasi + *class weight* terbukti mampu meningkatkan performa model secara konsisten dibandingkan model tanpa *balancing*, di mana nilai *accuracy* meningkat dari 87,32% menjadi 88,77%, *precision* meningkat dari 80,15% menjadi 83,28%, *sensitivity* meningkat dari 76,18% menjadi 83,42%, *specificity* meningkat dari 96,87% menjadi 97,07%, serta *F1-score* meningkat dari 77,51% menjadi 83,10%, dengan AUC yang juga meningkat dari 98,94% menjadi 99,04%. Peningkatan ini menunjukkan bahwa augmentasi + *class weight* mampu memperbaiki keseimbangan performa model baik dalam mengenali kelas mayoritas maupun minoritas.

Sebaliknya, penerapan teknik *class weight* tanpa augmentasi justru menyebabkan penurunan performa model pada seluruh metrik evaluasi. Hal ini ditunjukkan oleh penurunan nilai *accuracy* menjadi 86,27%, *precision* menjadi 80,91%, *sensitivity* menjadi 74,35%, serta *F1-score* menjadi 77,13%, meskipun nilai *specificity* masih mencapai 96,04% dan AUC sebesar 98,61%. Kondisi ini mengindikasikan bahwa pemberian bobot kelas yang berlebihan dapat menyebabkan model terlalu fokus pada kelas minoritas, sehingga meningkatkan jumlah FP dan menurunkan kemampuan generalisasi model.

Selanjutnya sekma dengan augmentasi menghasilkan performa yang lebih baik dibandingkan penggunaan *class weight* saja, dengan nilai *accuracy* tertinggi sebesar 88,87%, *precision* sebesar 85,76%, *sensitivity* sebesar 80,05%, *specificity* sebesar 96,98%, serta *F1-score* sebesar 82,65% dan AUC sebesar 99,05%. Namun demikian, nilai *F1-score* yang diperoleh masih lebih rendah dibandingkan penggunaan augmentasi + *class weight*. Oleh karena itu, dapat disimpulkan bahwa augmentasi + *class weight* merupakan strategi *balancing* yang paling efektif pada penelitian ini dalam meningkatkan performa model secara menyeluruh.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran dapat diajukan untuk pengembangan penelitian selanjutnya.

1. Penelitian selanjutnya disarankan untuk menggunakan dataset dengan jumlah data yang lebih besar atau menerapkan variasi teknik augmentasi data yang lebih beragam, seperti rotasi dengan sudut yang bervariasi, perubahan intensitas pencahayaan, serta augmentasi berbasis warna dan tekstur. Penggunaan data yang lebih besar dan bervariasi diharapkan dapat meningkatkan kemampuan generalisasi model dalam mengklasifikasikan lesi kulit, terutama pada kelas dengan jumlah data terbatas. Selain itu, variasi augmentasi yang lebih kompleks dapat membantu model dalam mengenali pola visual lesi kulit yang beragam sehingga performa klasifikasi menjadi lebih stabil pada data baru.
2. Penelitian berikutnya juga disarankan untuk mengeksplorasi berbagai varian arsitektur *Swin Transformer*, seperti perbedaan ukuran *window attention*, jumlah *layer*, serta penggunaan varian model dengan kapasitas yang lebih besar. Evaluasi terhadap variasi arsitektur ini penting dilakukan untuk mengetahui konfigurasi *Swin Transformer* yang paling optimal dalam klasifikasi lesi kulit multi-kelas. Selain itu, penelitian lanjutan dapat mempertimbangkan penggunaan *pretrained* model yang dilatih pada domain medis atau penggabungan *Swin Transformer* dengan pendekatan lain, seperti *ensemble learning*, guna meningkatkan kinerja model, khususnya pada metrik *sensitivity* dan *f1-score*.
3. Selain itu, untuk mendukung penerapan hasil penelitian dalam konteks nyata, disarankan agar penelitian selanjutnya mengembangkan sistem antarmuka pengguna (*user interface*) yang terintegrasi dengan model klasifikasi. Sistem ini dapat dirancang agar mampu menampilkan hasil prediksi, tingkat kepercayaan model, serta visualisasi pendukung seperti *attention map* atau *heatmap*. Pengembangan antarmuka yang informatif dan mudah digunakan diharapkan dapat membantu tenaga medis dalam memahami hasil klasifikasi, sehingga sistem yang dikembangkan dapat berfungsi secara optimal sebagai sistem pendukung keputusan diagnosis lesi kulit.

DAFTAR PUSTAKA

- Abreu-Velez, A. M., Gao, W., & Howard, M. S. (2018). Patients Affected by Endemic Pemphigus Foliaceus in Colombia, South America Exhibit Autoantibodies to Optic Nerve Sheath Envelope Cell Junctions. *Dermatology Practical & Conceptual*, 8(1).doi: 10.5826/dpc.0801a01
- Agus, I. P., Hidjah, K., Sulistianingsih, N., Hendro, G., & Syahrir, S. (2025). Implementasi Arsitektur Deep Convolutional Neural Network (CNN) dengan Transfer Learning untuk Klasifikasi Penyakit Kulit. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 7(3), 461–477. doi:10.35746/jtim.v7i3.734
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-Generation Hyperparameter Optimization Framework. *arXiv preprint*. doi:10.48550/arXiv.1907.10902
- Aksoy, S., Demircioglu, P., & Bogrekci, I. (2025). Deep Learning-Based Web Application for Automated Skin Lesion Classification and Analysis. *Dermato*, 5(2), 7. doi:10.3390/dermato5020007
- Aksoy, S., Demircioglu, P., & Bogrecki, I. (2024). Enhancing Melanoma Diagnosis with Advanced Deep Learning Models Focusing on Vision Transformer, Swin Transformer, and ConvNeXt. *Dermatopathology*, 11, 239–252. doi:10.3390/dermatopathology11030026
- Ali, K., Shaikh, Z. A., Khan, A. A., & Laghari, A. A. (2022). *Multiclass Skin Cancer Classification using EfficientNets – A First Step Towards Preventing Skin Cancer*. *Neuroscience Informatics*, 2(4), 100034. Elsevier. doi: 10.1016/j.neuri.2021.100034
- An, Q., Rahman, S., Zhou, J., & Kang, J. J. (2023). A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. *Sensors*, 23(9), 4178. doi:10.3390/s23094178

- Andika, D., & Darwis, D. (2021). Modifikasi Algoritma GifShuffle untuk Peningkatan Kualitas Citra pada Steganografi. *Jurnal Ilmiah Infrastruktur Teknologi Informasi (JIITI)*, 1(2), 19–23. doi: 10.33365/jiiti.v1i2.614
- Annisa. (2025). *Pengelolaan Citra Digital: Pengertian, jenis, dan Contohnya*. Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara. Diakses 12 November 2025 dari <https://fikt.umsu.ac.id/>
- Arulanathan, S., Prakash, S. W., Ayyasamy, R. K., Kavitha, V. P., Kuppusamy, P. G., & Chinnasamy, P. (2024). *Classification of Paediatric Pneumonia Using Modified DenseNet-121 Deep-Learning Model*. *IEEE Access*, 12, 35716–35727. IEEE. doi: 10.1109/ACCESS.2024.3371151
- Ayash, L., Algarni, A., & Alqahtani, O. (2025). Advancements in Feature Selection and Extraction Methods for Text Mining: A Review. *Discover Applied Sciences*, 7, 914. doi:10.1007/s42452-025-07587-w
- Azimi, A., & Fernandez-Peñas, P. (2023). Molecular Classifiers in Skin Cancers: Challenges and Promises. *Cancers*, 15, 4463. doi:10.3390/cancers15184463
- Badan Pengawas Obat dan Makanan. (2025). *BPOM Intensifkan Pengawasan: Rp31,7 Miliar Kosmetik Ilegal Ditemukan, Influencer Diminta Hati-Hati dalam Promosi*. Diakses 14 November 2025 dari <https://www.pom.go.id/>
- Balcere, A., Konrāde-Jilmaza, L., Pauliņa, L. A., Čēma, I., & Krūmiņa, A. (2022). Clinical Characteristics of Actinic Keratosis Associated with the Risk of Progression to Invasive Squamous Cell Carcinoma: A Systematic Review. *Journal of Clinical Medicine*, 11, 5899. doi:10.3390/jcm11195899
- Bamidele, O. D., Kayode, B. A., Eniaiyewu, O. I., dkk. (2023). Quality Assessment of Hydroquinone, Mercury, and Arsenic in Skin-Lightening Cosmetics Marketed in Ilorin, Nigeria. *Scientific Reports*, 13, 20992. doi:10.1038/s41598-023-47160-2
- Bao, C. (2023). Image Classification under Class-Imbalanced Situation. *Highlights in Science, Engineering and Technology*, 39, 465–474. doi:10.54097/hset.v39i.6570
- Bello, A., Ng, S.-C., & Leung, M.-F. (2024). Skin Cancer Classification Using Fine-Tuned Transfer Learning of DenseNet-121. *Applied Sciences*, 14, 7707. doi:10.3390/app14177707

- Belmourida, S., Meziane, M., Ismaili, N., Benzekri, L., & Senouci, K. (2021). Giant Seborrheic Keratoses: An Historical Case. *Clinical Medical Image Library*, 7(3), 174. doi:10.23937/2474-3682/1510174
- Brutti, F., La Rosa, F., Lazzeri, L., dkk. (2023). Artificial Intelligence Algorithms for Benign vs. Malignant Dermoscopic Skin Lesion Image Classification. *Bioengineering*, 10, 1322. doi:10.3390/bioengineering10111322
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., dkk. (2020). Albumentations: Fast and flexible image augmentations. *Information*, 11(2), 125. doi:10.3390/info11020125
- Candra, A. P. (2025). Analisis Data Menggunakan Python: Memperkenalkan Pandas dan NumPy. *Journal of Information System and Education Development*, 3(1). doi:10.62386/jised.v3i1.118
- Castillo-Rangel, C., Marín, G., Hernandez-Contreras, K. A., Zarate-Calderon, C., Vichi-Ramirez, M. M., Cortez-Saldias, W., Rodriguez-Florido, M. A., Riley-Moguel, Á. E., Pichardo, O., Torres-Pineda, O., dkk. (2022). Atlas of Nervous System Vascular Malformations: A Systematic Review. *Life*, 12, 1199. doi:10.3390/life12081199
- Chan, K. Y., Abu-Salih, B., Qaddoura, R., Al-Zoubi, A. M., Palade, V., Pham, D.-S., Del Ser, J., & Muhammad, K. (2023). Deep Neural Networks in The Cloud: Review, Applications, Challenges and Research Directions. *Neurocomputing*, 545, 126327. doi:10.1016/j.neucom.2023.126327
- Chiu, T.-M., Chi, I.-C., Li, Y.-C., & Tseng, M.-H. (2025). Deep Ensemble Learning for Multiclass Skin Lesion Classification. *Bioengineering*, 12, 934. doi:10.3390/bioengineering12090934
- Chmiel, P., Kosińska, M., Forma, A., Pelc, Z., Geca, K., & Skórzewska, M. (2022). Novel Approaches in Non-melanoma Skin Cancers: A Focus on Hedgehog Pathway in Basal Cell Carcinoma (BCC). *Cells*, 11, 3210. doi:10.3390/cells11203210
- Choi, A., & Oakley, A. (2021). A Retrospective Review of Cutaneous Vascular Lesions Referred to A Teledermatology Clinic. *Journal of Primary Health Care*, 13(1), 70–74. doi:10.1071/HC20046
- Costeris, C., Petridou, M., & Ioannou, Y. (2021). Psychological Impact of Skin Disorders on Patients' Self-Esteem and Perceived Social Support. *Journal of*

- Dermatology & Skin Science*, 3(1), 14–22. <https://www.heighpubs.org/hjdss/>
- Dimililer, K., & Sekeroglu, B. (2023). Skin Lesion Classification Using CNN-Based Transfer Learning Model. *Gazi University Journal of Science*, 36(2), 660–673. doi:10.35378/gujs.1063289
- Fahmi, M. N. (2023). Implementasi Machine Learning Menggunakan Python Library: Scikit-Learn (Supervised dan Unsupervised Learning). *Sains Data: Jurnal Studi Matematika dan Teknologi*, 1(2), 87–96. doi:10.52620/sainsdata.v1i2.31
- Fernandez-Flores, A., Cassarino, D., & Colmenero, I. (2023). Vascular Malformations: A Histopathologic and Conceptual Appraisal. *Actas Dermo-Sifiliográficas*, 114, 213–228. doi:10.1016/j.ad.2022.10.035
- Fitriani, F., Faisol, A., Nuryaman, A., Kurniasari, D., & Utami, B. H. S. (2024). Pelatihan L^AT_EX Menggunakan Overleaf untuk Meningkatkan Kemampuan Penulisan Karya Ilmiah bagi Dosen di Pringsewu. *Jurnal Pengabdian Kepada Masyarakat (JPKM) TABIKPUN*, 5(3). doi:10.23960/jpkmt.v5i3.184
- Frederich, J., Himawan, J., dan Rizkinia, M. (2024). Skin Lesion Classification using EfficientNet B0 and B1 Via Transfer Learning for Computer Aided Diagnosis. *AIP Conference Proceedings*, 3080(1), 110002. doi:10.1063/5.0200741
- Gambini, D., Passoni, E., Nazzaro, G., Beltramini, G., Tomasello, G., Ghidini, M., Kuhn, E., & Garrone, O. (2022). Basal Cell Carcinoma and Hedgehog Pathway Inhibitors: Focus on Immune Response. *Frontiers in Medicine*, 9, 893063. doi:10.3389/fmed.2022.893063
- GeeksforGeeks. (2023). *Splitting Data for Machine Learning Models*. Diakses 12 November 2025 dari <https://www.geeksforgeeks.org/machine-learning/splitting-data-for-machine-learning-models/>
- Giudici, P., Schrader, J., Rosciano, R. C., & Kummerfeld, D.-M. (2025). *A Multiclass ROC Curve*. arXiv:2510.15670v1 [stat.ME]. doi: 10.48550/arXiv.2510.15670
- Guerrero, R. E. D., Carvalho, L., Bocklitz, T., Popp, J., & Oliveira, J. L. (2024). A Data Augmentation Methodology to Reduce the Class Imbalance in Histopathology Images. *Journal of Imaging Informatics in Medicine*, 37, 1767–1782. doi:10.1007/s10278-024-01018-9

- Hakim, H. B., Utaminingrum, F., & Setia Budi, A. (2021). Early Detection of COVID-19 Patients' Survivability Based on Lung X-Ray Images Using Deep Neural Networks. *Kinetik*, 6(3), 249–258. doi:10.22219/kinetik.v6i3.1265
- Hafeez, A., & Sial, A. H. (2021). Comparative Analysis of Data Visualization Libraries Matplotlib and Seaborn in Python. *International Journal of Advanced Trends in Computer Science and Engineering*, 10(1), 2770–281. doi:10.30534/ijatcse/2021/391012021
- Harrison, K. (2024). The Accuracy of Skin Cancer Detection Rates with the Implementation of Dermoscopy among Dermatology Clinicians: A Scoping Review. *Journal of Clinical and Aesthetic Dermatology*, 17(9–10 Suppl 1), S18–S27. PMID: 39386002. <https://pubmed.ncbi.nlm.nih.gov/39386002/>
- Hasan, S. N. (2024). Accurate Deep Learning Algorithms for Skin Lesion Classification. *Ingénierie des Systèmes d'Information*, 29(4), 1529–1539. doi:10.18280/isi.290426
- He, S. M., & Wen, Z. (2024). A Clinical and Histopathological Analysis of 147 Cases of Dermatofibroma (Benign Fibrous Histiocytoma). *Advances in Bioscience and Biotechnology*, 15, 590–601. doi:10.4236/abb.2024.1510037
- Hitchcock, J. A., Hundertmark, M., Foreman-Mackey, D., Bachelet, E., Dominik, M., Street, R., & Tsapras, Y. (2021). PyTorchDIA: A Flexible, GPU-Accelerated Numerical Approach to Difference Image Analysis. *Monthly Notices of the Royal Astronomical Society*, 504(3), 3561–3579. doi:10.1093/mnras/stab1114
- Huang, Y., Zhang, Z., Ran, X., Zhuang, K., & Ran, Y. (2025). An Ingeniously Designed Skin Lesion Classification Model across Clinical and Dermatoscopic Datasets. *Diagnostics*, 15, 2011. doi:10.3390/diagnostics15162011
- Ilembayo, J. A., Durodola, O., Alade, O., Awotunde, O. J., Olanrewaju, A. T., Falana, O., Ogungbire, A., Osinuga, A., Ogundiyi, D., Ifeanyi, A., Odezulgb, I., & Edu, O. E. (2024). Hyperparameter Tuning in Machine Learning: A Comprehensive Review. *Journal of Engineering Research and Reports*, 26(6), 389–395. doi:10.9734/jerr/2024/v26i61188
- International Agency for Research on Cancer (IARC). (2024). *Indonesia Country Fact Sheet: GLOBOCAN 2022*. Diakses 14 November 2025 dari

<https://gco.iarc.who.int/media/globocan/factsheets/populations/360-indonesia-fact-sheet.pdf>

- Jin, R., Luo, L., & Zheng, J. (2022). The Trinity of Skin: Skin Homeostasis as a Neuro–Endocrine–Immune Organ. *Life*, 12(7), 725. doi:10.3390/life12050725
- Joseph, V. R. (2022). Optimal Ratio for Data Splitting. *arXiv preprint*, arXiv:2202.03326. doi: 10.1002/sam.11583
- Kaya, K. Z., Kaya, Ö., Mermutlu, S. I., Karaemir, H. G., & Kılıç, S. O. (2025). Clinical and Dermoscopic Patterns of Acquired Melanocytic Nevi in Children and Adolescents: A Cross-Sectional Study from Turkey. *Anais Brasileiros de Dermatologia*, 100(1), 22–30. doi:10.1016/j.abd.2024.04.005
- Kurniasari, D., Pratama, M. D., Junaidi, A., & Faisol, A. (2025). Transforming Alzheimer’s Disease Diagnosis: Implementing Vision Transformer (ViT) for MRI Image Classification. *Journal of Information and Communication Technology*, 24(1), 130–152. doi:10.32890/jict2025.24.1.6
- Lahbacha, B., Nechi, S., Chaabane, A., Bani, A., Kchaou, M., Chtourou, F., Mfarrej, M. K., Dougaz, A., & Chelbi, E. (2024). Seborrheic Keratosis: Report of a Rare Presentation and Reminder of Current Knowledge. *Clinical Pathology*, 17, 1–6. doi:10.1177/2632010X241255874
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 10012–10022. doi:10.48550/arXiv.2103.14030
- Liao, J., Lam, H.-K., Gulati, S., & Hayee, B. (2023). *Improved Computer-Aided Diagnosis System using Contrastive Self-Supervised Learning. International Journal of Network Dynamics and Intelligence*, 2(3). doi: 10.53941/ijnidi.2023.100010
- Lopes, J., Rodrigues, C. M. P., Gaspar, M. M., & Reis, C. P. (2022). Melanoma Management: From Epidemiology to Treatment and Latest Advances. *Cancers*, 14, 4652. doi:10.3390/cancers14194652
- Lu, M. D., Usatine, R., Holt, J., Harper, D. M., & Verdick, A. (2023). Dermoscopy Training in Family Medicine Residencies: A CERA Survey of Program Directors. *Family Medicine*, 55(4), 259–262. doi:10.22454/FamMed.2023.368813

- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification. *Technologies*, 9(4), 81. doi:10.3390/technologies9040081
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information*, 15(12), 755. doi:10.3390/info15120755
- Miller, J. S., Bennett, N. E., & Rhoades, J. A. (2023). Targeting Hedgehog-Driven Mechanisms of Drug-Resistant Cancers. *Frontiers in Molecular Biosciences*, 10, 1286090. doi:10.3389/fmolb.2023.1286090
- Muddebihal, A., Khatoon, A., & Mohanty, S. (2024). Is Seborrheic Keratosis Really Benign? A Case Report of Seborrheic Keratosis with Malignant Transformation. *Indian Journal of Dermatology*, 69(1), 89–90. doi:10.4103/ijd.ijd_735_23
- Muhaba, K. A., Dese, K., Aga, T. M., Zewdu, F. T., & Simegn, G. L. (2022). Automatic Skin Disease Diagnosis Using Deep Learning from Clinical Image and Patient Information. *Skin Health and Disease*, 2(1), ski2.81. doi:10.1002/ski2.81
- Murcia-Gómez, D., Rojas-Valenzuela, I., & Valenzuela, O. (2022). Impact of Image Preprocessing Methods and Deep Learning Models for Classifying Histopathological Breast Cancer Images. *Applied Sciences*, 12(11), 11375. doi:10.3390/app122211375
- Musthafa, M. M., Mahesh, T. R., Vinoth Kumar, V., & Guluwadi, S. (2024). Enhanced Skin Cancer Diagnosis Using Optimized CNN Architecture and Checkpoints for Automated Lesion Classification. *BMC Medical Imaging*, 24, 201. doi:10.1186/s12880-024-01356-8
- Muto, Y., Fujimura, T., & Asano, Y. (2025). Recent Advances in Immunotherapy for Melanoma: Perspectives on Novel Treatment Development. *Cancers*, 17, 2265. doi:10.3390/cancers17132265
- Myers, D. J., & Fillman, E. P. (2024). *Dermatofibroma*. In *StatPearls [Internet]*. Treasure Island (FL): StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK470538/>
- Nafiah, S. R., Fitraneti, E., Rizal, Y., Primawati, I., & Hamama, D. A. (2023). Pengaruh Paparan Sinar Ultraviolet terhadap Kesehatan Kulit dan

- Upaya Pencegahannya: Tinjauan Literatur. *Scientific Journal*, 3(3), 185–192. doi:10.56260/sciena.v3i3
- Nguyen, V. D., Bui, N. D., & Do, H. K. (2022). Skin Lesion Classification on Imbalanced Data Using Deep Learning with Soft Attention. *Sensors*, 22, 7530. doi:10.3390/s22197530
- Olle, G. O., Evina, H. K., Aminou, H., & Medzo, C. A. (2025). A Method for Detecting Skin Cancer Disease Based on Deep Learning in Dermoscopic Images. *Journal of Computer and Communications*, 13, 138–155. doi:10.4236/jcc.2025.133010
- Octarina, S., Puspita, F. M., Yuliza, E., & Indrawati. (2025). Pendampingan Penggunaan Google Colab pada Pembelajaran Python dan Machine Learning bagi Dosen Matematika di Palembang. *Jurnal Pepadu*, 6(1). doi:10.29303/pepadu.v6i1.6457
- Pablo, I., Marwa, Z., Helmut, B., & Laurence, F. (2025). Basaloid Cell Hyperplasia Overlying Dermatofibroma. *Dermatopathology*, 12, 36. doi:10.3390/dermatopathology12040036
- Pacal, I., Alaftekin, M., & Zengul, F. D. (2024). Enhancing Skin Cancer Diagnosis Using Swin Transformer with Hybrid Shifted-Window Attention and SwiGLU-Based MLP. *Journal of Imaging Informatics in Medicine*, 37, 3174–3192. doi:10.1007/s10278-024-01140-8
- Patel, K., & Nixon, R. (2022). Irritant Contact Dermatitis: A Review. *Current Dermatology Reports*, 11, 41–51. doi:10.1007/s13671-021-00351-4
- Piatek, L. (2023). Analysis of Skin Lesions and Disease Types in Everyday Infections. *Prime Scholars – Dermatology*, 9(1). doi:10.36648/2472-0143.9.1.03
- Pino, E., Benítez, C., Aristizábal, C., Orozco, L., Rincón, O., Jiménez, M., & Aristizábal, B. (2023). Frequency of BRAFV600E/E2/D and V600K/R/M Mutations in Patients with Unresectable Malignant Melanoma Stages III–IV. *International Journal of Molecular Biology Open Access*, 6(1).
- Prasetya, M. I., Yadi, I. Z., Kunang, Y. N., & Permatasari, S. D. (2025). Prapemrosesan untuk Klasifikasi Gambar Aksara OKU Timur. *Jurnal Teknologi dan Sistem Informasi Bisnis (JTEKSIS)*, 7(1), 208–215. doi:10.47233/jteksis.v7i1.1629

- Prastyo, A. B., Anggraeny, F. T., & Mumpuni, R. (2025). Kidney Stone Disease Diagnosis Using Shifted Windows Transformer (Swin Transformer). *JATI EMAS*, 9(4). doi:10.12345/je.v9i4.383
- Pro, S. (2025, 29 Juni). *Windows 10 Pro: Fitur, Keunggulan, dan Kelebihannya untuk Profesional*. Rintiksedu.id. Diakses 14 November 2025 dari <https://rintiksedu.id/windows-10-pro/>
- Purnomo, N., Suri, R. M., Yuliana, D., & Rasyid, M. (2023). Sistem Pakar Identifikasi Penyakit Kulit Melanoma dengan Metode Teorema Bayes. *Jurnal KomtekInfo*, 10(2). doi:10.35134/komtekinfo.v10i2.368
- Ranjeet, K., Saha, S., & Ratnakumari, M. (2024). Skin Cancer Detection Using Swin Transformer Model. *SSRN Electronic Journal*. doi:10.2139/ssrn.5292024
- Rom, A. R. M., Jamil, N., & Ibrahim, S. (2024). Multi-Objective Hyperparameter Tuning via Random Search on Deep Learning Models. *TELKOMNIKA*, 22(4), 956–968. doi:10.12928/TELKOMNIKA.v22i4.25847
- Rong, C. (2024). *Skin Cancer Classification via Machine Learning*. The National High School Journal of Science (NHSJS). Tersedia secara daring: <https://nhsjs.com/2024/skin-cancer-classification-via-machine-learning/>
- Russo, T., Piccolo, V., Moscarella, E., Tschandl, P., Kittler, H., Paoli, J., Lallas, A., Braun, R. P., Thomas, L., Soyer, H. P., Malvey, J., Puig, S., Marghoob, A., Scope, A., Blum, A., Halpern, A. C., Cabo, H., Menzies, S., Stolz, W., Tanaka, M., dkk. (2022). Indications for Digital Monitoring of Patients with Multiple Nevi: Recommendations from the International Dermoscopy Society. *Dermatology Practical & Conceptual*, 12(4), e2022182. doi:10.5826/dpc.1204a182
- Saifullah, S., Agne, S., Dengel, A., & Ahmed, S. (2023). Analyzing the Potential of Active Learning for Document Image Classification. *International Journal on Document Analysis and Recognition*, 26, 187–209. doi:10.1007/s10032-023-00429-8
- Salem, A. M., Eyupoglu, S. Z., & Ma'aitah, M. K. (2024). The Influence of Machine Learning on Enhancing Rational Decision-Making and Trust Levels in E-Government. *Systems*, 12(9), 373. doi:10.3390/systems12090373
- Sarfraz, M. (2020). Introductory Chapter: On Digital Image Processing. In *Digital Imaging*. IntechOpen. doi:10.5772/intechopen.92060

- Sathyanarayanan, S., & Tantri, B. R. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 27(4s), 4023–4031. doi:10.53555/AJBR.v27i4S.4345
- Scikit-learn Developers. (2025). *Compute_Class_Weight: Compute Class Weights for Unbalanced Datasets*. Diakses 14 November 2025 dari https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html
- Septhya, D., Rahmaddeni, R., Susanti, S., & Agustin, A. (2024). Penerapan Algoritma Convolutional Neural Network untuk Klasifikasi Penyakit Kanker Kulit. *The Indonesian Journal of Computer Science*, 13(4), 1–7. doi:10.33022/ijcs.v13i4.4262
- Senalasari, W., Maulidani, R. N., Setiawati, L., & Najib, M. F. (2025). From Reviews to Purchase Intention: The Interplay of Customer Review, Influencer Review, and Trust in Indonesian Skincare Products. *Journal of Marketing Innovation*, 5(1). doi:10.35313/jmi.v5i1.184
- Septyana, A. P., & Fauzi, E. (2025). Implementasi Metode Naive Bayes Classifier dalam Menentukan Diagnosa Kerusakan pada Smartphone. *Jurnal Sistem Komputer dan Informatika (JSON)*, 7(1), 86–93. doi:10.30865/json.v7i1.8926
- Shah, K., Shah, S., Shah, V., & Godbole, A. (2025). Optimization of Data Splitting Methods for Machine Learning. *Proceedings of the International Conference on Innovative Computing & Communication (ICICC 2024)*. SSRN:5190348.
- Shetty, B., Fernandes, R., Rodrigues, A. P., Chengoden, R., Bhattacharya, S., & Lakshmana, K. (2022). Skin Lesion Classification of Dermoscopic Images Using Machine Learning and Convolutional Neural Network. *Scientific Reports*, 12, 18134. doi:10.1038/s41598-022-22644-9
- Shreberk-Hassidim, R., Ostrowski, S. M., & Fisher, D. E. (2023). The Complex Interplay Between Nevi and Melanoma: Risk Factors and Precursors. *International Journal of Molecular Sciences*, 24(5), 3541. doi:10.3390/ijms24043541
- Soares, A. M. S., Pereira, J. B., & de LaPeña, R. M. (2023). Actinic Keratosis – Lesions Behind the Mask. *Rural and Remote Health*, 23(1), 8113. doi:10.22605/RRH8113

- Subaşı, N. (2024). Comprehensive Analysis of Grid and Randomized Search on Dataset Performance. *European Journal of Engineering and Applied Sciences*, 7(2), 77–83. doi:10.55581/ejeas.1581494
- Surbakti, N. M., Angelyca, A., Talia, A., Perangin-Angin, C. B., Nainggolan, O., Friskauly, N. D., & Tumorang, S. R. B. (2024). Penggunaan Bahasa Pemrograman Python dalam Pembelajaran Kalkulus Fungsi Dua Variabel. *Algoritma: Jurnal Matematika, Ilmu Pengetahuan Alam, Kebumihan dan Angkasa*, 2(3), 98–107. doi:10.62383/algoritma.v2i3.67
- Tang, K., Su, J., Chen, R., Huang, R., Dai, M., & Li, Y. (2024). SkinSwinViT: A Lightweight Transformer-Based Method for Multiclass Skin Lesion Classification with Enhanced Generalization Capabilities. *Applied Sciences*, 14, 4005. doi:10.3390/app14104005
- Trojaniello, C., Sparano, F., Cioli, E., & Ascierto, P. A. (2023). Sequencing Targeted and Immune Therapy in *BRAF*-Mutant Melanoma: Lessons Learned. *Current Oncology Reports*, 25, 623–634. doi:10.1007/s11912-023-01402-8
- Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 Dataset: A Large Collection of Multi-Source Dermatoscopic Images of Common Pigmented Skin Lesions. *Scientific Data*, 5, 180161. doi:10.1038/sdata.2018.161
- Vallini, G., Calabrese, L., Canino, C., Trovato, E., Gentileschi, S., Rubegni, P., & Tognetti, L. (2023). Signaling Pathways and Therapeutic Strategies in Advanced Basal Cell Carcinoma. *Cells*, 12, 2534. doi:10.3390/cells12212534
- Wang, M., Gao, X., & Zhang, L. (2024). Recent Global Patterns in Skin Cancer Incidence, Mortality, and Prevalence. *Chinese Medical Journal*, 137(5), 1–8. doi:10.1097/CM9.00000000000003416
- Waseh, S., & Lee, J. B. (2023). Advances in Melanoma: Epidemiology, Diagnosis, and Prognosis. *Frontiers in Medicine*, 10, 1268479. doi:10.3389/fmed.2023.1268479
- Wightman, R., Touvron, H., & Jégou, H. (2021). ResNet Strikes Back: An Improved Training Procedure in TIMM. *arXiv preprint*, arXiv:2110.00476. doi:10.48550/arXiv.2110.00476
- Yilmaz, A., Gencoglan, G., Varol, R., Demircali, A. A., Keshavarz, M., & Uvet, H. (2022). MobileSkin: Classification of Skin Lesion Images Acquired Using

Mobile Phone-Attached Hand-Held Dermoscopes. *Journal of Clinical Medicine*, 11, 5102. doi:10.3390/jcm11175102

Zhang, H., & Qie, Y. (2023). Applying Deep Learning to Medical Imaging: A Review. *Applied Sciences*, 13(18), 10521. doi:10.3390/app131810521

Zhu, D., Huang, X., Huang, H., Shao, Z., & Cheng, Q. (2024). ChangeViT: Unleashing Plain Vision Transformers for Change Detection. *arXiv preprint*, arXiv:2406.12847. doi: 10.48550/arXiv.2406.12847