

**TESIS**

**ANALISIS PERBANDINGAN METODE CNN DAN CNN-SVM  
UNTUK KLASIFIKASI MULTI-KELAS JENIS  
PENYAKIT KULIT MANUSIA**



Disusun oleh:

**Nama : Dendi Anggrlandi**  
**NIM : 21.51.2095**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2024**

**TESIS**

**ANALISIS PERBANDINGAN METODE CNN DAN CNN-SVM  
UNTUK KLASIFIKASI MULTI-KELAS JENIS  
PENYAKIT KULIT MANUSIA**

**COMPARATIVE ANALYSIS OF CNN AND CNN-SVM METHODS FOR  
MULTI-CLASS CLASSIFICATION TYPES OF  
HUMAN SKIN DISEASES**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

**Nama : Dendi Anggrlandi**  
**NIM : 21.51.2095**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2024**

**HALAMAN PENGESAHAN**

**ANALISIS PERBANDINGAN METODE CNN DAN CNN-SVM UNTUK  
KLASIFIKASI MULTI-KELAS JENIS PENYAKIT KULIT MANUSIA**

**COMPARATIVE ANALYSIS OF CNN AND CNN-SVM METHODS FOR MULTI-  
CLASS CLASSIFICATION TYPES OF HUMAN SKIN DISEASES**

Diperiapkan dan Disusun oleh

**Dendi Anggriandi**

**21.51.2095**

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Senin, 8 Januari 2024

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 8 Januari 2024

**Rektor**

**Prof. Dr. M. Suyanto, M.M.**  
**NIK. 190302001**

## HALAMAN PERSETUJUAN

### ANALISIS PERBANDINGAN METODE CNN DAN CNN-SVM UNTUK KLASIFIKASI MULTI-KELAS JENIS PENYAKIT KULIT MANUSIA

### COMPARATIVE ANALYSIS OF CNN AND CNN-SVM METHODS FOR MULTI- CLASS CLASSIFICATION TYPES OF HUMAN SKIN DISEASES

Dipersiapkan dan Disusun oleh

**Deadi Anggriandi**

21.51.2095

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari senin, 8 januari 2024


Pembimbing Utama

  
Prof. Dr. Ema Utami, S.Si., M.Kom.  
NIK. 190302037

Anggota Tim Penguji

  
Hanif Al Fatta, M.Kom., Ph.D.  
NIK. 190302096

Pembimbing Pendamping

  
Dhan Ariamanto, M.Kom., Ph.D.  
NIK. 190302197

  
Hanafi, S.Kom., M.Eng., Ph.D.  
NIK. 190302024

  
Prof. Dr. Ema Utami, S.Si., M.Kom.  
NIK. 190302037

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 8 januari 2024

Direktur Program Pascasarjana

  
Prof. Dr. Kusriani, M.Kom.  
NIK. 190302196



## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Dendi Angriandi  
NIM : 21.51.2095  
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:  
**Analisis Perbandingan Metode CNN dan CNN-SVM Untuk Klasifikasi Multi-Kelas Jenis Penyakit Kulit Manusia**

Dosen Pembimbing Utama : Prof. Dr. Ema Utami, S.Si., M.Kom  
Dosen Pembimbing Pendamping : Dhanu Ariatmanto, M.Kom., Ph.D.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 8 Januari 2024  
Yang Menyatakan,



Dendi Angriandi

## HALAMAN PERSEMBAHAN

Dengan segala puji dan syukur kepada Allah Subhanahu Wa Ta'ala atas segala berkat, rahmat, hidayah dan karunia-Nya, penulis dapat menyelesaikan penulisan tesis ini dengan penuh perjuangan. Tesis ini dapat diselesaikan atas doa, dukungan, bantuan serta bimbingan dari berbagai pihak. Dalam kesempatan ini dengan segala kerendahan hati, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Kedua orang tua saya Bapak Purwanto dan Ibu Nurlia, serta seluruh keluarga yang tidak pernah berhenti mendoakan dan memberikan dukungannya selama ini.
2. Terima kasih kepada diri saya sendiri atas pencapaian melewati satu ujian kehidupan yang membawa saya menuju masa depan yang lebih baik
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom., selaku Dosen Pembimbing 1 yang telah memberikan bimbingan, saran, kritik, dan motivasi kepada penulis sehingga tesis ini dapat selesai.
4. Bapak Dhani Ariatmanto, M.Kom., Ph.D., selaku Dosen Pembimbing 2 yang telah memberikan arahan dan masukan selama penulisan tesis ini.
5. Desy Kumalasari, S.Sos., yang telah menjadi motivasi bagi saya untuk menyelesaikan tesis ini, dan semoga tetap menjadi dorongan untuk menjadi pribadi yang lebih baik di masa depan.
6. Teman-teman MTI Angkatan 27 kelas A yang telah memberikan semangat, saran, masukan dan pengalaman yang tak ternilai.
7. Semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah memberikan bantuan berupa moril maupun materil, sehingga Tesis ini dapat diselesaikan.



## HALAMAN MOTTO

"Berdoalah seolah-olah segala sesuatu bergantung pada Allah, dan kerjakanlah seolah-olah segala sesuatu bergantung pada usahamu sendiri."

"Dengan bismillah, kita memulai segala sesuatu. Dengan tawakal, kita melepaskan segala sesuatu."

"Setiap perkara yang baik yang tidak dimulai dengan 'Bismillah', maka ia terputus (dari berkah dan kebaikan)."

(HR. Al-Khatib dalam Al-Jami')

"Kerjakanlah untuk akhiratmu seolah-olah engkau akan mati esok hari dan kerjakanlah untuk duniamu seolah-olah engkau hidup selamanya."

(Ali bin Abi Thalib)

"Jika Allah mengambil darimu sesuatu yang tidak pernah engkau sangka kehilangannya, maka Allah akan memberimu sesuatu yang tidak pernah engkau sangka akan memilikinya."

## KATA PENGANTAR

Dengan segala puji dan syukur kepada Allah Subhanahu Wa Ta'ala atas segala berkat, rahmat, hidayah dan karunia-Nya, penulis dapat menyelesaikan penulisan tesis ini yang berjudul "Analisis Perbandingan Metode CNN dan CNN-SVM Untuk Klasifikasi Multi-Kelas Jenis Penyakit Kulit Manusia". Penulis menyadari masih terdapat banyak kekurangan selama penyusunan tesis ini dan tesis ini dapat diselesaikan atas doa, dukungan, bantuan serta bimbingan dari berbagai pihak. Dalam kesempatan ini dengan segala kerendahan hati, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. M. Suyanto, MM., selaku Rektor Universitas AMIKOM Yogyakarta.
2. Ibu Prof. Dr. Kusriani, M.Kom., selaku Direktur Program Pasca Sarjana Universitas AMIKOM Yogyakarta.
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom. dan bapak Dhani Ariatmanto, M.Kom., Ph.D., selaku dosen pembimbing yang dengan sabar dalam memberikan bimbingan, arahan dan masukan selama proses penulisan naskah tesis ini.
4. Kedua Orang Tua yang tak pernah Lelah dalam memberikan dukungan dan doa selama ini.
5. Dosen AMIKOM Yogyakarta yang telah memberikan banyak ilmu dan pengalaman.



Penulis menyadari bahwa keterbatasan pengetahuan dan pengalaman yang masih jauh dari harapan dan kesempurnaan, untuk itu penulis sangat mengharapkan kritik, saran dan masukan yang bersifat membangun untuk memperbaiki penulisan tesis ini. Akhir kata, semoga apa yang telah diberikan kepada penulis baik itu segala dukungan, doa, bantuan ataupun jasa, akan mendapatkan balasan dari Allah SWT dan semoga tesis ini dapat memberikan manfaat bagi pembaca.

Yogyakarta, 8 Januari 2024

Penulis



## DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xiv
INTISARI.....	xvi
<i>ABSTRACT</i> .....	xvii
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	9
1.3. Batasan Masalah.....	9
1.4. Tujuan Penelitian.....	10
1.5. Manfaat Penelitian.....	10
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>12</b>
2.1. Tinjauan Pustaka.....	12
2.2. Keaslian Penelitian.....	17
2.3. Landasan Teori.....	22

<b>BAB III METODE PENELITIAN</b> .....	37
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	37
3.2. Metode Pengumpulan Data.....	38
3.3. Metode Analisis Data.....	38
3.4. Alur Penelitian.....	39
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN</b> .....	47
4.1. Pengumpulan Data.....	47
4.2. Preprocessing Data.....	48
4.2.1. Labeling Data.....	48
4.2.2. Augmentasi dan Balancing Data.....	48
4.2.3. Mengubah ukuran gambar.....	51
4.2.4. Mengubah dataset menjadi array.....	51
4.2.5. Membagi dataset.....	53
4.2.6. Normalisasi data.....	53
4.3. Implementasi dan Hasil Model CNN.....	54
4.3.1. Rincian Implementasi Model CNN.....	54
4.3.2. Hasil Pelatihan dan Validasi Model.....	62
4.3.3. Hasil Evaluasi Model CNN.....	63
4.3.4. Diskusi Hasil Pengujian pada Model CNN.....	66
4.4. Implementasi dan Hasil Model CNN-SVM.....	66
4.4.1. Rincian Implementasi Model CNN-SVM.....	66

4.4.2. Evaluasi Hasil Kinerja Model CNN-SVM.....	70
4.4.3. Diskusi Hasil Pengujian pada Model CNN-SVM.....	73
4.5. Perbandingan dan Analisis Hasil .....	74
4.5.1. Perbandingan Performa Antara CNN dan CNN-SVM.....	74
4.5.2. Interpretasi Hasil dan Temuan Signifikan.....	76
4.5.3. Analisis Faktor-faktor yang Mempengaruhi Performa Model .....	76
4.6. Perbandingan dengan penelitian sebelumnya .....	79
<b>BAB V PENUTUP.....</b>	<b>83</b>
5.1. Kesimpulan .....	83
5.2. Saran .....	84
<b>DAFTAR PUSTAKA .....</b>	<b>86</b>

## DAFTAR TABEL

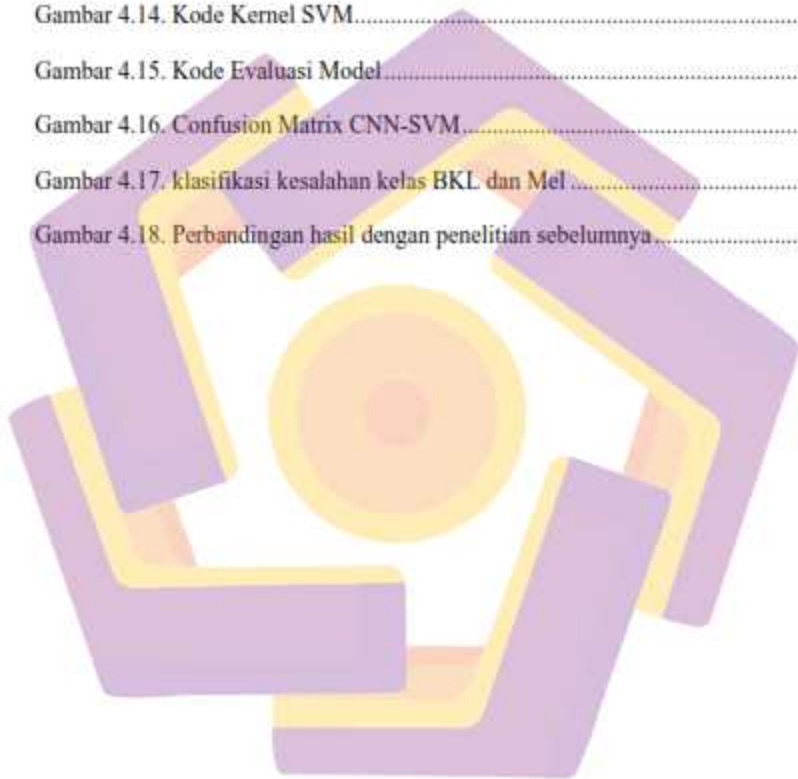
Tabel 2.1. Matriks literatur review dan posisi penelitian Analisis Perbandingan Metode CNN dan CNN-SVM untuk Klasifikasi multi-kelas Jenis Penyakit Kulit Manusia .....	17
Tabel 4.1. Rincian Dataset .....	47
Tabel 4.2. Labeling dataset .....	48
Tabel 4.3. Evaluasi Kinerja Model CNN .....	64
Tabel 4.4. Akurasi Per Kelas Model CNN .....	65
Tabel 4.5. Evaluasi Metrik Kinerja pada Data Pengujian untuk Setiap Kernel ....	71
Tabel 4.6. Evaluasi Metrik Kinerja pada Data Pelatihan untuk Setiap Kernel .....	71
Tabel 4.7. Akurasi Per Kelas Model CNN-SVM .....	72
Tabel 4.8. Perbandingan Performa Model CNN dan CNN-SVM .....	75
Tabel 4.9. Perbandingan Performa Per Kelas Model CNN dan CNN-SVM .....	75
Tabel 4.10. Perbandingan Kinerja Model Dengan Penelitian Sebelumnya .....	80

## DAFTAR GAMBAR

Gambar 2.1. Cara kerja Machine Learning .....	23
Gambar 2.2. Cara Kerja Deep Learning.....	25
Gambar 2.3. CNN arsitektur umum analisis gambar .....	26
Gambar 2.4. Contoh Proses Convolution.....	27
Gambar 2.5. Contoh Proses Pooling .....	28
Gambar 2.6. Contoh Proses <i>Fully Connected Layer</i> .....	30
Gambar 2.7. Arsitektur ResNet-50.....	31
Gambar 2.8. Sketsa pengklasifikasi linier algoritma Support Vector Machines ..	32
Gambar 2.9. Model gabungan CNN-SVM .....	33
Gambar 2.10. Confusion Matrix .....	35
Gambar 3.1. Alur Penelitian.....	40
Gambar 3.2. Model CNN-ResNet50.....	43
Gambar 3.3. Model CNN-SVM.....	45
Gambar 4.1. Kode Augmentasi.....	49
Gambar 4.2. Contoh augmentasi gambar.....	50
Gambar 4.3. Jumlah dataset sebelum dan sesudah proses blancing data.....	50
Gambar 4.4. Mengubah Ukuran Gambar.....	51
Gambar 4.5. Kode Mengubah Dataset Menjadi Array .....	52
Gambar 4.6. Kode Normalisasi Data .....	54
Gambar 4.7. Kode Modul .....	55
Gambar 4.8. Kode Membangun Model CNN .....	57
Gambar 4.9. Kode Pelatihan Model.....	59



Gambar 4.10. Kode Evaluasi Model .....	61
Gambar 4.11. Pelatihan dan Validasi Akurasi dan Loss .....	63
Gambar 4.12. Confusion matrix CNN .....	64
Gambar 4.13. Kode Membangun Model CNN-SVM .....	67
Gambar 4.14. Kode Kernel SVM.....	69
Gambar 4.15. Kode Evaluasi Model.....	70
Gambar 4.16. Confusion Matrix CNN-SVM.....	72
Gambar 4.17. klasifikasi kesalahan kelas BKL dan Mel .....	77
Gambar 4.18. Perbandingan hasil dengan penelitian sebelumnya.....	82



## INTISARI

Kanker adalah salah satu penyebab utama kematian di seluruh dunia, dengan kanker kulit peringkat kelima. Kulit, sebagai organ terluar tubuh, rentan terhadap berbagai penyakit, dan diagnosis yang akurat sangat penting untuk pengobatan yang efektif. Namun, akses terbatas ke dokter kulit dan biopsi kulit yang mahal menimbulkan tantangan dalam mencapai diagnosis yang efisien. Oleh karena itu, penting untuk mengembangkan sistem yang dapat membantu dalam mengklasifikasikan penyakit kulit secara efisien dan akurat. Di bidang klasifikasi penyakit kulit, metode Machine Learning dan Deep Learning khususnya Convolutional Neural Network (CNN) telah menunjukkan akurasi yang tinggi dalam klasifikasi citra medis.

Penelitian ini berjudul bertujuan untuk membandingkan hasil klasifikasi multi-kelas jenis penyakit kulit menggunakan metode CNN dan kombinasi CNN-SVM. Batasan penelitian melibatkan fokus pada perbandingan hasil klasifikasi, menggunakan model Transfer Learning Resnet50, dataset HAM10000 dengan tujuh jenis penyakit kulit umum, implementasi dengan bahasa pemrograman Python dan TensorFlow, dan evaluasi menggunakan Confusion Matrix.

Metode CNN arsitektur ResNet50 dengan hyperparameter yang tepat dan penerapan Balancing pada data memperoleh akurasi sebesar 94,76%, presisi 94,85%, recall 94,94%, dan F1-score 94,87%. Dibandingkan dengan metode CNN-SVM memiliki hasil akurasi tertinggi dengan kernel Polynomial sebesar 80%, CNN-SVM dengan kernel RBF, Linear, dan Sigmoid menunjukkan performa yang lebih rendah, dan Sigmoid memberikan hasil terendah. Secara keseluruhan, performa CNN-SVM tidak melampaui performa CNN dan CNN terbukti secara konsisten unggul dalam tugas klasifikasi multi-kelas jenis penyakit kulit manusia.

Kata kunci: Convolutional Neural Network (CNN), Dermatological, ResNet50, Skin disease classification, Support Vector Machine (SVM)

## **ABSTRACT**

*Cancer is one of the leading causes of death worldwide, with skin cancer ranking fifth. The skin, as the outermost organ of the body, is susceptible to various diseases, and an accurate diagnosis is essential for effective treatment. However, limited access to dermatologists and expensive skin biopsies poses challenges in achieving an efficient diagnosis. Therefore, it is important to develop a system that can help in classifying skin diseases efficiently and accurately. In the field of skin disease classification, Machine Learning and Deep Learning methods especially Convolutional Neural Network (CNN) have shown high accuracy in medical image classification.*

*This study entitled aims to compare the results of a multi-class classification of skin disease types using the CNN method and the CNN-SVM combination. The limitations of the study involved focusing on comparison of classification results, using the Resnet50 Transfer Learning model, HAM10000 datasets with seven common skin disease types, implementation with Python and TensorFlow programming languages, and evaluation using Confusion Matrix.*

*CNN method ResNet50 architecture with precise hyperparameters and application of Balancing on data obtained accuracy of 94.76%, precision 94.85%, recall 94.94%, and F1-score 94.87%. Compared to the CNN-SVM method has the highest accuracy results with Polynomial kernels at 80%, CNN-SVM with RBF, Linear, and Sigmoid kernels show lower performance, and Sigmoid gives the lowest results. Overall, CNN-SVM's performance did not surpass CNN's performance and CNN proved to be consistently superior in the task of multi-class classification of human skin disease types.*

*Keyword: Convolutional Neural Network (CNN), Dermatological, ResNet50, Skin disease classification, Support Vector Machine (SVM)*

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang Masalah**

The world health organization (WHO) atau Organisasi kesehatan dunia melaporkan bahwa kanker adalah salah satu penyebab utama kematian di dunia secara global dan bertanggung jawab atas sekitar 10 juta kematian setiap tahunnya. Secara global, sekitar 1 dari 6 kematian disebabkan oleh kanker. Kematian akibat kanker global diproyeksikan meningkat sebesar 45% antara tahun 2008 dan 2030. Kanker kulit berada di peringkat kelima di antara bentuk kanker yang paling umum. Pertumbuhan abnormal sel-sel kulit menyebabkan kanker kulit, yang merupakan salah satu jenis kanker yang paling luas di dunia (Ünver & Ayan, 2019).

Kulit merupakan salah satu bagian tubuh yang paling esensial karena kulit lapisan paling luar yang menutupi seluruh bagian tubuh manusia. Kulit memiliki 3 lapisan yang terdiri dari lapisan paling luar (epidermis), kulit dibawah epidermis (dermis) dan dalam lapisan kulit dalam (hipodermis). Kulit membantu dalam regulasi suhu, pertahanan kekebalan tubuh, produksi vitamin, dan sensasi rasa.

Sebagai pelindung fisik terluar tubuh, kulit berperan penting dalam melindungi dari paparan sinar ultraviolet dan bahan kimia berbahaya. Kulit juga memiliki fungsi antibakteri yang berperan dalam sistem kekebalan tubuh untuk melawan benda asing dan mikroorganisme berbahaya. Namun, karena merupakan organ terbuka, kulit rentan terhadap serangan penyakit. Ada banyak faktor eksternal dan internal yang dapat mempengaruhi terjadinya penyakit kulit, seperti kebersihan



lingkungan, sistem kekebalan individu, dan gaya hidup. Penyakit kulit dapat disebabkan oleh kerusakan pada kulit akibat pertumbuhan jamur, bakteri tersembunyi, reaksi alergi, mikroorganisme yang mempengaruhi tekstur kulit, atau produksi pigmen (Refianti et al., 2019).

Penyakit kulit memiliki berbagai jenis, bentuk, dan penyebab. Beberapa jenis penyakit kulit yang umum seperti Actinic Keratoses and Intraepithelial Carcinoma (AKIEC), Basal Cell Carcinoma (BCC), Benign Keratosis-like Lesions (BKL), Dermatofibroma (DF), Melanocytic Nevi (NV), Melanoma, Vascular Lesions (VASC) dan lainnya.

Diagnosis jenis penyakit kulit yang akurat biasanya dilakukan oleh ahli dermatologi. Namun, beberapa kendala seperti akses terbatas ke ahli kulit dan kurangnya pengetahuan tentang pentingnya kesehatan kulit seringkali dihadapi. Jika tidak diobati, penyakit kulit dapat menyebabkan cacat dan memerlukan biaya pengobatan yang tinggi, bahkan dapat mengancam jiwa. Secara umum, dokter kulit mendiagnosa penyakit kulit kronis melalui biopsi, yaitu dengan mengambil sampel kecil jaringan kulit untuk diperiksa di laboratorium, dan menganalisisnya. Namun, biopsi kulit memiliki biaya yang cukup tinggi dan dapat menyebabkan luka atau goresan pada kulit (Tschandl et al., 2018). Oleh karena itu, penting untuk mengembangkan sistem yang dapat membantu mengklasifikasi penyakit kulit yang efisien guna mengatasi keterbatasan tersebut.

Dalam era modern saat ini, perkembangan ilmu teknologi, seperti computer vision, telah sangat membantu dalam berbagai aspek kehidupan manusia. Computer vision merupakan cabang kecerdasan buatan yang memungkinkan komputer untuk

melihat dan memahami objek melalui gambar atau input visual lainnya. Kemajuan computer vision dalam bidang kesehatan menjadi isu penting, di mana tenaga medis menggunakan data citra medis untuk membantu diagnosis, pengobatan, dan identifikasi penyakit (Kose & Alzubi, 2021).

Membangun sebuah sistem untuk klasifikasi jenis penyakit kulit diperlukannya sebuah metode/algorithm Machine Learning atau Deep Learning yang dapat mengklasifikasikan citra gambar. Teknik Deep Learning sangat sesuai dalam menganalisis citra medis, dengan salah satu teknik Deep Learning yang banyak digunakan dalam melakukan klasifikasi adalah dengan menggunakan metode Convolutional Neural Network (CNN). CNN memiliki kemampuan ekstraksi fitur yang sangat baik terutama dalam klasifikasi gambar medis (Gong, W., Chen, H., Zhang, Z., Zhang, M., Wang, R., Guan, C., & Wang, 2019).

Seperti penelitian yang dilakukan oleh (Kassem et al., 2020) Klasifikasi yang tepat dan dini dari lesi kulit sangat penting untuk pengobatan yang efektif dan keselamatan pasien. Penelitian ini mengusulkan model yang sangat akurat untuk klasifikasi lesi kulit dengan menggunakan transfer learning dan model yang sudah dilatih sebelumnya yaitu GoogleNet. Model yang diusulkan berhasil mengklasifikasikan delapan kelas lesi kulit yang berbeda, termasuk melanoma, melanocytic nevus, basal cell carcinoma, actinic keratosis, benign keratosis, dermatofibroma, lesi vaskular, dan squamous cell carcinoma, dengan akurasi sebesar 94,92%, dan presisi 80,36%. Selain itu, model ini mampu mengidentifikasi gambar yang tidak termasuk dalam salah satu dari delapan kelas, dan mengklasifikasikannya sebagai gambar yang tidak diketahui.



Penelitian (Mukkapati & Anbarasi, 2022), kami mengusulkan model CNN yang dapat mengklasifikasikan tumor otak menjadi lima kelas dengan akurasi 92,98%. Model ini dibandingkan dengan beberapa model CNN terkini seperti AlexNet, Inception v3, ResNet-50, VGG-16, dan GoogleNet. Hasil klasifikasi yang memuaskan diperoleh dengan menggunakan dataset klinis yang besar dan tersedia publik. Model CNN yang diusulkan dapat digunakan oleh dokter dan radiolog untuk memverifikasi hasil skrining awal dalam multi-klasifikasi tumor otak.

Pada penelitian (Al., 2020) mengusulkan model hibrida Faster R-CNN dan SVM untuk deteksi tumor dan klasifikasi gambar otak MRI. Hasil penelitian menunjukkan bahwa model kombinasi Faster R-CNN dan SVM menghasilkan akurasi yang lebih tinggi yaitu sebesar 98.81% dibandingkan dengan model penelitian sebelumnya yang menggunakan model R-CNN 91.66%, CNN & RBF berbasis SVM 92%, RELM-94.233%, KNN-96.6% dan CNN 97.5%.

Dalam penelitian (Chaturvedi et al., 2020), mengusulkan sebuah sistem diagnosis komputer otomatis untuk klasifikasi kanker kulit multi-kelas (MCS). Metode yang diusulkan berhasil mengungguli baik dermatolog ahli maupun metode deep learning terkini dalam klasifikasi kanker kulit MCS. Melakukan penyesuaian ulang pada tujuh kelas dataset HAM10000 dan melakukan studi perbandingan untuk menganalisis performa lima model jaringan saraf konvolusi (CNN) yang sudah dilatih sebelumnya dan empat model ensemble. Akurasi maksimum sebesar 93,20% untuk model individual dicapai, sedangkan akurasi maksimum sebesar 92,83% untuk model ensemble dilaporkan dalam penelitian ini.

Penelitian (Deif & Hammam, 2020) mengimplementasikan dilated convolution, Menggunakan transfer learning dengan empat arsitektur populer, yaitu VGG16, VGG19, MobileNet, dan InceptionV3. Dataset HAM10000 digunakan untuk pelatihan, validasi, dan pengujian, yang terdiri dari total 10015 gambar dermoskopis dari tujuh kelas lesi kulit dengan ketidakseimbangan kelas yang signifikan. Akurasi teratas yang dicapai pada versi dilated dari VGG16, VGG19, MobileNet, dan InceptionV3 adalah 87,42%, 85,02%, 88,22%, dan 89,81%, secara berturut-turut.

Penelitian lainnya oleh (Jean et al., 2022) untuk membangun aplikasi menggunakan pendekatan Hybrid CNN-SVM dan PCA-svm untuk Klasifikasi Jumlah Biji Kakao. Dalam penelitian ini, CNN digunakan sebagai ekstraksi fitur dan SVM digunakan untuk klasifikasi. Hasil penelitian menunjukkan bahwa model CNN-SVM memiliki akurasi yang lebih tinggi yaitu sebesar 98.32% dibandingkan dengan model PCA-svm yaitu sebesar 97.65%.

Pada penelitian (Khairandish et al., 2022) juga melakukan penelitian dengan pendekatan segmentasi ambang batas CNN-SVM hibrida untuk tumor deteksi dan klasifikasi gambar otak MRI. Dalam penelitian ini, gambar MRI otak akan diklasifikasikan dengan mempertimbangkan keunggulan dari CNN pada kumpulan data publik untuk mengklasifikasikan tumor Jinak dan Ganas. Hasil penelitian sebelumnya dengan model yang berbeda memperoleh akurasinya sebagai berikut Rough Extreme Learning Machine (RELM) 94.233%, Deep CNN (DCNN) 95%, Deep Neural Network (DNN) dan Discrete Wavelet Autoencoder (DWA) 96%, K-

Nearest Neighbor (KNN) 96,6%, CNN 97,5%. Sedangkan pada penelitian ini dengan kombinasi CNN-SVM memperoleh akurasi sebesar 98,4959%.

Namun hasil tersebut berbeda dengan penelitian yang dilakukan oleh (Y. Wang et al., 2018). Dalam penelitiannya, CNN dan model CNN hibrida seperti CNN-SVM digunakan untuk mengklasifikasikan payudara gambar mikroskop kanker pada himpunan data ICIAR2018. Hasil penelitiannya menyimpulkan bahwa hasil klasifikasi CNN lebih tinggi dengan nilai akurasi sebesar 92.5% hasil validasi dataset dan 91.1% data testing dibandingkan dengan model CNN-SVM dengan nilai akurasi 82.25% validasi dataset dan 80.6% data testing.

Penelitian yang dilakukan oleh (Keerthana et al., 2023) untuk mengklasifikasi otomatis gambar dermoskopi 2 jenis penyakit kulit yaitu jinak dan melanoma menggunakan model hibrida CNN-SVM. Dalam penelitiannya membandingkan CNN digabungkan dengan 3 metode Machine Learning yaitu SVM, KNN, dan DT. Hasilnya menunjukkan bahwa klasifikasi menggunakan CNN-SVM memperoleh akurasi yang lebih baik dibandingkan dengan CNN-KNN dan CNN-DT. Dalam penelitiannya juga membandingkan beberapa arsitektur CNN yaitu AlexNet, GoogleNet, VGG-16, VGG-19, ResNet-18, ResNet-50, ResNet-101, ShuffleNet, MobileNet dan DenseNet-201. Hasil akhir penelitian bahwa menggunakan CNN-SVM dengan model transfer learning gabungan memperoleh akurasi sebesar 87,43% untuk DenseNet201-ResNet50 dan 88,02% untuk DenseNet201-MobileNet. Akan tetapi dalam penelitian ini hanya mengklasifikasikan 2 jenis penyakit sehingga metode ini dapat lebih ditingkatkan untuk mengklasifikasikan lebih banyak jenis penyakit yang berbeda.

CNN dan SVM adalah dua algoritma pembelajaran mesin berbeda yang digunakan untuk tugas klasifikasi. CNN adalah algoritma pembelajaran mendalam yang dirancang khusus untuk mengekstrak fitur dari gambar, sedangkan SVM adalah pengklasifikasi yang lebih umum. CNN dikenal lebih baik daripada SVM untuk tugas klasifikasi gambar karena mereka dapat mengekstraksi fitur yang lebih kompleks dari gambar. Namun, dalam beberapa kasus, menggabungkan CNN dan SVM dapat menghasilkan performa klasifikasi yang lebih baik, terutama ketika menangani tugas klasifikasi gambar yang kompleks. (Naresh, Rk., 2023).

CNN dirancang untuk mengekstrak fitur dari gambar, sehingga cocok untuk tugas-tugas seperti analisis gambar medis. SVM, di sisi lain, adalah pengklasifikasi kuat yang dapat menangani data linier dan non-linier (Hartini et al, 2022), (Xue et al., 2016). SVM dikenal karena kemampuan generalisasinya yang baik dan dapat menangani kumpulan data yang tidak seimbang, yang umum terjadi dalam aplikasi medis. Sebaliknya, meskipun CNN unggul dalam ekstraksi fitur, CNN mungkin tidak seefektif klasifikasi akhir (Wan et al., 2021)

Menggabungkan CNN dan SVM dalam model hibrid dapat memanfaatkan kekuatan kedua algoritme, sehingga menghasilkan peningkatan performa klasifikasi. Seperti sebuah penelitian (Hartini et al, 2022), mengusulkan model hibrid CNN-SVM untuk klasifikasi penyakit pernafasan menggunakan gambar sinar-X, sehingga mencapai tingkat akurasi yang tinggi.

Dalam beberapa kasus, kombinasi CNN dan SVM dapat menghasilkan kinerja klasifikasi yang lebih baik daripada hanya menggunakan salah satu algoritma CNN saja. Misalnya, sebuah penelitian dilakukan oleh (Keerthana et al.,



2023) mengusulkan model hybrid CNN-SVM untuk klasifikasi multikelas tumor otak, virus corona, dan penyakit lutut, sehingga mencapai peningkatan akurasi.

Metode CNN telah terbukti memiliki hasil akurasi yang tinggi dalam berbagai penelitian sebelumnya dalam klasifikasi gambar medis. Keunggulan CNN terletak pada kemampuannya untuk melakukan ekstraksi fitur secara otomatis dan mendalam dari citra kulit, yang memungkinkan pengambilan keputusan yang akurat dalam mengklasifikasikan jenis penyakit kulit.

Kombinasi CNN-SVM menawarkan pendekatan yang menarik. CNN digunakan untuk melakukan ekstraksi fitur, sementara SVM digunakan sebagai algoritma klasifikasi. Keuntungan dari pendekatan ini adalah SVM dapat mengatasi masalah overfitting yang mungkin terjadi pada model CNN. SVM juga dapat memberikan interpretabilitas yang lebih tinggi dalam hasil klasifikasi, memungkinkan identifikasi fitur-fitur yang penting dalam pengambilan keputusan.

Namun, dalam penelitian klasifikasi jenis penyakit kulit menggunakan CNN dan CNN-SVM, terdapat beberapa permasalahan yang perlu diatasi dari penelitian sebelumnya. Keterbatasan dataset yang cukup besar dan representatif, ketidakseimbangan kelas dalam jumlah sampel antar jenis penyakit kulit, kompleksitas dalam preprocessing data, serta mengembangkan model yang lebih efisien dalam arsitektur CNN adalah beberapa masalah yang dihadapi dalam penelitian ini.

Berdasarkan uraian diatas, Penelitian ini bertujuan untuk membandingkan kinerja dua metode klasifikasi, yaitu Convolutional Neural Network (CNN) dan kombinasi Convolutional Neural Network + Support Vector Machine (CNN-

SVM), dalam mengklasifikasikan multi-kelas jenis penyakit kulit. Adapun tujuan utama penelitian ini adalah untuk menganalisis dan membandingkan hasil klasifikasi berdasarkan akurasi, presisi, dan recall dari kedua model. Akurasi mengukur kemampuan model dalam mengenali dan mengklasifikasikan gambar penyakit kulit secara benar. Presisi menilai ketepatan model dalam mengklasifikasikan multi-kelas jenis penyakit kulit, sedangkan recall mengukur kemampuan model dalam mengidentifikasi sebagian besar kasus penyakit kulit yang sebenarnya. Hasil penelitian ini juga diharapkan dapat meningkatkan akurasi dan keandalan dalam klasifikasi multi-kelas jenis penyakit kulit menggunakan CNN dan CNN-SVM, serta memberikan kontribusi penting dalam pengembangan solusi diagnostik yang lebih baik dalam bidang medis.

### **1.2. Rumusan Masalah**

Berdasarkan uraian latar belakang diatas, dapat diperoleh rumusan masalah sebagai berikut:

- a. Apakah metode CNN atau metode CNN-SVM memberikan hasil klasifikasi yang lebih akurat dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia?
- b. Bagaimana akurasi, presisi, dan recall dari model klasifikasi CNN dan CNN-SVM dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia?

### **1.3. Batasan Masalah**

Batasan masalah dalam penelitian ini adalah:



- a. Penelitian ini bertujuan untuk membandingkan hasil klasifikasi multi-kelas jenis penyakit kulit manusia menggunakan metode CNN dan kombinasi CNN-SVM.
- b. Menggunakan model Transfer Learning Resnet50.
- c. Dataset yang digunakan adalah HAM10000, yang terdiri dari 10.015 gambar penyakit kulit dan diperoleh dari Dataverse Harvard.
- d. Penelitian ini akan mengklasifikasikan 7 jenis penyakit kulit umum manusia, yaitu Actinic Keratoses and Intraepithelial Carcinoma (AKIEC), Basal Cell Carcinoma (BCC), Benign Keratosis-like Lesions (BKL), Dermatofibroma (DF), Melanocytic Nevi (NV), Melanoma (MEL), Vascular Lesions (VASC).
- e. Implementasi dan pelatihan model dilakukan menggunakan bahasa pemrograman Python dan pustaka Python.
- f. Evaluasi klasifikasi dilakukan menggunakan Confusion Matrix.

#### **1.4. Tujuan Penelitian**

Tujuan dari penelitian ini adalah sebagai berikut:

- c. Membandingkan performa dua metode klasifikasi, yaitu CNN dan kombinasi CNN-SVM dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia.
- d. Menganalisis dan membandingkan hasil klasifikasi berdasarkan akurasi, presisi, recall, dan F1-score dari kedua metode klasifikasi.

#### **1.5. Manfaat Penelitian**

Manfaat dari penelitian ini adalah:

- a. Bagi peneliti, penelitian ini memberikan pemahaman tentang perbandingan hasil kinerja antara metode klasifikasi CNN dan CNN-SVM dalam pengklasifikasian multi-kelas jenis penyakit kulit.
- b. Menambah pengetahuan tentang model yang dapat mengklasifikasikan multi-kelas jenis penyakit kulit.
- c. Rancangan model dapat diimplementasikan sebagai sistem deteksi penyakit kulit secara langsung, membantu mendiagnosis awal secara cepat dan akurat.
- d. Menjadi referensi untuk penelitian lain dalam bidang yang sama dan memberikan wawasan untuk pengembangan penelitian selanjutnya.



## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1. Tinjauan Pustaka**

Klasifikasi penyakit kulit menggunakan teknik deep learning telah mendapatkan perhatian yang signifikan dalam beberapa tahun terakhir. Beberapa penelitian telah berfokus pada pengembangan model yang kuat untuk secara akurat mengklasifikasikan multi-kelas jenis penyakit kulit. Dalam tinjauan pustaka ini, akan membahas temuan dan kontribusi studi penelitian yang relevan di bidang ini.

Sebuah penelitian yang dilakukan oleh (Keerthana et al., 2023) bertujuan untuk mengklasifikasi otomatis gambar dermoskopi lesi jinak atau melanoma menggunakan model hibrida CNN-SVM. Dalam penelitiannya membandingkan CNN digabungkan dengan 3 metode Maching Learning yaitu SVM, KNN, dan DT. Hasilnya menunjukkan bahwa klasifikasi menggunakan CNN-SVM memperoleh akurasi yang lebih baik dibandingkan dengan CNN-KNN dan CNN-DT. Dalam penelitiannya juga membandingkan beberapa arsitektur CNN yaitu AlexNet, GoogleNet, VGG-16, VGG-19, ResNet-18, ResNet-50, ResNet-101, ShuffleNet, MobileNet dan DenseNet-201. Hasil akhir penelitian bahwa menggunakan CNN-SVM dengan model transfer learning gabungan memperoleh akurasi sebesar 87,43% untuk DenseNet201-ResNet50 dan 88,02% untuk DenseNet201-MobileNet. Akan tetapi dalam penelitian ini hanya mengklasifikasikan 2 jenis penyakit sehingga metode ini dapat lebih ditingkatkan untuk mengklasifikasikan lebih banyak jenis penyakit yang berbeda.

Diteliti juga Oleh (Yanagisawa et al., 2023), mereka mengembangkan model berbasis Convolutional Neural Network (CNN) dan sistem diagnosis berbantu komputer (CAD) untuk melakukan segmentasi gambar kulit dan menghasilkan dataset gambar penyakit kulit yang cocok untuk CAD dari beberapa klasifikasi penyakit kulit. Model segmentasi CNN ini mampu secara otomatis mengekstrak lesi kulit dan memisahkannya dari latar belakang gambar. Dalam pengujian klasifikasi penyakit kulit, model segmentasi CNN mencapai sensitivitas dan spesifisitas sekitar 90% dalam membedakan dermatitis atopik. Dataset masih dalam berbagai bentuk variasi dan perbedaan bidang gambar. Diperlukannya metode untuk mengekstrak lesi dan mesegmentasi area kulit dari bidang gambar. Hal ini dapat menyulitkan model dalam mengenali dan membedakan fitur-fitur penting dalam gambar, sehingga tidak disarankan menggunakan dataset yang memiliki perbedaan bidang gambar untuk klasifikasi jenis penyakit kulit.

Penelitian oleh (Aljohani & Turki, 2022) dalam penelitiannya menggunakan Deep-CNN untuk mengklasifikasikan kanker kulit melanoma dari gambar lesi kulit secara otomatis. Menguji beberapa arsitektur jaringan saraf konvolusional (CNN) yaitu DenseNet201, MobileNetV2, ResNet50V2, ResNet152V2, Xception, VGG16, VGG19, dan GoogleNet. Meskipun arsitektur GoogleNet memiliki kinerja terbaik tetapi Penelitian hanya terfokus pada 1 jenis penyakit kulit Melanoma, belum ada penjelasan mengenai keefektifan arsitektur ini dalam mengenali fitur-fitur yang berbeda, jenis kulit yang berbeda dan pada jenis penyakit yang berbeda. Memiliki hasil akurasi yang terbilang cukup rendah yaitu

sebesar training 74,91% dan testing 76,08% sehingga masih dapat ditingkatkan menjadi lebih baik lagi.

Penelitian berikutnya oleh yang dilakukan oleh (Akter et al., 2022) bertujuan untuk melakukan klasifikasi kanker kulit multi-kelas menggunakan metode Deep Convolutional Neural Network. Model Convolutional Neural Network (CNN) dan 6 model pembelajaran transfer yaitu Resnet-50, VGG-16, Densenet, Mobilenet, Inceptionv3, dan Xception diterapkan pada dataset benchmark HAM10000 dengan 7 jenis penyakit kulit. Memperoleh hasil akurasi 90, 88, 88, 87, 82, dan 77 persen untuk inceptionv3, Xception, Densenet, Mobilenet, Resnet, CNN, dan VGG16. Tetapi dalam jurnal tersebut tidak menjelaskan hasil augmentasi secara spesifik, hanya menyebutkan melakukan augmentasi terhadap keseluruhan data. Sedangkan, dari 7 jenis penyakit yang diklasifikasi terdapat beberapa jenis penyakit yang memiliki jumlah dataset yang sedikit. Hal tersebut sebaiknya dilakukan augmentasi agar data menjadi seimbang. Ketika dataset tidak seimbang, model cenderung memiliki bias terhadap kelas mayoritas yang berpengaruh terhadap hasil akurasi.

Dalam penelitian yang dilakukan oleh (Srinivasu et al., 2021) mengusulkan proses komputerisasi untuk mengklasifikasikan penyakit kulit menggunakan *Deep Learning* berbasis MobileNet V2 dan Long Short-Term Memory (LSTM) pada dataset HAM1000. Dataset yang digunakan berupa gambar penyakit kulit dengan 7 kategori penyakit kulit yang berbeda. Dalam kasus ini, LSTM (Long Short-Term Memory) digunakan untuk memproses urutan fitur yang diekstraksi oleh CNN. Dalam proses ekstraksi fitur walaupun data gambar penyakit kulit diambil dalam



waktu berbeda tetapi masih dalam kategori yang sama. Oleh karena itu, tidak ada kebutuhan khusus untuk mempertimbangkan urutan temporal dalam pendekatan menggunakan CNN-LSTM. Pendekatan menggunakan CNN-SVM lebih cocok untuk mengelompokkan data dengan batas keputusan non-linear (hubungan fitur-fitur dan kelas-kelas) dan SVM juga dapat mengatasi masalah klasifikasi dengan jumlah kelas yang banyak.

Penelitian lainnya oleh (Junayed et al., 2021) menggunakan metode Deep Convolution Neural Network (CNN) untuk mendeteksi dan mengklasifikasikan 4 jenis kanker kulit. Model yang diusulkan mencapai akurasi 96,98% untuk empat jenis kanker kulit. Akan tetapi, dalam penelitian ini menggunakan dataset awal yang terbilang sedikit yaitu sebanyak 800 gambar untuk 4 jenis penyakit, sehingga masih diperlukannya peningkatan dataset agar dapat belajar fitur-fitur yang lebih representatif dan mampu membedakan antara kelas-kelas penyakit.

Dalam penelitian yang dilakukan oleh (Chaturvedi et al., 2020) mengusulkan sebuah sistem diagnosis berbantu komputer otomatis untuk klasifikasi kanker kulit multi-kelas. Menggunakan dataset HAM10000 yang terdiri dari tujuh kelas, dan melakukan studi perbandingan untuk menganalisis kinerja dari lima jaringan saraf konvolusi (CNN) yang sudah dilatih sebelumnya dan empat model ensemble. Hasil penelitian menunjukkan tingkat akurasi maksimum sebesar 93,20% untuk model individual dan 92,83% untuk model ensemble. Akan tetapi model terbaik dari klasifikasi tidak hanya dilihat dari nilai akurasi yang tinggi. Adapun hasil dari semua model dalam penelitian ini memiliki nilai presisi, recall, dan f1-score yang masih dibawah angka 90%. Hal ini menunjukkan bahwa model



masih dapat ditingkatkan keakuratan dan keseluruhan performa klasifikasi dalam penelitian ini.

Penelitian multi-kelas lainnya (Deif & Hammam, 2020) Mengembangkan sebuah sistem deteksi lesi kulit berbantu komputer yang lebih akurat dengan menggunakan metode dilated convolution dalam deep learning. Mengimplementasikan dilated convolution pada empat arsitektur model yang berbeda, yaitu VGG16, VGG19, MobileNet, dan InceptionV3. Dataset HAM10000 digunakan untuk pelatihan, validasi, dan pengujian, yang terdiri dari total 10.015 gambar dermoskopi dari tujuh kelas lesi kulit dengan ketidakseimbangan kelas yang signifikan. Akurasi terbaik yang dicapai pada versi dilated dari VGG16, VGG19, MobileNet, dan InceptionV3 adalah masing-masing 87,42%, 85,02%, 88,22%, dan 89,81%. Dapat meningkatkan akurasi dengan melakukan eksperimen yang melibatkan variasi parameter lainnya, seperti peningkatan jumlah epoch, optimasi learning rate, dan penerapan teknik regularisasi seperti dropout. Selain itu, untuk mengatasi masalah ketidakseimbangan jumlah sampel antara kelas penyakit kulit dalam dataset HAM10000. Dapat diterapkan teknik oversampling atau undersampling untuk menciptakan distribusi kelas yang lebih seimbang. Menggunakan Convolution Standart dari model ResNet50 dan melakukan perubahan dalam jumlah epoch, optimasi learning rate, batch\_size dan penerapan teknik regularisasi seperti dropout untuk mengembangkan model klasifikasi.

## 2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian  
Analisis Perbandingan Metode CNN dan CNN-SVM untuk Klasifikasi multi-kelas Jenis Penyakit Kulit Manusia

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Convolutional neural network-based skin image segmentation model to improve classification of skin diseases in conventional and non-standardized picture images	Yuta Yanagisawa, Kosuke Shido, Kaname Kojima dan Kenshi Yamasaki, Journal of Dermatological Science, 2023.	Mengembangkan model berbasis Convolutional neural network (CNN) dan computer-aided diagnosis system (CAD) untuk segmentasi gambar kulit untuk menghasilkan dataset gambar penyakit kulit yang cocok untuk CAD dari beberapa klasifikasi penyakit kulit.	Model segmentasi CNN ini mampu secara otomatis mengekstrak lesi kulit dan memisahkannya dari latar belakang gambar. Dalam pengujian klasifikasi penyakit kulit, model segmentasi CNN mencapai sensitivitas dan spesifisitas sekitar 90% dalam membedakan dermatitis apotik.	Dataset masih dalam berbagai bentuk variasi dan perbedaan bidang gambar. Sehingga perlukannya metode untuk mengekstrak lesi dan mesegmentasi area kulit dari bidang gambar. Hal ini dapat menyulitkan model dalam mengenali dan membedakan fitur-fitur penting dalam gambar.	Penelitian ini akan menggunakan dataset yang terfokus pada bagian kulit yang bermasalah, sehingga tidak perlukannya deteksi dan segmentasi bagian tubuh terlebih dahulu.
2	Hybrid convolutional neural networks with SVM classifier for classification of skin cancer	Duggani Keerthana, Vipin Venugopal, Malaya Kumar Nath dan Madhusudhan Mishra, Biomedical Engineering Advances journal, 2022.	Klasifikasi otomatis menggunakan model hibrida CNN-SVM untuk gambar dermoskopi lesi jinak atau melanoma.	Hasilnya menunjukkan bahwa klasifikasi menggunakan CNN-SVM memperoleh akurasi yang lebih baik dibandingkan dengan CNN-KNN dan CNN-DT. Hasil CNN-SVM dengan model transfer learning gabungan memperoleh	Penelitian ini hanya mengklasifikasikan 2 jenis penyakit sehingga metode ini dapat lebih ditingkatkan untuk mengklasifikasikan lebih banyak jenis penyakit yang berbeda	Menggunakan CNN dan kombinasi CNN-SVM dengan arsitektur ResNet50 untuk mengklasifikasi 7 jenis penyakit kulit.

Tabel 2.1. Lanjutan Matriks literatur review dan posisi penelitian

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				akurasi sebesar 87,43% untuk DenseNet201-ResNet50 Dan 88,02% untuk DenseNet201-MobileNet.		
3	Multi-class Skin Cancer Classification Architecture Based on Deep Convolutional Neural Network	Mst Shapna Akter, Hossain Shahriar, Sweta Sneha dan Alfredo Cuzzocrea, 2022 IEEE International Conference on Big Data (Big Data), 2022.	Melakukan Klasifikasi Kanker Kulit Multi-kelas menggunakan metode Deep Convolutional Neural Network	Model Convolutional Neural Network (CNN) dan 6 model pembelajaran transfer yaitu Resnet-50, VGG-16, Densenet, Mobilenet, Inceptionv3, dan Xception diterapkan pada dataset benchmark HAM10000 dengan 7 jenis penyakit kulit. Memperoleh hasil akurasi 90, 88, 88, 87, 82, dan 77 persen untuk inceptionv3, Xception, Densenet, Mobilenet, Resnet, CNN, dan VGG16.	Hanya melakukan augmentasi terhadap keseluruhan data. Sedangkan, dari 7 jenis penyakit yang diklasifikasi terdapat beberapa jenis penyakit yang memiliki jumlah dataset yang sedikit. Hal tersebut sebaiknya dilakukan augmentasi agar data menjadi seimbang. Ketika dataset tidak seimbang, model cenderung memiliki bias terhadap kelas mayoritas yang berpengaruh terhadap hasil akurasi.	Menggabungkan metode Deep Learning dan Maching Learning yaitu CNN-SVM. Melakukan augmentasi pada dataset agar dataset menjadi seimbang.
4	A Deep CNN Model for Skin Cancer Detection and Classification	Masum Shah Junayed, Nipa Anjum, Abu Noman Md Sakib dan Md Baharul Islam,	Menggunakan metode Deep Convolution Neural Network (CNN)	Model yang diusulkan mencapai akurasi 96,98% untuk empat jenis kanker kulit	Dataset awal yang digunakan terlalu sedikit yaitu sebanyak 800 gambar untuk 4	Menggabungkan metode CNN-SVM. Meningkatkan jumlah dataset dan

Tabel 2.1. Lanjutan Matriks literatur review dan posisi penelitian

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		Computer Science Research Notes, 2021.	untuk mendeteksi dan mengklasifikasikan 4 jenis kanker kulit.		jenis penyakit, sehingga masih diperlukannya peningkatan dataset agar dapat belajar fitur-fitur yang lebih representatif dan mampu membedakan antara kelas-kelas penyakit.	jumlah jenis penyakit yang akan diklasifikasi.
5	Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM	Parvathaneni Naga Srinivasu, Jalluri Gnana SivaSat, Muhammad Fazal Ijaz, Akash Kumar Bhoi, Wonjoon Kim and James Jin Kang, MDPI, 2021.	Penelitian ini mengusulkan proses komputisasi untuk mengklasifikasikan penyakit kulit menggunakan Deep Learning berbasis MobileNet V2 dan Long Short-Term Memory (LSTM).	Model MobileNet V2 terbukti efisien dengan akurasi yang lebih baik yang dapat bekerja pada perangkat komputasi ringan. Model yang diusulkan menghasilkan akurasi sebesar 85,36%	Dalam proses CNN untuk ekstraksi fitur walaupun data gambar penyakit kulit diambil dalam waktu berbeda tetapi masih dalam kategori yang sama. Oleh karena itu, tidak ada kebutuhan khusus untuk mempertimbangkan urutan temporal dalam pendekatan menggunakan CNN-LSTM.	Melakukan klasifikasi menggunakan CNN dan kombinasi CNN-SVM untuk klasifikasi multi-kelas penyakit kulit.
6	Automatic Classification of Melanoma Skin	Khalil Aljohani and Turki, MDPI, 2020.	Menggunakan Deep-CNN untuk mengklasifikasikan	Dari semua arsitektur yang diuji GoogleNet memiliki kinerja terbaik dengan	Meskipun arsitektur GoogleNet memiliki kinerja terbaik tetapi	Penelitian ini akan menggunakan arsitektur ResNet50



Tabel 2.1. Lanjutan Matriks literatur review dan posisi penelitian

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Cancer with Deep Convolutional Neural Networks		kanker kulit melanoma dari gambar lesi kulit secara otomatis dan menguji arsitektur (CNN) yaitu DenseNet201, MobileNetV2, ResNet50V2, ResNet152V2, Xception, VGG16, VGG19, dan GoogleNet.	hasil akurasi training sebesar 74,91% dan testing 76,08%.	Penelitian hanya terfokus pada 1 jenis penyakit kulit Melanoma, belum ada penjelasan mengenai keefektifan arsitektur ini dalam mengenali fitur-fitur yang berbeda, jenis kulit dan jenis penyakit yang berbeda. Akurasi juga terbilang cukup rendah sehingga masih bisa ditingkatkan.	pada dataset yang memiliki 7 jenis penyakit kulit yang berbeda.
7	A multi-class skin Cancer classification using deep convolutional neural networks	Chaturvedi S, Tembhurne J, Diwan T, Multimedia Tools and Applications, 2020.	Mengembangkan sistem diagnosis otomatis dengan akurasi tinggi untuk klasifikasi multi-kelas kanker kulit. Penelitian ini juga membandingkan performa terhadap lima model CNN dan empat model ensemble.	Hasil akurasi penelitian ini mencapai tingkat akurasi maksimum sebesar 93,20% untuk model individual dan akurasi maksimum sebesar 92,83% untuk model ensemble dalam klasifikasi multi-kelas kanker kulit.	Dalam klasifikasi tidak hanya mengukur dari nilai akurasi, hasil penelitian ini memiliki nilai presisi, recall, dan F1-score dari semua model masih dibawah angka 90%. Hal ini menunjukkan bahwa model masih dapat ditingkatkan keakuratan dan keseluruhan performa klasifikasi dalam penelitian ini.	Meningkatkan model ResNet50 dan CNN-SVM dalam klasifikasi multi-kelas penyakit kulit. Melakukan augmentasi dan balancing dataset.

Tabel 2.1. Lanjutan Matriks literatur review dan posisi penelitian

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
8	Skin Lesions Classification Based on Deep Learning Approach.	Deif M & Hammam R, Journal of Clinical Engineering, 2020.	Mengembangkan sebuah sistem deteksi lesi kulit berbantu komputer yang lebih akurat dengan menggunakan metode dilated convolution dalam deep learning. Mengimplementasikan dilated convolution pada empat arsitektur model yang berbeda, yaitu VGG16, VGG19, MobileNet, dan InceptionV3.	Dataset HAM10000 digunakan untuk pelatihan, validasi, dan pengujian, yang terdiri dari total 10.015 gambar dermoskopi dari tujuh kelas lesi kulit dengan ketidakseimbangan kelas yang signifikan. Akurasi terbaik yang dicapai pada versi dilated dari VGG16, VGG19, MobileNet, dan InceptionV3 adalah masing-masing 87,42%, 85,02%, 88,22%, dan 89,81%.	Dapat meningkatkan akurasi dengan melakukan eksperimen yang melibatkan variasi parameter lainnya, seperti peningkatan jumlah epoch, optimasi learning rate, dan penerapan teknik regularisasi seperti dropout. Selain itu, untuk mengatasi masalah ketidakseimbangan jumlah sampel antara kelas penyakit kulit dalam dataset HAM10000, dapat diterapkan teknik oversampling atau undersampling untuk menciptakan distribusi kelas yang lebih seimbang.	Menggunakan Conolution Standart dari model ResNet50 dan melakukan perubahan dalam jumlah epoch, optimasi learning rate, batch_size dan penerapan teknik regularisasi seperti dropout.



## **2.3. Landasan Teori**


### **2.3.1. Klasifikasi**

Klasifikasi adalah suatu pengelompokan data dimana data yang digunakan tersebut mempunyai kelas label atau target kedalam kategori tertentu. Klasifikasi dikategorisasikan ke dalam Supervised Learning atau pembelajaran yang diawasi. Maksud dari pembelajaran yang diawasi adalah data label atau target ikut berperan sebagai 'Supervisor' atau 'guru' yang mengawasi proses pembelajaran dalam mencapai tingkat akurasi atau presisi tertentu. Beberapa algoritma yang sering digunakan dalam menyelesaikan pengklasifikasian yaitu Algoritma K-Nearest Neighbor (K-NN), Algoritma C-45, Algoritma Naïve Bayes, Algoritma Jaringan Saraf Tiruan (JST), Deep Learning (DL)/Neural Network, Support Vector Classificatio (SVM), dan metode lainnya.

### **2.3.2. Machine Learning**

Machine learning adalah inti dari bidang kecerdasan buatan yang melibatkan berbagai disiplin seperti probabilitas, statistika, teori aproksimasi, analisis konveks, dan teori kompleksitas algoritma. Tujuan utama dari machine learning adalah mempelajari bagaimana komputer dapat mensimulasikan atau mengimplementasikan proses pembelajaran manusia. Proses ini melibatkan akuisisi pengetahuan atau keterampilan baru serta organisasi struktur pengetahuan yang sudah ada untuk meningkatkan kinerja komputer. Dalam machine learning, hukum-hukum atau pola-pola dipelajari dari data historis yang besar menggunakan algoritma yang relevan. Data baru kemudian dapat diprediksi atau dinilai menggunakan pengetahuan yang telah dipelajari tersebut, meniru kemampuan

manusia dalam belajar (P. Wang et al., 2021). Cara kerja Machine Learning seperti pada Gambar 2.1.



Gambar 2.1. Cara kerja Machine Learning

Machine learning umumnya mengkategorikan tugas-tugasnya ke dalam beberapa skenario yang umum digunakan. Berikut adalah beberapa contoh skenario tersebut:

a. **Supervised learning (Pembelajaran terpantau)**

Pada supervised learning, model machine learning dilatih menggunakan data yang memiliki label atau jawaban yang benar. Misalnya, dalam klasifikasi gambar, setiap gambar dilengkapi dengan label yang menunjukkan kategori gambar tersebut. Tujuan dari supervised learning adalah untuk membuat model yang dapat mempelajari pola-pola dari data yang diberikan dan dapat memprediksi label atau jawaban yang benar untuk data baru yang belum pernah dilihat sebelumnya.

b. **Unsupervised learning (Pembelajaran tanpa pengawasan):**

Pada unsupervised learning, model Machine Learning belajar dari data yang tidak memiliki label atau jawaban yang benar. Tujuannya adalah untuk menemukan pola-pola tersembunyi atau struktur dalam data tersebut tanpa adanya panduan eksternal. Contoh dari unsupervised learning adalah clustering, di mana model berusaha untuk mengelompokkan data berdasarkan kesamaan karakteristik atau pola yang ada.

c. Reinforcement learning (Pembelajaran penguatan):

Pada reinforcement learning, model Machine Learning belajar melalui interaksi dengan lingkungan. Model menerima umpan balik dalam bentuk reward atau hukuman sebagai respons terhadap tindakan yang diambil. Tujuan dari reinforcement learning adalah untuk membuat keputusan yang optimal untuk mencapai tujuan tertentu berdasarkan umpan balik yang diterima.

d. Semi-supervised learning (Pembelajaran semi-terpantau):

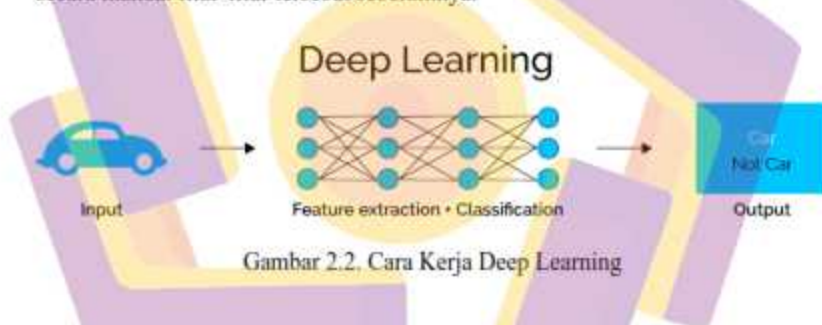
Pada semi-supervised learning, model machine learning menggunakan data yang sebagian besar tidak memiliki label atau jawaban yang benar, tetapi juga memiliki sejumlah kecil data yang memiliki label. Tujuan dari semi-supervised learning adalah untuk memanfaatkan informasi yang terbatas dari data berlabel untuk meningkatkan kinerja model dalam memprediksi data yang tidak berlabel.

### 2.3.3. Deep Learning

Deep learning adalah bidang baru dalam machine learning yang memiliki motivasi untuk membangun dan mensimulasikan jaringan saraf otak manusia dalam analisis dan pembelajaran. Deep learning meniru mekanisme otak manusia dalam menginterpretasikan data seperti teks, suara, dan gambar. Dalam deep learning, digunakan arsitektur jaringan saraf dalam kedalaman (deep neural network) yang terdiri dari banyak lapisan tersembunyi. Pendekatan ini memungkinkan deep learning untuk mempelajari representasi fitur yang kompleks secara otomatis melalui lapisan-lapisan tersebut. Salah satu karakteristik utama deep learning adalah jenis pembelajaran tanpa pengawasan (Unsupervised Learning), di mana

model belajar secara mandiri dari data tanpa memerlukan anotasi atau label yang eksplisit (P. Wang et al., 2021).

Dalam deep learning, gambar mentah dimasukkan ke dalam jaringan saraf dengan lapisan-lapisan. Melalui proses tersebut, jaringan mengidentifikasi pola-pola dalam gambar untuk membangun fitur-fitur kompleks. Jaringan tidak hanya melakukan ekstraksi fitur, tetapi juga melakukan klasifikasi untuk memprediksi kelas atau label yang sesuai seperti pada Gambar 2.2. Perbedaan deep learning dengan machine learning tradisional adalah kemampuan jaringan untuk secara otomatis mempelajari fitur-fitur yang relevan dari data tanpa perlu menentukan secara manual fitur-fitur tersebut sebelumnya.




Gambar 2.2. Cara Kerja Deep Learning

#### 2.3.4. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu algoritma deep Learning yang dirancang khusus untuk memproses data berupa citra. CNN memiliki kemampuan yang kuat dalam pengenalan pola dan pengolahan citra berkat struktur dan operasinya yang terinspirasi oleh organisasi visual korteks manusia. Dalam CNN, konsep dasar seperti lapisan konvolusi, lapisan pooling, dan lapisan terhubung penuh digunakan untuk memperoleh fitur-fitur penting dari citra dan melakukan klasifikasi (Lecun et al., 2015).



Arsitektur Convolutional Neural Network (CNN) terdiri dari dua komponen utama: Lapisan ekstraksi fitur dan Lapisan klasifikasi. Lapisan ekstraksi fitur adalah bagian awal dari arsitektur yang terdiri dari lapisan konvolusional dan lapisan pooling. Lapisan klasifikasi terdiri dari beberapa lapisan yang terhubung sepenuhnya. Contoh dari arsitektur CNN seperti pada Gambar 2.3(Khairandish et al., 2022).



Gambar 2.3. CNN arsitektur umum analisis gambar

#### a. Layer Ekstraksi Fitur


Lapisan ekstraksi fitur adalah bagian awal dari arsitektur yang terdiri dari lapisan konvolusional dan lapisan pooling. Lapisan konvolusional bertugas mengidentifikasi pola penting dalam input, sedangkan lapisan pooling mengurangi dimensi fitur yang diekstraksi. Kedua lapisan ini menerapkan fungsi aktivasi untuk memperkenalkan non-linearitas. Hasilnya adalah vektor fitur yang akan diproses oleh lapisan selanjutnya dalam jaringan (Refianti et al., 2019).

##### 1. Lapisan Konvolusional

Lapisan Konvolusional adalah lapisan utama dalam arsitektur CNN. Pada lapisan ini, operasi konvolusi dilakukan untuk mengekstraksi fitur-fitur visual dari




citra input. Lapisan konvolusi terdiri dari sejumlah filter atau kernel yang digunakan untuk melaksanakan operasi konvolusi pada citra. Setiap kernel melakukan konvolusi pada bagian-bagian citra dan menghasilkan peta fitur yang mencerminkan kehadiran fitur-fitur yang spesifik dalam citra. Proses konvolusi melibatkan perkalian antara matriks bobot filter dengan bagian-bagian citra dan penjumlahan hasilnya (Lecun et al., 2015) seperti pada Gambar 2.4



Gambar 2.4. Contoh Proses Convolution

## 2. Lapisan Pooling

Setelah lapisan konvolusi, lapisan pooling digunakan untuk mengurangi dimensi peta fitur yang dihasilkan oleh lapisan konvolusi. Metode pooling yang umum digunakan adalah max pooling dan average pooling seperti pada **Error! Reference source not found.** Pada max pooling, nilai maksimum dari setiap jendela atau wilayah pada peta fitur dipertahankan, sementara pada average pooling, nilai rata-rata dari setiap jendela dipertahankan. Tujuan dari lapisan pooling adalah untuk mengurangi jumlah parameter dan komputasi yang diperlukan serta mempertahankan informasi penting dari peta fitur (Lecun et al., 2015).



Gambar 2.5. Contoh Proses Pooling

### 3. Activation Function

Fungsi aktivasi merupakan proses matematis yang mengaktifkan atau menonaktifkan neuron dalam jaringan saraf. Fungsi ini juga dikenal sebagai transfer function atau fungsi non-linear, karena mengubah fungsi linear dari jumlah berbobot menjadi model non-linear. Tujuan dari fungsi aktivasi adalah memperkenalkan non-linearitas ke dalam jaringan saraf, sehingga jaringan dapat mempelajari hubungan yang kompleks antara input dan output (Lecun et al., 2015). Salah satu contoh fungsi aktivasi yang umum digunakan adalah Rectified Linear Unit (ReLU). ReLU menghasilkan output 0 jika input negatif, dan menghasilkan input tersebut tanpa perubahan jika inputnya positif.

$$f(x) = \max(0, xi)$$

Keterangan:

$f(xi)$  = nilai dari ReLU activation

$Xi$  = nilai matriks dari citra

#### b. Lapisan Klasifikasi

Lapisan klasifikasi terdiri dari beberapa lapisan yang terhubung sepenuhnya (Fully Connected Layers). Setiap lapisan memiliki neuron yang menerima input


dari vektor fitur hasil lapisan ekstraksi. Dalam lapisan ini, seperti dalam Multi Neural Network, terdapat beberapa lapisan tersembunyi. Setiap lapisan melakukan transformasi pada input dan menghasilkan nilai-nilai penilaian kelas untuk klasifikasi. CNN memproses gambar secara bertahap, lapisan per lapisan, mengubah nilai piksel menjadi penilaian kelas. Setiap lapisan memiliki parameter hiper, termasuk bobot dan bias pada neuron, yang mempengaruhi hasil dari transformasi tersebut (Refianti et al., 2019).

### **1. Flatten**

Flatten dalam CNN adalah proses mengubah tensor multidimensi menjadi vektor satu dimensi. Ini dilakukan sebelum lapisan fully connected untuk memproses informasi fitur dalam proses klasifikasi atau regresi. Dalam flatten, tensor diubah menjadi vektor dengan menempatkan setiap elemen secara berurutan. Hal ini memungkinkan pengambilan informasi fitur yang diekstraksi sebelumnya dalam langkah-langkah sebelumnya.

### **2. Fully Connected Layers**

Fully Connected Layers adalah jenis lapisan dalam jaringan saraf di mana setiap neuron terhubung sepenuhnya dengan setiap neuron di lapisan sebelumnya dan setelahnya. Lapisan ini biasanya digunakan sebagai lapisan akhir dalam tugas klasifikasi atau regresi. Neuron-neuron di lapisan ini memiliki bobot dan bias yang diatur selama pelatihan jaringan untuk mempelajari hubungan kompleks antara input dan output. Lapisan terhubung penuh memungkinkan model jaringan saraf untuk memodelkan hubungan yang lebih kompleks, meskipun melibatkan banyak parameter seperti pada Gambar 2.6.



Gambar 2.6. Contoh Proses *Fully Connected Layer*

### 2.3.5. Transfer Learning


Transfer learning adalah pendekatan dalam pembelajaran mesin di mana pengetahuan yang telah diperoleh dari satu tugas atau domain dapat ditransfer dan digunakan dalam tugas atau domain lain yang terkait. Dalam konteks pengklasifikasian gambar, transfer learning melibatkan penggunaan model yang telah dilatih sebelumnya pada dataset yang besar dan beragam. Salah satu arsitektur jaringan saraf yang sering digunakan dalam transfer learning adalah ResNet (Residual Neural Network). ResNet menggunakan blok-blok residual yang memungkinkan jaringan untuk mengatasi masalah degradasi kinerja ketika jaringan menjadi lebih dalam. Arsitektur ResNet-50, sebagai varian dari ResNet, terdiri dari 50 lapisan dan telah terbukti berhasil dalam banyak tugas pengenalan gambar (Yosinski et al., 2014).

### 2.3.6. ResNet-50

Dalam penelitian ini, transfer learning menggunakan arsitektur ResNet-50 digunakan untuk mengklasifikasikan multi-kelas jenis penyakit kulit. Model



ResNet-50 telah dilatih pada dataset gambar yang beragam dan memiliki kemampuan untuk mengekstraksi fitur-fitur penting dari gambar. Dengan menerapkan transfer learning, model dapat memanfaatkan pengetahuan yang telah terkandung dalam ResNet-50 untuk meningkatkan kinerja pengklasifikasian jenis penyakit kulit (Yosinski et al., 2014). Seperti yang ditunjukkan dalam Gambar 2.7.



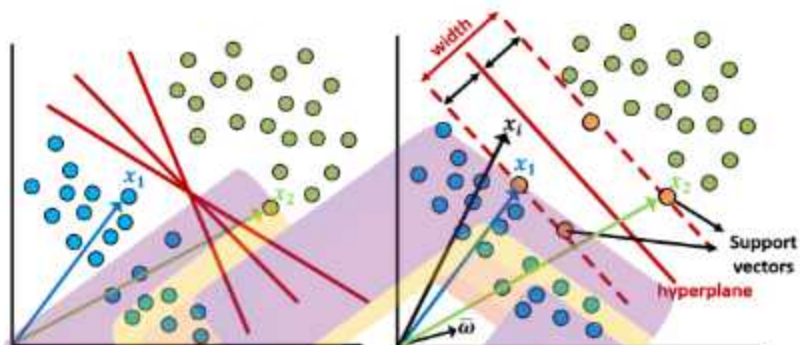
Gambar 2.7. Arsitektur ResNet-50

### 2.3.7. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah sebuah algoritma yang mengklasifikasikan data dengan mencari hyperplane terbaik yang memisahkan semua data dari satu kelas dengan data dari kelas lainnya. Algoritma ini dapat digunakan untuk pemisahan linear maupun pemisahan non-linear antara kelas-kelas tersebut. Pendekatan SVM dalam memecahkan masalah ini adalah dengan mempertimbangkan jarak terkecil antara garis keputusan (decision boundary) dan setiap sampel data. Pada klasifikasi linier SVM, ide utamanya adalah dengan memproyeksikan vektor tak diketahui  $x_i$  pada vektor  $\omega$  garis, yang harus tegak lurus dengan hyperplane keputusan (misalnya, berada di dimensi ketiga jika hyperplane keputusan terbentang di dua dimensi), dan memeriksa apakah vektor tersebut melintasi hyperplane pemisah atau tidak untuk menentukan klasifikasinya.



Implementasinya dimulai dengan mendapatkan hyperplane optimal SVM (Savas & Dosis, 2019).



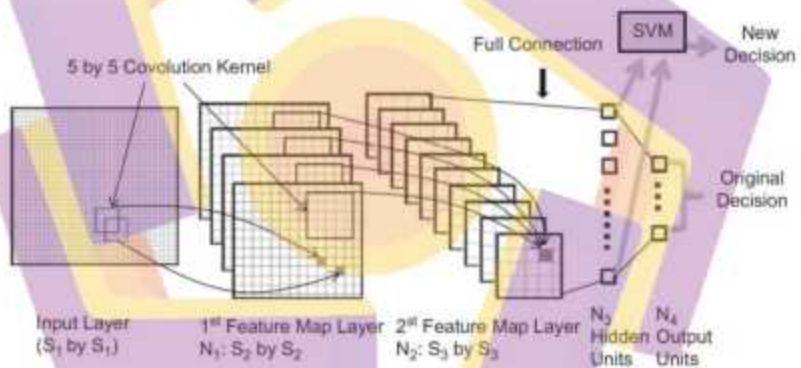
Gambar 2.8. Sketsa pengklasifikasi linier algoritma Support Vector Machines

Gambar 2.8. menunjukkan contoh ilustrasi dua set data yang dapat dipisahkan menjadi dua kelas. Meskipun demikian, pada Gambar kiri terdapat jumlah tak terhingga hyperplane pemisah yang mungkin. Dalam SVM, hyperplane terbaik dipilih berdasarkan margin terbesar antara kelas-kelas tersebut, seperti yang ditunjukkan pada Gambar kanan. Margin adalah lebar maksimum dari area yang tidak berisi sampel data dan sejajar dengan hyperplane pemisah. Sampel data yang berada paling dekat dengan hyperplane pemisah disebut vektor pendukung (support vectors), seperti yang terlihat pada Gambar kanan.

### 2.3.8. Kombinasi CNN-SVM

CNN-SVM adalah model gabungan yang menggabungkan CNN dan SVM dengan mengganti lapisan keluaran terakhir dari model CNN dengan pengklasifikasi SVM. Pada lapisan keluaran model CNN, probabilitas perkiraan untuk sampel masukan dihasilkan. Dalam proses CNN-SVM, gambar input yang

telah dinormalisasi dan dipusatkan dikirim ke lapisan input, dan model CNN dilatih melalui beberapa epoch sampai proses pelatihan konvergen. Kemudian, SVM dengan kernel linear dan kernel RBF (Radial Basis Function), yang digunakan dalam penelitian ini, menggantikan lapisan keluaran. SVM menggunakan keluaran dari lapisan tersembunyi sebagai fitur vektor baru untuk pelatihan. Setelah pengklasifikasi SVM terlatih dengan baik, pengenalan dan pengambilan keputusan dilakukan pada gambar pengujian menggunakan fitur yang diekstraksi secara otomatis (Santos & Welfer, 2019). Gabungan model CNN-SVM dapat dilihat pada Gambar 2.9.



Gambar 2.9. Model gabungan CNN-SVM

### 2.3.9. Augmentasi Data

Augmentasi data adalah teknik yang digunakan dalam pemrosesan data untuk menghasilkan variasi baru dari sampel data yang ada dengan melakukan transformasi atau modifikasi pada data asli. Tujuan dari augmentasi data adalah meningkatkan keberagaman dataset, mengurangi overfitting, dan meningkatkan kinerja model. Dalam konteks pengolahan gambar, augmentasi data dapat

mencakup berbagai transformasi seperti rotasi, pemotongan (cropping), pergeseran (shifting), pembalikan (flipping), perubahan skala (scaling), perubahan warna, penambahan noise, dan lain sebagainya. Dengan menerapkan transformasi-transformasi ini pada data gambar, kita dapat menghasilkan variasi baru dari gambar yang ada, sehingga meningkatkan jumlah sampel data yang dapat digunakan dalam pelatihan model (Yang et al., 2016).

#### **2.3.10. Normalisasi**

Selain itu, normalisasi data menggunakan metode Min-Max dilakukan untuk memastikan nilai piksel dalam rentang yang sama dan mencegah dominasi fitur-fitur tertentu. Normalisasi Min-Max merupakan teknik yang umum digunakan dalam pemrosesan citra untuk menjaga konsistensi dan memungkinkan model untuk lebih efisien mempelajari pola-pola yang terdapat dalam citra. Dengan mengubah rentang nilai piksel menjadi 0-1, normalisasi Min-Max dapat meningkatkan stabilitas pelatihan dan konvergensi model CNN (Yang et al., 2016).

#### **2.3.11. Confusion Matrix**

Evaluasi hasil klasifikasi adalah proses pengukuran tingkat akurasi kinerja suatu metode atau algoritma klasifikasi yang digunakan. Hasil klasifikasi sentimen akan dievaluasi menggunakan Confusion Matrix untuk menentukan nilai akurasi, presisi dan recall.

Confusion matrix berbentuk tabel matriks yang menjelaskan tentang kinerja model klasifikasi terhadap data uji yang nilai sebenarnya diketahui. Confusion matrix seperti pada Gambar 2.10.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	<b>TP</b> (True Positive)	<b>FP</b> (False Positive) <i>Type I Error</i>
	0 (Negative)	<b>FN</b> (False Negative) <i>Type II Error</i>	<b>TN</b> (True Negative)

Gambar 2.10. Confusion Matrix

Dari Gambar 2.10. diatas, ada empat macam kejadian yang bisa dijelaskan sebagai berikut:

1. TP (True Positive) = Jumlah data yang sebenarnya True diprediksi True.
2. TN (True Negative) = Jumlah data yang sebenarnya False diprediksi False.
3. FP (False Positive) = Jumlah data yang sebenarnya True diprediksi False.
4. FN (False Negative) = Jumlah data yang sebenarnya False diprediksi True.

Berdasarkan Confusion Matrix (4 macam kejadian) diatas, akan digunakan sebagai acuan untuk bisa menentukan nilai akurasi, presisi, Recall dan F1-Score.

#### a. Akurasi

Akurasi menggambarkan seberapa akurat model dapat mengklasifikasikan dengan benar. Akurasi diperoleh dari perbandingan rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Dengan kata lain, akurasi merupakan tingkat kedekatan nilai prediksi dengan nilai aktual (sebenarnya).



$$Akurasi = \frac{(TP + TN)}{(TP + FP + FN + TN)}$$

#### b. Presisi

Presisi menggambarkan tingkat keakuratan antara data yang diminta dengan hasil prediksi yang diberikan oleh model. Presisi diperoleh dari perbandingan rasio prediksi benar positif dengan keseluruhan hasil yang diprediksi positif. Dari semua kelas positif yang telah di prediksi dengan benar, berapa banyak data yang benar-benar positif.

$$Presisi = \frac{(TP)}{(TP + FP)}$$

#### c. Recall

Recall menggambarkan keberhasilan model dalam menemukan kembali sebuah informasi. Maka, recall merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif.

$$Recall = \frac{(TP)}{(TP + FN)}$$

Bagian ini memuat rangkuman teori-teori yang diambil dari buku atau literatur yang mendukung penelitian, serta memuat penjelasan tentang konsep dan prinsip dasar yang diperlukan untuk pemecahan permasalahan. Landasan teori dapat berbentuk uraian kualitatif, model matematis, atau tools yang langsung berkaitan dengan permasalahan yang diteliti. Sumber teori yang dirujuk pada bagian ini harus dicantumkan dalam kalimat atau pernyataan yang diacu dan dicantumkan dalam Daftar Pustaka.



## BAB III METODE PENELITIAN

### 3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini termasuk kedalam penelitian eksperimental yang melakukan pengujian dan perbandingan kinerja model CNN dan kombinasi CNN-SVM untuk mengklasifikasi multi-kelas jenis penyakit kulit manusia. Penelitian ini juga memiliki sifat kuantitatif karena menggunakan data yang dapat diukur secara kuantitatif untuk mengukur hasil kinerja model klasifikasi, seperti akurasi, presisi dan recall.

Pendekatan yang dilakukan dalam penelitian ini memiliki 2 pendekatan yaitu pertama pendekatan Deep Learning dengan memanfaatkan arsitektur CNN untuk melakukan ekstraksi fitur dari gambar penyakit kulit. CNN dapat mempelajari pola-pola kompleks pada tingkat piksel yang mendalam. Kedua, pendekatan klasifikasi SVM setelah ekstraksi fitur diperoleh SVM digunakan untuk melakukan klasifikasi multi-kelas jenis penyakit kulit manusia berdasarkan fitur-fitur yang diekstraks sebelumnya. SVM memiliki kemampuan untuk membangun batas keputusan yang optimal di antara kelas-kelas yang berbeda. Dengan menggunakan SVM, model dapat membedakan dan mengklasifikasikan penyakit kulit ke dalam kategori penyakit yang tepat berdasarkan fitur-fitur yang teridentifikasi melalui proses ekstraksi.

### 3.2. Metode Pengumpulan Data

Data yang digunakan pada penelitian ini adalah Dataset HAM10000, kumpulan besar gambar dermatoskopik dari lesi kulit berpigmen umum yang dikumpulkan dari berbagai sumber (Tschandl et al., 2018). Dataset dari website <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/DBW86T>. Dataset HAM10000 adalah kumpulan data yang berisi 10.015 gambar dermatoskopik dari 7 jenis penyakit kulit manusia yang berbeda yaitu Melanocytic Nevi (6705 gambar), Melanoma (1113 gambar), Benign Keratosis-like Lesions (1099 gambar), Basal Cell Carcinoma (514 gambar), Actinic Keratoses and Intraepithelial Carcinoma (327 gambar), Vascular Lesions (142 gambar) dan Dermatofibroma (115 gambar).

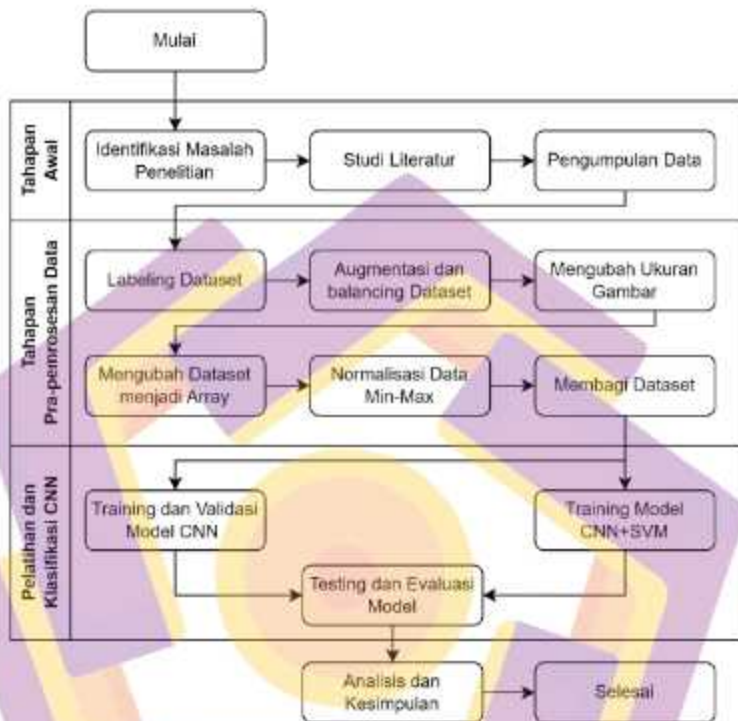
### 3.3. Metode Analisis Data

Penelitian ini menggunakan metode analisis data yang mengombinasikan Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) untuk mengklasifikasi tujuh jenis penyakit kulit manusia. Pada tahap pertama, model CNN ResNet-50 dilatih menggunakan data gambar lesi kulit untuk mengidentifikasi pola-pola penting dalam gambar tersebut. Kemudian, fitur-fitur yang diekstraksi dari CNN digunakan sebagai input untuk model SVM. SVM digunakan sebagai algoritma klasifikasi untuk membangun batas keputusan yang optimal dalam membedakan tujuh jenis penyakit kulit yang berbeda. Dengan menggunakan kombinasi CNN dan SVM, penelitian ini bertujuan untuk mencapai tingkat akurasi yang tinggi dalam mengklasifikasikan jenis penyakit kulit.

Setelah melatih model klasifikasi CNN-SVM, penelitian ini melakukan evaluasi dan analisis kinerja model. Metrik evaluasi seperti akurasi, presisi dan recall digunakan untuk mengukur sejauh mana model mampu mengklasifikasikan lesi kulit ke dalam kategori penyakit yang tepat. Dengan menggunakan metode analisis data ini, penelitian ini bertujuan untuk menghasilkan model yang mampu dengan akurat mengenali dan mengklasifikasikan tujuh jenis penyakit kulit. Performa model akan dianalisis untuk mengevaluasi keberhasilannya dalam membedakan jenis penyakit kulit manusia yang berbeda dan mengidentifikasi tingkat akurasi dalam melakukan klasifikasi.

#### **3.4. Alur Penelitian**

Alur penelitian ini melibatkan beberapa tahapan yaitu identifikasi tujuan penelitian, tinjauan pustaka, pengumpulan dataset, pra-pemrosesan data, pelatihan model CNN menggunakan ResNet-50 untuk ekstraksi fitur, Klasifikasi menggunakan CNN dan SVM, evaluasi performa menggunakan metrik evaluasi, analisis hasil dan kesimpulan. Untuk lebih jelasnya dapat dilihat pada Gambar 3.1. dibawah ini:



Gambar 3.1. Alur Penelitian

Pada Gambar 3.1. terdapat 4 tahapan alur penelitian dengan penjelasan sebagai berikut:

**a. Tahapan awal**

- a) Identifikasi Masalah Penelitian, dalam penelitian telah menentukan masalah sebagai berikut “Metode klasifikasi mana antara metode CNN dan kombinasi CNN-SVM yang memiliki performa terbaik dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia?”

- b) Studi literatur, Studi literatur dilakukan untuk mencari penelitian sebelumnya tentang klasifikasi penyakit kulit menggunakan metode CNN, SVM, atau kombinasi keduanya. Tujuan dari studi literatur ini adalah untuk menemukan peluang penelitian yang ada berdasarkan temuan dan hasil dari penelitian sebelumnya.
- c) Pengumpulan data, data yang digunakan yaitu Dataset HAM10000 yang di unduh dari website dataverse Harvard. Dataset HAM10000 adalah kumpulan data yang berisi 10.015 gambar dermatoskopik dari 7 jenis penyakit kulit manusia yang berbeda.

**b. Tahapan Pra-prosesan data**

- a) Labeling dataset, Pada tahap ini, setiap gambar dalam dataset dipisahkan kedalam folder yang diberikan label yang sesuai dengan jenis penyakit kulit yang terkandung di dalamnya.
- b) Augmentasi data, Augmentasi data dilakukan untuk meningkatkan keberagaman dataset, mencegah overfitting, dan memperkaya variasi dalam dataset untuk meningkatkan kualitas model. Adapun augmentasi yang dilakukan yaitu rotasi, pergeseran, pemutar balikan, perbesaran/pengecilan gambar, dan pengisian piksel kosong.
- c) Mengubah ukuran gambar, Pada dataset yang dikumpulkan ukuran gambar yang diunduh adalah 600x450 piksel. Namun, untuk menjaga konsistensi dan kesesuaian dengan arsitektur ResNet-50 yang digunakan, gambar-gambar tersebut diubah menjadi ukuran yang sama, yaitu 224x224 piksel.



d) Mengubah dataset menjadi array, Normalisasi data, Membagi dataset. Dataset gambar kemudian diubah menjadi array numerik untuk dapat diproses oleh model klasifikasi. Selain itu, dilakukan normalisasi data menggunakan metode Min-Max untuk memastikan nilai piksel dalam rentang yang sama dan mencegah dominasi fitur-fitur tertentu. Terakhir, dataset dapat dibagi menjadi tiga bagian, yaitu 80% data untuk pelatihan, 10% data untuk validasi, dan 10% data untuk pengujian model klasifikasi.


### **c. Tahapan Pelatihan dan Klasifikasi Model**

Setelah dilakukan pra-processing terhadap dataset, data tersebut kemudian akan digunakan pada proses pelatihan dan klasifikasi untuk menghasilkan model yang mampu mengenali dan mengklasifikasikan jenis penyakit kulit. Data pelatihan (80%) akan digunakan untuk melatih model agar dapat mengenali pola-pola yang mewakili setiap jenis penyakit secara efektif. Data validasi (10%) digunakan untuk mengevaluasi kinerja model selama pelatihan. Data pengujian (10%) digunakan untuk menguji kinerja akhir model setelah proses pelatihan selesai. Model yang telah dilatih akan diterapkan pada data pengujian yang tidak pernah dilihat sebelumnya. Hasil klasifikasinya akan dievaluasi untuk mengukur tingkat keberhasilan dalam mengenali dan mengklasifikasikan jenis penyakit kulit tersebut. Terdapat 2 model yang dibangun dan digunakan dalam tahapan ini yaitu Model CNN arsitektur ResNet50 dan Model CNN-SVM arsitektur ResNet50 sebagai berikut:

#### **a) Model CNN**

Dalam CNN arsitektur ResNet50 memiliki lapisan konvolusi yang bertanggung jawab untuk ekstraksi fitur dari gambar. Ketika gambar lesi kulit disampaikan ke model, lapisan konvolusi ResNet50 akan mengenali pola dan fitur-fitur penting dari gambar tersebut. Setelah ekstraksi fitur, ResNet50 akan menghasilkan representasi fitur yang kuat untuk setiap gambar lesi kulit. Representasi ini mencerminkan karakteristik yang signifikan dari gambar yang dapat membedakan antara jenis penyakit kulit yang berbeda.

Lapisan akhir dari ResNet50 akan bertindak sebagai lapisan klasifikasi. Ini akan menggunakan representasi fitur untuk mengklasifikasikan gambar lesi kulit ke dalam salah satu dari tujuh jenis penyakit kulit yang ditargetkan. Setelah proses klasifikasi selesai, model ResNet50 akan menghasilkan prediksi untuk setiap gambar lesi kulit. Proses klasifikasi menggunakan CNN seperti pada Gambar 3.2.



Gambar 3.2. Model CNN-ResNet50


#### b) Model CNN-SVM

Sama seperti sebelumnya dalam model CNN-SVM ini, CNN dengan arsitektur ResNet-50 digunakan untuk melakukan ekstraksi fitur dari gambar lesi kulit. Model CNN ini terdiri dari lapisan konvolusi yang dapat menggali

pola-pola kompleks pada tingkat piksel dengan mendalam. Ketika setiap gambar lesi kulit dimasukkan ke dalam model CNN, lapisan-lapisan konvolusi secara bertahap mengekstraksi fitur-fitur visual yang relevan dari gambar tersebut. Proses ini menciptakan representasi-fitur yang lebih abstrak, mencerminkan karakteristik unik dari setiap jenis penyakit kulit.

Ekstraksi fitur ini merupakan langkah penting dalam proses klasifikasi. Fitur-fitur tersebut dapat mencakup seperti garis tepi, pola tekstur, atau bentuk yang spesifik. Hasil dari langkah ekstraksi fitur ini kemudian dibentuk menjadi suatu vektor numerik yang disebut sebagai feature vector. Feature vector ini merepresentasikan informasi penting yang dihasilkan oleh model CNN dan menggambarkan karakteristik visual yang telah diekstraksi dari gambar. Feature vector ini tidak hanya sekadar kumpulan nilai numerik, tetapi menyimpan inti dari informasi visual yang ada dalam gambar, memungkinkan model untuk memahami dan memprosesnya secara lebih efektif.

Setelah feature vector terbentuk, langkah selanjutnya adalah menggunakan feature vector ini sebagai input untuk model Support Vector Machine (SVM) dalam proses klasifikasi, di mana SVM akan mempelajari batas keputusan optimal untuk membedakan antara 7 jenis penyakit kulit dalam kasus ini. Model SVM akan mencoba menemukan pola dalam data pelatihan yang membedakan penyakit kulit yang berbeda. Untuk detail dari model CNN-SVM dapat dilihat pada Gambar 3.3, dibawah.



Gambar 3.3. Model CNN-SVM

### c) Evaluasi Model

Setelah proses klasifikasi selesai, baik Model CNN maupun CNN-SVM akan menghasilkan prediksi untuk setiap gambar lesi kulit. Prediksi ini kemudian akan dievaluasi menggunakan metrik evaluasi seperti akurasi, presisi dan recall. Metrik-metrik ini sangat penting dalam mengevaluasi kinerja model dalam mengklasifikasikan gambar lesi kulit dengan benar.

Akurasi akan memberikan informasi tentang seberapa akurat model dalam melakukan klasifikasi secara keseluruhan, sedangkan presisi akan mengindikasikan sejauh mana prediksi positif yang dibuat oleh model benar. Recall akan menggambarkan sejauh mana model mampu mengenali kasus positif yang sebenarnya. Dengan menggunakan metrik-metrik evaluasi ini, dapat diukur dan dinilai kualitas dan kehandalan model klasifikasi CNN dan CNN-SVM dalam mengklasifikasikan gambar lesi kulit secara akurat.

### d. Analis dan Kesimpulan

Setelah evaluasi model selesai, langkah selanjutnya adalah melakukan analisis terhadap hasil evaluasi yang telah diperoleh. Analisis ini bertujuan



untuk memahami kinerja model secara lebih mendalam, mengidentifikasi kelebihan dan kekurangan model, serta melihat aspek-aspek yang perlu diperbaiki atau dioptimalkan.

Dalam analisis tersebut, kita dapat melihat perbandingan hasil evaluasi antara model CNN dan model CNN-SVM, serta membandingkannya dengan tujuan awal penelitian. Kita juga dapat menganalisis performa model dalam mengklasifikasikan setiap jenis penyakit kulit, melihat metrik evaluasi untuk setiap kelas penyakit, dan mengidentifikasi kelas mana yang memiliki performa lebih baik atau lebih buruk.

Berdasarkan hasil analisis, kita dapat menyimpulkan keberhasilan atau kegagalan model dalam mengklasifikasikan jenis penyakit kulit. Kesimpulan ini akan menjadi informasi penting dalam mengevaluasi apakah model yang dikembangkan sudah mencapai tujuan penelitian atau masih perlu diperbaiki. Kesimpulan ini juga dapat digunakan sebagai dasar untuk mengambil keputusan atau rekomendasi terkait penerapan model dalam praktik klinis atau penelitian lebih lanjut.







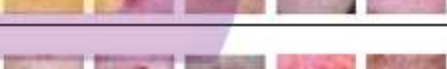


## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

#### 4.1. Pengumpulan Data

Data yang digunakan adalah Dataset HAM10000, kumpulan besar gambar dermatoskopik dari lesi kulit berpigmen umum yang dikumpulkan dari berbagai sumber (Tschandl et al., 2018). Dataset diperoleh dari website <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/DBW86T>. Dataset HAM10000 terdiri 10.015 gambar dengan 7 jenis penyakit kulit manusia yang berbeda, dengan rincian seperti pada Tabel 4.1.

Tabel 4.1. Rincian Dataset

No	Jenis Penyakit	Jumlah	Gambar
1	Melanocytic Nevi	6705	
2	Melanoma	1113	
3	Benign Keratosis-like Lesions	1099	
4	Basal Cell Carcinoma	514	
5	Actinic Keratoses and Intraepithelial Carcinoma	327	
6	Vascular Lesions	142	
7	Dermatofibroma	115	

## 4.2. Preprocessing Data

Sebelum data gambar penyakit kulit manusia dimasukkan ke dalam model klasifikasi, akan menjalankan serangkaian tahapan preprocessing data. Preprocessing data adalah tahapan yang kritis dalam pengembangan model pembelajaran mesin. Tujuan dari preprocessing ini adalah untuk mempersiapkan data yang akan digunakan dalam pelatihan model. Memahami langkah-langkah ini penting karena data yang bersih dan relevan adalah kunci untuk memastikan bahwa model yang dikembangkan dapat menghasilkan hasil klasifikasi yang akurat dan dapat diandalkan. Berikut adalah tahapan-tahapan yang dilakukan:

### 4.2.1. Labeling Data

Pada tahap ini, setiap gambar dalam dataset dipisahkan ke dalam folder yang diberikan label yang sesuai dengan jenis penyakit kulit yang terkandung di dalamnya. Hasil dari labeling dapat dilihat pada Tabel 4.2.

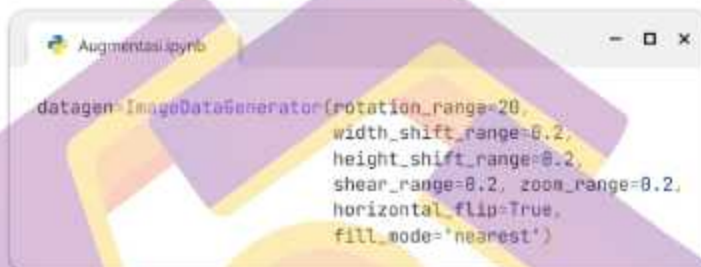
Tabel 4.2. Labeling dataset

No	Jenis Penyakit	Label Folder
1	Actinic Keratoses and Intraepithelial Carcinoma	akiec
2	Basal Cell Carcinoma	bcc
3	Benign Keratosis-like Lesions	bkl
4	Dermatofibroma	df
5	Melanocytic Nevi	nv
6	Melanoma	mel
7	Vascular Lesions	vasc

### 4.2.2. Augmentasi dan Balancing Data

Augmentasi data dilakukan untuk meningkatkan keberagaman dataset, mencegah overfitting, dan memperkaya variasi dalam dataset untuk meningkatkan

kualitas model, serta proses penyeimbangan (balancing) data agar setiap kelas penyakit memiliki jumlah sampel yang seimbang. Adapun augmentasi yang dilakukan yaitu rotasi, pergeseran, pemutar balikan, perbesaran/pengecilan gambar, dan pengisian piksel kosong. Proses ini dilakukan menggunakan bahasa pemrograman Python menggunakan perintah pada Gambar 4.1 berikut:



```

datagen=ImageDataGenerator(rotation_range=20,
                            width_shift_range=0.2,
                            height_shift_range=0.2,
                            shear_range=0.2, zoom_range=0.2,
                            horizontal_flip=True,
                            fill_mode='nearest')

```

Gambar 4.1. Kode Augmentasi

Berdasarkan perintah diatas, gambar-gambar dalam dataset mengalami berbagai transformasi menggunakan objek "ImageDataGenerator". Gambar-gambar dapat diputar hingga 20 derajat, bergeser baik secara horizontal maupun vertikal hingga 20% dari dimensi gambar asli, dan distorsi sudut (shear) dapat diterapkan hingga 20%. Selain itu, terdapat pilihan perbesaran gambar hingga 20% untuk menciptakan variasi dalam skala objek. Penggunaan flip horizontal juga digunakan, menciptakan cermin objek dalam gambar. Selama transformasi, area yang kosong dalam gambar diisi dengan nilai piksel terdekat. Melalui serangkaian transformasi ini, dataset diperkaya dengan variasi tampilan objek, membantu model untuk belajar dari berbagai kondisi dan sudut pandang. Pendekatan ini memastikan bahwa model yang dikembangkan mampu mengenali penyakit kulit manusia dalam berbagai situasi visual, meningkatkan kemampuannya dalam klasifikasi yang


akurat dan handal. Contoh hasil augmentasi yang dilakukan dapat dilihat pada Gambar 4.2.



Gambar 4.2. Contoh augmentasi gambar

Pada Gambar 4.2 diatas merupakan contoh dari augmentasi yang dilakukan pada salah satu gambar dataset (a) gambar sebelum augmentasi (b) sesudah augmentasi.


Balancing data diperoleh melalui proses augmentasi yang dilakukan pada setiap jenis penyakit, dengan cara meningkatkan atau mengurangi jumlah sampel menjadi 3000 gambar per kelas, sehingga totalnya menjadi 21 ribu gambar untuk 7 kelas penyakit. Teknik oversampling digunakan untuk memperbanyak sampel pada kelas minoritas, sementara teknik undersampling digunakan untuk mengurangi jumlah sampel pada kelas mayoritas. Jumlah dataset sebelum dan sesudah proses balancing dapat dilihat pada Gambar 4.3



Gambar 4.3. Jumlah dataset sebelum dan sesudah proses blancing data.

### 4.2.3. Mengubah ukuran gambar

Pada dataset yang dikumpulkan ukuran gambar yang diunduh adalah 600x450 piksel. Namun, untuk menjaga konsistensi dan kesesuaian dengan arsitektur ResNet-50 yang digunakan, gambar-gambar tersebut diubah menjadi ukuran yang sama, yaitu 224x224 piksel seperti pada Error! Reference source not found.. Hal ini dilakukan agar memudahkan kompatibilitas dengan arsitektur model dan juga untuk meningkatkan efisiensi komputasi. Dengan demikian, semua gambar dalam dataset memiliki ukuran yang seragam dan siap untuk digunakan dalam tahap pelatihan dan klasifikasi menggunakan model ResNet-50.



Gambar 4.4 Mengubah Ukuran Gambar

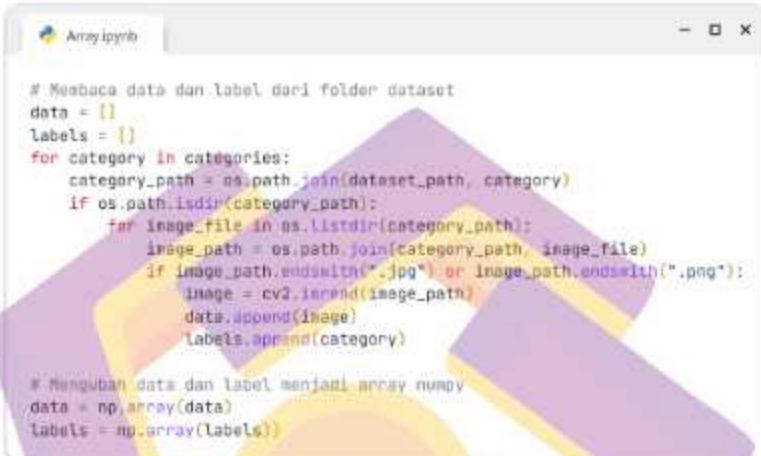
### 4.2.4. Mengubah dataset menjadi array

Mengubah dataset gambar menjadi format yang dapat dipahami oleh model pembelajaran mesin, yaitu dalam bentuk array numerik. Dimana setiap elemen matriks mewakili nilai piksel dari gambar tersebut. Proses ini bertujuan untuk membuat data yang dapat dimengerti oleh model, sehingga model dapat memproses dan mempelajari pola-pola yang ada dalam gambar.

Untuk melakukan konversi ini, kita memanfaatkan library OpenCV dalam bahasa pemrograman Python. Dengan bantuan OpenCV, gambar-gambar tersebut dibaca, diubah menjadi array numerik, dan disusun ke dalam bentuk data yang siap



digunakan dalam pelatihan model. Untuk perintah program yang digunakan pada Gambar 4.5 berikut:



```
# Membaca data dan label dari folder dataset
data = []
labels = []
for category in categories:
    category_path = os.path.join(dataset_path, category)
    if os.path.isdir(category_path):
        for image_file in os.listdir(category_path):
            image_path = os.path.join(category_path, image_file)
            if image_path.endswith(".jpg") or image_path.endswith(".png"):
                image = cv2.imread(image_path)
                data.append(image)
                labels.append(category)

# Mengubah data dan label menjadi array numpy
data = np.array(data)
labels = np.array(labels)
```

Gambar 4.5. Kode Mengubah Dataset Menjadi Array

Kode tersebut berfungsi untuk membaca data gambar dan label dari folder dataset. Proses dimulai dengan inisialisasi dua list kosong, yaitu "data" untuk menyimpan gambar dan "labels" untuk menyimpan label dari masing-masing gambar. Selanjutnya, kode melakukan iterasi melalui setiap kategori (jenis penyakit) di dalam folder dataset. Untuk setiap gambar dalam kategori, kode menggunakan OpenCV untuk membaca gambar dan menyimpannya dalam bentuk matriks gambar. Matriks gambar tersebut kemudian ditambahkan ke dalam list "data". Selain itu, nama kategori juga ditambahkan ke list "labels" untuk setiap gambar, sehingga setiap gambar memiliki label yang sesuai dengan jenis penyakitnya.

Setelah proses membaca gambar dan menambahkan label selesai, list “data” dan “labels” diubah menjadi array Numpy menggunakan “np.array()”. Hal ini mengonversi data gambar ke format yang sesuai untuk digunakan dalam model machine learning. Dengan demikian, kode ini mempersiapkan data dalam bentuk yang dapat digunakan untuk melatih dan menguji model machine learning pada dataset tersebut.

#### **4.2.5. Membagi dataset**

Dataset kemudian dibagi menjadi data pelatihan, validasi, dan pengujian untuk digunakan pengembangan model klasifikasi. Dari total 20,000 dataset dibagi menjadi 80% untuk pelatihan model CNN, 10% untuk validasi model CNN, dan 10% untuk pengujian model CNN. Selanjutnya, model CNN-SVM menggunakan 80% data untuk pelatihan dan 20% data untuk pengujian.

Penggunaan data validasi pada model CNN adalah karena proses penyetelan parameter pada CNN melibatkan kompleksitas yang memerlukan validasi untuk mengoptimalkan kinerja model, sedangkan pada model CNN-SVM, fokus utama adalah pada ekstraksi fitur oleh CNN dan klasifikasi oleh SVM, yang tidak memerlukan penyetelan parameter yang sama dengan tingkat kompleksitas.

#### **4.2.6. Normalisasi data**

Proses normalisasi data merupakan langkah penting dalam mempersiapkan dataset gambar penyakit kulit manusia untuk model klasifikasi. Pada tahapan ini, nilai intensitas piksel dalam setiap gambar dinormalisasi dengan membaginya oleh nilai maksimal piksel yang mungkin, yaitu 255.0. Implementasi normalisasi pada

dataset pelatihan ( $X_{train}$ ), dataset validasi ( $X_{val}$ ), dan dataset pengujian ( $X_{test}$ ) dapat dilihat dalam kode pada Gambar 4.6 berikut:



```
Normalisasi data.ipynb
X_train = X_train / 255.0
X_val = X_val / 255.0
X_test = X_test / 255.0
```

Gambar 4.6. Kode Normalisasi Data

Proses ini bertujuan mencapai konsistensi nilai piksel di seluruh gambar, sehingga model CNN dan CNN-SVM dapat mengolah data secara seragam tanpa terpengaruh oleh variasi intensitas warna antar gambar. Normalisasi juga berkontribusi pada percepatan konvergensi model selama pelatihan.

Hasil normalisasi, yaitu nilai piksel yang berada dalam rentang 0 hingga 1, memungkinkan model untuk belajar lebih efisien. Dengan fokus pada pola-pola utama yang mengidentifikasi jenis penyakit kulit manusia, proses ini secara positif memengaruhi akurasi dan keandalan model klasifikasi. Ini menjamin bahwa hasil klasifikasi dapat diandalkan dalam konteks identifikasi penyakit kulit manusia secara otomatis.

### 4.3. Implementasi dan Hasil Model CNN

#### 4.3.1. Rincian Implementasi Model CNN

Dalam implementasi model Convolutional Neural Network (CNN) dengan menggunakan arsitektur ResNet50, langkah-langkah berikut diambil untuk memastikan kelancaran klasifikasi multi-kelas jenis penyakit kulit manusia sebagai berikut:

### a) Membangun Model CNN

Model CNN dibangun dengan memanfaatkan arsitektur ResNet50, yang telah terbukti efektif dalam mengatasi masalah kompleksitas gambar medis. Penggunaan ResNet50 dari Keras memungkinkan kami menggunakan model pre-trained yang telah memahami fitur-fitur tingkat tinggi dari dataset gambar umum. Kode implementasi berikut memberikan gambaran tentang penggunaan ResNet50.



```

import cv2
import os
import numpy as np
import seaborn as sns
import tensorflow as tf
from sklearn.svm import SVC
from google.colab import drive
import matplotlib.pyplot as plt
from tensorflow.keras.applications.resnet50 import ResNet50, preprocess_input
from tensorflow.keras.layers import Sequential, Dense, GlobalAveragePooling2D
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.callbacks import ModelCheckpoint
from sklearn.preprocessing import LabelEncoder
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score,
confusion_matrix
  
```

Gambar 4.7. Kode Modul

Pada script kode Gambar 4.7 di atas merupakan berbagai modul yang diimpor untuk digunakan dalam pengembangan, pelatihan, dan evaluasi metode Convolutional Neural Network (CNN) serta kombinasi CNN dengan Support Vector Machine (CNN-SVM). Modul-modul ini mencakup alat-alat esensial seperti manipulasi gambar, operasi sistem, dan pembuatan model deep learning menggunakan TensorFlow. Selain itu, terdapat modul untuk visualisasi data, implementasi Support Vector Classifier (SVC), dan akses ke Google Drive.

Semua modul ini akan berperan penting dalam tahap-tahap pengembangan dan evaluasi model klasifikasi penyakit kulit.

Pertama, modul "cv2" digunakan untuk manipulasi gambar, "os" untuk operasi sistem, dan "numpy" untuk manipulasi array dan operasi matematika. "Seaborn" digunakan untuk visualisasi data dan plot, sementara "tensorflow" memberikan platform untuk membangun dan melatih model deep learning. Modul "SVC" dari "sklearn" digunakan untuk implementasi Support Vector Classifier (SVM). "Drive" dari "google.colab" memungkinkan akses ke Google Drive. "Matplotlib.pyplot" digunakan untuk plotting. Modul "ResNet50" dan "preprocess\_input" dari "tensorflow.keras.applications" memberikan akses ke arsitektur ResNet50 dan fungsi preprocessing. "Sequential", "Dense", dan "GlobalAveragePooling2D" dari "tensorflow.keras.layers" digunakan untuk membangun model neural network. Modul "ImageDataGenerator" dari "tensorflow.keras.preprocessing.image" digunakan untuk augmentasi gambar. "ModelCheckpoint" dari "tensorflow.keras.callbacks" digunakan untuk menyimpan model dengan akurasi validasi terbaik. "LabelEncoder" dari "sklearn.preprocessing" digunakan untuk mengkodekan label kelas. Modul "train\_test\_split" dari "sklearn.model\_selection" membantu dalam pembagian dataset. "accuracy\_score", "precision\_score", "recall\_score", "f1\_score", dan "confusion\_matrix" dari "sklearn.metrics" memberikan metrik evaluasi kinerja model.



```

ResNet50.ipynb
# Membangun model ResNet-50
num_classes = 7
base_model = resnet50(include_top=False, weights='imagenet', input_shape=(224, 224, 3))

# Menambahkan layer klasifikasi di atas model ResNet-50
model = tf.keras.models.Sequential()
model.add(base_model)
model.add(tf.keras.layers.GlobalAveragePooling2D())
model.add(tf.keras.layers.Dropout(0.7))
model.add(tf.keras.layers.Dense(num_classes, activation='softmax'))

```

Gambar 4.8. Kode Membangun Model CNN

Pada Gambar 4.8 Base Model ResNet50 berfungsi sebagai dasar model karena menerapkan transfer learning. Dalam konteks ini, transfer learning memungkinkan model untuk memanfaatkan pengetahuan yang sudah ada dari pelatihan sebelumnya pada dataset besar, seperti ImageNet. Dengan menggunakan model yang telah terlatih, ResNet50 dapat mendeteksi fitur-fitur tingkat tinggi pada gambar penyakit kulit manusia tanpa perlu memulai pembelajaran dari awal. Ini mempercepat proses pelatihan dan membantu model memahami pola yang umum dalam dataset gambar.

Layer Global Average Pooling (GAP) berfungsi untuk menyederhanakan representasi spasial dari setiap fitur dalam matriks hasil konvolusi. Dengan meratakan fitur-fitur ini, GAP menghasilkan vektor rata-rata yang mewakili fitur-fitur penting dari seluruh gambar. Ini membantu model untuk lebih fokus pada aspek-aspek yang paling penting dalam gambar, mengurangi kompleksitas representasi spasial.

Penambahan layer Dropout (0.7) pada model ResNet-50 bertujuan untuk mengurangi overfitting selama proses pelatihan. Overfitting terjadi ketika model terlalu mempelajari pola yang spesifik pada data pelatihan, yang dapat menghambat

kemampuan generalisasi pada data baru. Dengan menggunakan Dropout, sekitar 70% dari unit (neuron) pada layer tersebut diabaikan secara acak selama setiap iterasi pelatihan. Hal ini membantu mencegah model terlalu bergantung pada ketergantungan tertentu dan meningkatkan kemungkinan generalisasi yang lebih baik pada data validasi atau uji. Dropout adalah teknik regularisasi yang umum digunakan dalam jaringan saraf untuk meningkatkan kinerja model pada data yang tidak terlihat selama pelatihan.

Dense Layer dengan Softmax Activation, Lapisan Dense terakhir dalam model menggunakan fungsi aktivasi softmax. Fungsi ini digunakan untuk menghasilkan distribusi probabilitas kelas. Dalam konteks klasifikasi multi-kelas jenis penyakit kulit manusia, softmax membantu model mengeluarkan prediksi dalam bentuk probabilitas untuk setiap kelas. Kelas dengan probabilitas tertinggi dianggap sebagai prediksi akhir model.

Softmax membuat output model menjadi interpretatif. Probabilitas yang dihasilkan memberikan informasi tentang seberapa yakin model terhadap setiap kelas. Dengan melihat nilai probabilitas, kita dapat memahami sejauh mana model yakin terhadap prediksinya, membantu interpretasi hasil model.

Fungsi softmax sering digunakan bersama dengan fungsi loss categorical crossentropy. Selama pelatihan, model berusaha mengoptimalkan distribusi probabilitas agar mendekati distribusi probabilitas yang sebenarnya. Ini membimbing model untuk memahami dan membedakan antara berbagai kelas penyakit kulit.

Dengan menggunakan ResNet50 sebagai dasar model dan menambahkan lapisan GAP dan Dense dengan softmax activation, model ini dirancang untuk mengoptimalkan kinerja klasifikasi multi-kelas pada jenis penyakit kulit manusia dengan memanfaatkan pengetahuan yang sudah ada dan memfokuskan perhatian pada fitur-fitur yang paling penting dalam gambar.

#### b) Pelatihan Model

Selanjutnya proses pelatihan model dilakukan dengan menggunakan data gambar yang telah dipersiapkan pada tahapan preprocessing data sebelumnya. Kode pelatihan berikut memberikan gambaran detail tentang langkah-langkahnya:



```

# Melatih model
batch_size = 64
epochs = 100

optimizer = tf.keras.optimizers.SGD(learning_rate=0.001, momentum=0.9)
model.compile(optimizer=optimizer, loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
history = model.fit(X_train, y_train_encoded, batch_size=batch_size,
                   epochs=epochs, validation_data=(X_val, y_val_encoded),
                   callbacks=[checkpoint_callback])

```

Gambar 4.9. Kode Pelatihan Model

Pada Gambar 4.9, Stochastic Gradient Descent (SGD) dengan momentum 0.9, Optimizer berperan dalam menyesuaikan bobot (weights) model selama proses pelatihan untuk mengoptimalkan fungsi loss. SGD bekerja dengan memperbarui bobot berdasarkan gradien dari fungsi loss terhadap bobot tersebut.

Learning rate merupakan parameter yang menentukan seberapa besar langkah-langkah pembaruan bobot dilakukan selama pelatihan. Pemilihan learning rate yang tepat kritis untuk keberhasilan pelatihan model. Dalam penelitian ini,

learning rate sebesar 0.001 dipilih untuk mengendalikan sejauh mana model menyesuaikan bobotnya setiap kali pembaharuan dilakukan. Nilai ini dianggap cukup kecil untuk memastikan konvergensi yang stabil.

Sparse Categorical Crossentropy Loss digunakan untuk mengukur seberapa baik prediksi model mendekati label yang sebenarnya. Pada tugas klasifikasi multi-kelas seperti ini, di mana label direpresentasikan sebagai integer, Sparse Categorical Crossentropy Loss merupakan pilihan yang tepat. Fungsi ini secara khusus dirancang untuk menangani tugas klasifikasi dengan lebih dari dua kelas.

Batch size mengontrol jumlah sampel yang digunakan untuk memperbarui bobot dalam satu iterasi. Pemilihan batch size memengaruhi kecepatan pelatihan dan penggunaan sumber daya komputasi. Dalam penelitian ini, batch size sebesar 64 dipilih. Nilai ini dapat memberikan keseimbangan yang baik antara efisiensi komputasi dan keakuratan model.

Epoch menunjukkan berapa kali seluruh dataset digunakan selama pelatihan. Pemilihan jumlah epochs memengaruhi sejauh mana model dapat belajar dari dataset. Dalam penelitian ini, pelatihan dilakukan sebanyak 100 epochs, yang dapat memberikan waktu yang cukup bagi model untuk menyesuaikan bobotnya dengan baik terhadap data pelatihan.

Dengan kombinasi optimizer SGD dengan learning rate 0.001 dan momentum 0.9, fungsi loss Sparse Categorical Crossentropy, batch size 64, dan 100 epochs, model dirancang untuk mengoptimalkan kinerjanya dalam klasifikasi multi-kelas jenis penyakit kulit manusia. Penyesuaian parameter ini didasarkan



pada kebutuhan untuk mencapai keseimbangan antara akurasi, stabilitas konvergensi, dan efisiensi komputasi.

### c) Evaluasi Model

Setelah pelatihan selesai, model dievaluasi untuk memahami seberapa baik model dapat menggeneralisasi pengetahuannya ke dataset pengujian. Kode evaluasi berikut memberikan detail tentang penggunaan beberapa metrik evaluasi kinerja model:



```

# Evaluasi model
accuracy = model.evaluate(X_test, y_test_encoded)[1]
loss = model.evaluate(X_test, y_test_encoded)[0]

# Confusion Matrix
predictions_classes = np.argmax(predictions, axis=1)
conf_matrix = confusion_matrix(y_test_encoded, predictions_classes)

```

Gambar 4.10. Kode Evaluasi Model


Pada Gambar 4.10 tahap evaluasi kinerja model Convolutional Neural Network (CNN), dua metrik utama yang digunakan adalah akurasi dan fungsi kerugian. Fungsi “model.evaluate” diimplementasikan untuk memperoleh nilai akurasi dan fungsi kerugian pada dataset pengujian. Akurasi memberikan gambaran persentase seberapa baik model mampu mengklasifikasikan data dengan benar, sementara fungsi kerugian mengukur seberapa baik model memperkirakan label kelas yang sebenarnya. Akurasi menjadi penting untuk mengevaluasi sejauh mana model berhasil dalam mengenali berbagai jenis penyakit kulit. Di sisi lain, fungsi kerugian memberikan informasi tentang seberapa besar kesalahan model dalam memperkirakan label kelas yang benar.



Selain itu, untuk mendapatkan pemahaman yang lebih rinci tentang kinerja model pada setiap kelas, digunakan metode "confusion\_matrix". Matriks kebingungan menyajikan detail True Positives (TP), True Negatives (TN), False Positives (FP), dan False Negatives (FN) untuk setiap kelas. TP dan TN mewakili jumlah data yang benar-benar diklasifikasikan dengan benar oleh model, sedangkan FP dan FN mencerminkan kesalahan model. Matriks kebingungan memberikan wawasan yang sangat berguna untuk mengidentifikasi di mana model cenderung membuat kesalahan, seperti kelas yang sulit dikenali atau kecenderungan untuk membingungkan antara kelas tertentu. Dengan demikian, kombinasi penggunaan akurasi, fungsi kerugian, dan matriks kebingungan memberikan pemahaman yang holistik tentang kinerja model CNN dalam konteks klasifikasi multi-kelas jenis penyakit kulit manusia.

#### **4.3.2. Hasil Pelatihan dan Validasi Model**

Dalam bab ini, kita akan mengulas bagaimana model kita berhasil selama pelatihan dan validasi. Akurasi pelatihan mencerminkan sejauh mana model mampu memahami pola dalam data pelatihan, sedangkan akurasi validasi memberikan gambaran tentang kinerja model pada data baru. Sementara itu, Kehilangan pelatihan mengukur seberapa baik model mempelajari pola dalam data pelatihan, dan kehilangan pelatihan yang lebih rendah menunjukkan adaptasi model yang lebih baik terhadap data pelatihan. Untuk lebih jelas hasil pelatihan dan validasi model dapat dilihat pada Gambar 4.11, yang memvisualisasikan perubahan akurasi dan kehilangan selama proses pelatihan.



Gambar 4.11. Pelatihan dan Validasi Akurasi dan Loss

Dari Gambar 4.11, kita dapat melihat bahwa akurasi pelatihan mencapai puncaknya pada epoch 55 dengan tingkat akurasi 99%, sedangkan akurasi validasi mencapai puncak tertinggi pada epoch 96 dengan tingkat akurasi 94%. Ini menunjukkan bahwa model mampu memahami data pelatihan dengan sangat baik dan dapat berkinerja baik pada data yang baru.

Selain itu, kita juga memeriksa kehilangan pelatihan, yang memberi tahu kita seberapa baik model belajar selama pelatihan. Kita mencapai kehilangan pelatihan terendah pada epoch 84 dengan nilai 0,0053, sementara kehilangan validasi terendah terjadi pada epoch 27 dengan nilai 0,2350. Ini menunjukkan bahwa model kita belajar dengan baik dari data pelatihan dan mampu mengenali pola pada data tersebut. Secara keseluruhan, hasil ini memberikan gambaran positif tentang kemampuan model. Model dapat mengenali pola dengan baik pada data pelatihan, dan kemampuannya untuk berkinerja pada data baru diuji dengan baik.

#### 4.3.3. Hasil Evaluasi Model CNN

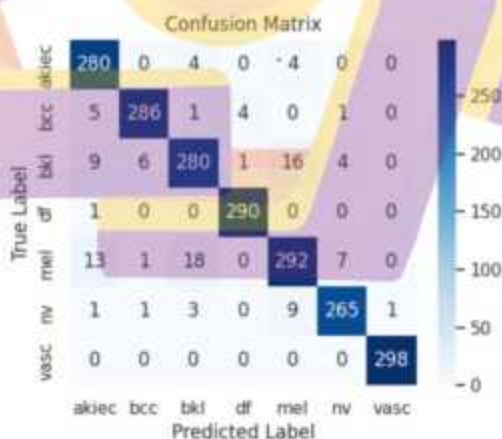
Hasil kinerja model Convolutional Neural Network (CNN) pada penelitian ini menampilkan temuan yang sangat positif, menunjukkan kemampuan model dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia. Evaluasi kinerja keseluruhan melibatkan metrik utama seperti akurasi, presisi, recall, dan F1

Score, memberikan pandangan yang holistik tentang kemampuan model. Tabel 4.3. merangkum hasil evaluasi.

Tabel 4.3. Evaluasi Kinerja Model CNN

No	Metric	Nilai
1	Akurasi	94.76%
2	Presisi	94.85%
3	Recall	94.94%
4	F1 Score	94.87%

Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan hampir 95% dari total dataset pengujian dengan akurasi yang tinggi. Presisi dan recall yang baik menandakan kemampuan model untuk memberikan prediksi positif yang tepat dan mengidentifikasi sebagian besar kasus positif. Selanjutnya, evaluasi per kelas memberikan wawasan rinci tentang kinerja model pada setiap jenis penyakit kulit, seperti yang tercantum dalam Tabel 4.4, dan hasil Confusion Matrix dari CNN dapat dilihat pada Gambar 4.12.



Gambar 4.12. Confusion matrix CNN

Gambar 4.12. Confusion matrix diatas memberikan pandangan yang lebih rinci tentang bagaimana model kita mengklasifikasikan data pada setiap kelas. Matriks ini berguna untuk mengevaluasi kinerja model pada tingkat kelas, memberikan wawasan tentang seberapa baik atau buruk model dalam mengidentifikasi setiap kategori. akiec: Actinic Keratosis, bcc: Basal Cell Carcinoma, bkl: Benign Keratosis, df: Dermatofibroma, mel: Melanoma, nv: Melanocytic Necus, dan vasc: Vascular Lesion. Dari konfusi matrix diatas, kita dapat membahas secara rinci akurasi per kelas dari model ini untuk masing-masing jenis penyakit kulit, yang tercantum dalam Tabel 4.4.

Tabel 4.4. Akurasi Per Kelas Model CNN

No	Kelas	Akurasi
1	akiec	97.22%
2	bcc	96.30%
3	bkl	88.61%
4	df	99.66%
5	mel	88.22%
6	vasc	94.64%
7	nv	100%

Pada Tabel 4.4. dapat dilihat bahwa tingkat akurasi yang tinggi pada beberapa kelas, seperti nv (100.00%) dan df (99.66%), menunjukkan keunggulan model dalam mengklasifikasikan kelas-kelas ini. Meskipun demikian, kelas bkl (88.61%) dan kelas mel (88.22%) menunjukkan tingkat akurasi yang sedikit lebih rendah, menandakan area potensial untuk peningkatan. Dengan demikian, Hasil kinerja model CNN memberikan gambaran positif tentang efektivitas model dalam mendukung klasifikasi multi-kelas jenis penyakit kulit manusia secara otomatis.



#### **4.3.4. Diskusi Hasil Pengujian pada Model CNN**

Pada hasil evaluasi diatas, dapat disimpulkan bahwa model CNN berhasil dengan baik dalam tugas klasifikasi multi-kelas jenis penyakit kulit manusia. Akurasi yang tinggi menunjukkan kemampuan model untuk secara efektif mengenali dan mengklasifikasikan berbagai jenis penyakit kulit. Presisi dan recall yang tinggi menandakan kemampuan model dalam memberikan prediksi yang akurat dan sekaligus menghindari kesalahan klasifikasi yang signifikan.

Diskusi lebih lanjut dapat dilakukan untuk memahami performa model pada setiap kelas penyakit kulit secara spesifik. Identifikasi kelas dengan akurasi lebih rendah dapat menjadi fokus untuk perbaikan atau peningkatan model di masa mendatang. Kesimpulan diskusi ini memberikan dasar yang kuat untuk percaya pada kemampuan model CNN dalam mendukung klasifikasi jenis penyakit kulit manusia secara otomatis.

#### **4.4. Implementasi dan Hasil Model CNN-SVM**

##### **4.4.1. Rincian Implementasi Model CNN-SVM**

Pada tahap ini, kami akan menjelaskan secara detail implementasi model CNN-SVM, yang melibatkan proses pembangunan model CNN-SVM, ekstraksi fitur, pelatihan, dan evaluasi model CNN-SVM untuk klasifikasi multi-kelas jenis penyakit kulit manusia.

##### **a) Membangun Model CNN-SVM**

Arsitektur ResNet50, dalam konteks CNN-SVM, digunakan sebagai model pre-trained untuk melakukan ekstraksi fitur dari gambar penyakit kulit manusia.



ResNet50 terkenal karena kemampuannya menangani tantangan vanishing gradient dan memungkinkan pelatihan model yang lebih dalam.



```

Model ResNet50.py:nb
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import GlobalAveragePooling2D
from tensorflow.keras.models import Model

# Bangun model ResNet50 untuk ekstraksi fitur
base_model = ResNet50(include_top=False, weights='imagenet', input_shape=(224, 224, 3))

# Menambahkan lapisan global pooling di atas model ResNet50
x = base_model.output
x = GlobalAveragePooling2D()(x)

# Mendefinisikan model CNN-SVM
model = Model(inputs=base_model.input, outputs=x)

```

Gambar 4.13. Kode Membangun Model CNN-SVM

Pada Gambar 4.13 ResNet50 memiliki arsitektur yang mendalam dengan blok-blok residual, memungkinkan pelatihan model dengan lebih banyak lapisan tanpa degradasi kinerja. Blok residual memungkinkan aliran gradien yang efisien melalui jaringan, memudahkan pelatihan model yang mendalam. Dalam konteks ini, bagian fully connected dari ResNet50 (`include_top=False`) tidak digunakan, karena kita hanya tertarik pada fitur-fitur yang dihasilkan oleh lapisan-lapisan konvolusi.

Setelah melakukan ekstraksi fitur dari lapisan-lapisan konvolusi ResNet50, lapisan global pooling ditambahkan di atasnya. Global Average Pooling (GAP) adalah teknik yang menghitung rata-rata dari setiap fitur di seluruh matriks fitur, menghasilkan vektor fitur global. GAP membantu mengurangi dimensi data secara signifikan, membuatnya lebih efisien untuk digunakan oleh model klasifikasi selanjutnya.

Dengan menggabungkan ResNet50 untuk ekstraksi fitur dan lapisan global pooling, kita mendapatkan representasi fitur yang efisien dan berguna untuk digunakan dalam model klasifikasi SVM pada tahap berikutnya.

#### **b) Membangun Kernel SVM**

Setelah proses ekstraksi fitur menggunakan arsitektur ResNet50 dan lapisan global pooling, langkah selanjutnya adalah melatih model menggunakan metode Support Vector Machine (SVM) dengan empat jenis kernel yang berbeda untuk melengkapi model Convolutional Neural Network (CNN) yang digunakan sebagai ekstraksi fitur. SVM dengan kernel Polynomial (Poly) menerapkan fungsi polinomial untuk menangani pola yang kompleks dan non-linear pada data. Kernel Radial Basis Function (RBF) menggunakan fungsi Gaussian untuk menangani pola non-linear dan kompleks.

Kernel Linear digunakan untuk pemisahan linear pada data, ideal untuk situasi di mana kelas dapat dipisahkan dengan jelas secara linear. Terakhir, kernel Sigmoid menggunakan fungsi sigmoid untuk menangani pola non-linear dengan bentuk yang kompleks. Setiap kernel memiliki karakteristik dan fungsi masing-masing, yang berpengaruh pada kemampuan model dalam menangkap pola dan memisahkan kelas pada data jenis penyakit kulit manusia. Koding yang digunakan untuk masing-masing kernel dapat dilihat pada Gambar 4.14.

```

Polynomial.ipynb
svm_poly = SVC(kernel='poly')
svm_poly.fit(features_train, np.argmax(y_train, axis=1))

Radial Basis Function.ipynb
svm_rbf = SVC(kernel='rbf')
svm_rbf.fit(features_train, np.argmax(y_train, axis=1))

Linear.ipynb
svm_linear = SVC(kernel='linear')
svm_linear.fit(features_train, np.argmax(y_train, axis=1))

sigmoid.ipynb
svm_sigmoid = SVC(kernel='sigmoid')
svm_sigmoid.fit(features_train, np.argmax(y_train, axis=1))

```

Gambar 4.14. Kode Kernel SVM

Dengan menggabungkan model CNN sebagai ekstraktor fitur dan SVM dengan berbagai kernel, penelitian ini memungkinkan eksplorasi variasi dalam menangkap pola pada data jenis penyakit kulit manusia. Perbandingan kinerja antar kernel memberikan informasi kritis untuk pemilihan model yang paling efektif dalam konteks klasifikasi multi-kelas pada dataset ini.

### c) Evaluasi Kinerja Model

Evaluasi kinerja model CNN-SVM dilakukan dengan mempertimbangkan empat jenis kernel yang berbeda, yakni Polynomial (Poly), Radial Basis Function (RBF), Linear, dan Sigmoid. Setiap kernel dievaluasi dengan menggunakan metrik kinerja standar seperti akurasi, presisi, recall, dan F1-score. Hal ini memberikan

gambaran komprehensif mengenai kemampuan model dalam mengklasifikasikan jenis penyakit kulit manusia. Selain itu, evaluasi akurasi per kelas juga dilakukan untuk memberikan wawasan mendalam tentang kemampuan model dalam menangani variasi kompleksitas setiap jenis penyakit kulit. Proses evaluasi ini diimplementasikan melalui penggunaan koding sebagai berikut pada Gambar 4.15.



```

# Evaluasi Kinerja Model
accuracy = accuracy_score(np.argmax(y_test, axis=1), y_pred_test)
precision = precision_score(np.argmax(y_test, axis=1), y_pred_test, average='macro')
recall = recall_score(np.argmax(y_test, axis=1), y_pred_test, average='macro')
f1 = f1_score(np.argmax(y_test, axis=1), y_pred_test, average='macro')

# Akurasi per kelas
for i, class_name in enumerate(unique_labels):
    true_positive = confusion_mtx[i, i]
    total_samples = np.sum(confusion_mtx[i, :])
    accuracy_class = true_positive / total_samples
    print("{} Accuracy: {:.2f}%".format(class_name, accuracy_class * 100))

```

Gambar 4.15. Kode Evaluasi Model

Dengan mengevaluasi kinerja pada setiap kernel, kita dapat memahami keunggulan dan kelemahan masing-masing dalam konteks klasifikasi jenis penyakit kulit manusia. Analisis akurasi per kelas juga memberikan wawasan yang mendalam mengenai kemampuan model dalam menangani variasi kompleksitas tiap jenis penyakit kulit. Proses ini tidak hanya membantu kita memilih kernel yang paling sesuai dengan tugas klasifikasi, tetapi juga memberikan pemahaman yang lebih baik tentang sejauh mana model mampu mengidentifikasi dan mengklasifikasikan setiap kondisi kulit secara spesifik.

#### 4.4.2. Evaluasi Hasil Kinerja Model CNN-SVM

Evaluasi hasil kinerja model CNN-SVM dilakukan dengan mempertimbangkan empat jenis kernel yang berbeda: Polynomial (Poly), Radial

Basis Function (RBF), Linear, dan Sigmoid. Masing-masing kernel dievaluasi menggunakan metrik kinerja standar seperti akurasi, presisi, recall, dan F1-score, yang memberikan gambaran komprehensif tentang kemampuan model dalam mengklasifikasikan jenis penyakit kulit manusia. Dapat dilihat pada Tabel 4.5. dan Tabel 4.6 dibawah.

Tabel 4.5. Evaluasi Metrik Kinerja pada Data Pengujian untuk Setiap Kernel

No	Kernel	Akurasi	Presisi	Recall	F1 Score
1	Polynomial	80%	80%	80%	80%
2	RBF	77%	77%	78%	77%
3	Linear	71%	71%	71%	71%
4	Sigmoid	52%	52%	51%	51%


Selain data pengujian, untuk memahami bagaimana model CNN-SVM berperforma selama tahap pelatihan. Berikut adalah hasil evaluasi metrik kinerja untuk setiap kernel selama tahap pelatihan:

Tabel 4.6. Evaluasi Metrik Kinerja pada Data Pelatihan untuk Setiap Kernel

No	Kernel	Akurasi	Presisi	Recall	F1 Score
1	Polynomial	90%	91%	90%	90%
2	RBF	85%	85%	85%	85%
3	Linear	93%	93%	93%	93%
4	Sigmoid	52%	53%	52%	51%

Analisis metrik kinerja pada tahap pelatihan memberikan pandangan tentang sejauh mana model dapat mempelajari pola-pola yang ada dalam data pelatihan dan hasil Confusion Matrix dari CNN-SVM dapat dilihat pada Gambar 4.16.





Gambar 4.16. Confusion Matrix CNN-SVM

Tabel 4.7 dibawah memberikan informasi lebih rinci tentang akurasi model dalam mengklasifikasikan setiap kelas penyakit kulit manusia. Evaluasi per kelas memberikan wawasan lebih mendalam tentang kemampuan model dalam mengatasi variasi kompleksitas setiap jenis penyakit

Tabel 4.7. Akurasi Per Kelas Model CNN-SVM

No	Kelas	Polynomial	RBF	Linear	Sigmoid
1	akiec	82.51%	79.86%	74.56%	60.07%
2	bbc	83.23%	79.86%	73.73%	38.45%
3	bkl	56.78%	52.68%	47.79%	23.97%
4	df	90.41%	88.10%	77.44%	53.46%
5	mel	61.32%	88.10%	50.40%	37.24%
6	nv	90.29%	90.63%	82.45%	75.47%
7	vasc	96.48%	90.63%	82.45%	76.21%

Tabel 4.7. diatas memperlihatkan sejauh mana model dapat mengenali setiap kelas penyakit kulit. Terlihat bahwa beberapa kelas, seperti 'vasc' dan 'nv', memiliki akurasi yang relatif tinggi, sementara kelas 'bkl' dan 'mel' dengan akurasi yang rendah memiliki tantangan lebih besar. Evaluasi akurasi per kelas memberikan gambaran yang lebih komprehensif tentang kemampuan model dalam menangani berbagai jenis penyakit kulit manusia.

#### **4.4.3. Diskusi Hasil Pengujian pada Model CNN-SVM**

Hasil evaluasi model CNN-SVM dengan empat jenis kernel yang berbeda, yaitu Polynomial (Poly), Radial Basis Function (RBF), Linear, dan Sigmoid, mengungkapkan beberapa temuan.

Pertama-tama, Polynomial Kernel menunjukkan performa unggul dengan akurasi keseluruhan mencapai 80%. Model ini konsisten dalam mengidentifikasi setiap jenis penyakit kulit, terutama pada kelas vasc, df, dan nv. Akurasi per kelas yang tinggi memberikan keyakinan bahwa model mampu mengatasi kompleksitas variasi penyakit kulit.

Kedua, RBF Kernel menunjukkan akurasi yang solid, mencapai 77%, dengan hasil luar biasa pada kelas vasc mencapai 96%. Walaupun demikian, terdapat ketidak-konsistenan pada kinerja model pada beberapa kelas seperti mel dan bkl. Oleh karena itu, diperlukan optimasi lebih lanjut pada hyperparameter dan penerapan teknik augmentasi data untuk meningkatkan konsistensi model.

Ketiga, Linear Kernel mencapai akurasi keseluruhan sebesar 71%, menunjukkan performa lebih baik pada kelas nv dan vasc. Namun, tantangan

terlihat pada klasifikasi kelas mel dan bkl, menunjukkan area potensial yang dapat dioptimalkan untuk meningkatkan performa.

Terakhir, Sigmoid Kernel menunjukkan kinerja yang lebih rendah dengan akurasi keseluruhan 52%. Model ini menghadapi kesulitan terutama pada kelas bbc, bkl, dan mel. Jenis kernel ini mungkin tidak optimal untuk tugas klasifikasi ini dan memerlukan penelitian lebih lanjut atau pertimbangan alternatif.

Dalam keseluruhan diskusi, terlihat bahwa pemilihan jenis kernel memiliki dampak yang signifikan pada kinerja model CNN-SVM. Oleh karena itu, penelitian mendetail dan eksperimen lebih lanjut diperlukan untuk menemukan jenis kernel yang paling sesuai dengan karakteristik data dan tugas klasifikasi yang spesifik. Disamping itu, optimalisasi pada parameter SVM dan penerapan teknik augmentasi data dapat membawa peningkatan signifikan pada kinerja model secara keseluruhan.

#### **4.5. Perbandingan dan Analisis Hasil**

##### **4.5.1. Perbandingan Performa Antara CNN dan CNN-SVM**

Perbandingan performa antara CNN dan CNN-SVM menjadi fokus utama untuk mengevaluasi keefektifan masing-masing model dalam mengklasifikasikan jenis penyakit kulit manusia. Dari hasil pengujian, kita dapat melihat bahwa CNN memberikan akurasi lebih tinggi daripada CNN-SVM. Secara lebih spesifik, CNN mencapai akurasi sekitar 94%, sementara CNN-SVM dengan kernel Polynomial (Poly) menunjukkan akurasi tertinggi sekitar 80%, diikuti oleh RBF dengan 77%, Linear dengan 71%, dan Sigmoid dengan 52%. Hasil ini mengindikasikan bahwa,

secara keseluruhan, CNN cenderung memberikan kinerja yang lebih unggul dalam tugas klasifikasi multi-kelas pada dataset penyakit kulit manusia. Untuk lebih jelasnya dapat dilihat pada Tabel 4.8. perbandingan berikut.

Tabel 4.8. Perbandingan Performa Model CNN dan CNN-SVM

No	Matrix	CNN	CNN-SVM (Poly)	CNN-SVM (RBF)	CNN-SVM (Linear)	CNN-SVM (Sigmoid)
1	Akurasi	94,76%	80%	77%	71%	52%
2	Precisi	94,85%	80%	77%	71%	52%
3	Recall	94,94%	80%	78%	71%	51%
4	F1 Score	94,87%	80%	77%	71%	51%

Tidak hanya melihat akurasi secara keseluruhan, tetapi juga penting untuk mengevaluasi performa per kelas. Analisis performa per kelas memberikan gambaran lebih rinci tentang seberapa baik model CNN dan CNN-SVM dapat mengenali jenis penyakit kulit. Akurasi per kelas ini menunjukkan sejauh mana setiap model dapat berhasil mengidentifikasi tiap kategori penyakit. Dapat di lihat pada Tabel 4.9. perbandingan akurasi per kelas untuk kedua model.

Tabel 4.9. Perbandingan Performa Per Kelas Model CNN dan CNN-SVM

No	Kelas	CNN	CNN-SVM (Poly)	CNN-SVM (RBF)	CNN-SVM (Linear)	CNN-SVM (Sigmoid)
1	akicc	97,22%	82,51%	79,86%	74,56%	60,07%
2	bbc	96,30%	83,23%	79,86%	73,73%	38,45%
3	bkl	<b>88,61%</b>	<b>56,78%</b>	<b>52,68%</b>	<b>47,79%</b>	<b>23,97%</b>
4	df	99,66%	90,41%	88,10%	77,44%	53,46%
5	mel	<b>88,22%</b>	<b>61,32%</b>	<b>88,10%</b>	<b>50,40%</b>	<b>37,24%</b>
6	nv	94,64%	90,29%	90,63%	82,45%	75,47%
7	vasc	100%	96,48%	90,63%	82,45%	76,21%

Dari Tabel 4.9. diatas, menunjukkan bahwa meskipun model CNN-SVM (Poly) berhasil dengan baik pada beberapa kelas tertentu, seperti "vasc", "nv" dan "df", namun kemampuannya lebih rendah pada kelas lain. di sisi lain Model CNN,



menunjukkan konsistensi dan akurasi tinggi pada semua kelas dalam klasifikasi jenis penyakit kulit.

#### **4.5.2. Interpretasi Hasil dan Temuan Signifikan**

Dari hasil perbandingan performa antara model CNN dan CNN-SVM, dapat diinterpretasikan bahwa model CNN cenderung lebih efektif dalam mengklasifikasikan jenis penyakit kulit. Meskipun beberapa variasi kernel pada CNN-SVM menunjukkan performa yang cukup baik, namun tidak konsisten di seluruh kelas.

Keunggulan model CNN terutama terlihat dalam akurasi per kelas yang tinggi dan konsisten. Sebaliknya, beberapa kernel pada CNN-SVM menunjukkan kecenderungan untuk kurang berhasil dalam mengidentifikasi jenis penyakit tertentu. Temuan ini mendukung pemahaman bahwa penggunaan arsitektur CNN sebagai model tunggal lebih efektif dalam tugas klasifikasi jenis penyakit kulit manusia pada dataset ini.

#### **4.5.3. Analisis Faktor-faktor yang Mempengaruhi Performa Model**

Arsitektur-model pada CNN dan balancing pada dataset menjadi elemen utama yang berkontribusi pada kinerja tinggi. Struktur jaringan saraf konvolusi mampu secara efektif mengekstraksi fitur-fitur penting dari gambar, menciptakan representasi yang kuat untuk klasifikasi. Dalam CNN-SVM, pemilihan arsitektur model juga penting, tetapi model ini lebih sensitif terhadap variasi arsitektur dan kernel yang digunakan. Pemilihan kernel SVM dapat memengaruhi kemampuan model dalam menangkap pola kompleks dalam data.



Ukuran dataset yang besar memberikan dampak positif pada kinerja CNN. Dataset yang besar memungkinkan model untuk belajar dengan baik dan meningkatkan generalisasi pada data pengujian. Pada CNN-SVM meskipun ukuran dataset sama dengan CNN, kinerja CNN-SVM bervariasi tergantung pada jenis kernel yang digunakan. Kernel tertentu lebih cocok untuk dataset berukuran besar, tetapi efektivitasnya tergantung pada kompleksitas data yang dihadapi. Keterbatasan model CNN-SVM sensitivitas terhadap data yang ketika ada kelas penyakit kulit yang memiliki fitur serupa atau tumpang tindih dengan kelas lainnya, model CNN-SVM mengalami kesulitan membedakan antara kelas-kelas dan memutuskan klasifikasi yang tepat, khususnya pada kelas penyakit bkl dan mel dengan akurasi yang rendah dapat dilihat pada Gambar 4.17. hasil klasifikasi untuk kelas bkl dan mel di bawah.



Gambar 4.17. klasifikasi kesalahan kelas BKL dan Mel

Gambar 4.17 merupakan 10 sampel gambar random hasil klasifikasi yang salah dari CNN pada kelas bkl dan mel. Dari gambar diatas dapat dilihat bahwa dari 10 gambar kelas bkl yang diprediksi salah (kelas mel 6, akiec 3, dan nv 1). Sedangkan untuk kelas mel yang diprediksi salah (kelas bkl 4, nv 2, bbc 2, akiec 1, dan df 1). Jadi dapat disimpulkan bahwa dari 7 kelas yang diklasifikasikan 2 kelas bkl dan mel berperan penting dalam mempengaruhi penurunan hasil kinerja

klasifikasi, dikarenakan kelas bkl dan mel memiliki karakteristik dan fitur yang serupa atau tumpang tindih. Hal tersebut juga dibuktikan dengan hasil akurasi pada kelas bkl dan mel tidak hanya pada CNN tetapi juga dengan CNN-SVM dengan 4 kernel yang berbeda.

Penurunan akurasi pada penggunaan CNN-SVM disebabkan oleh beberapa faktor. Salah satu faktor utama adalah fitur yang dihasilkan oleh ResNet50 tidak sepenuhnya cocok dengan kebutuhan SVM. Selain itu, pengaturan parameter SVM belum optimal pada penelitian ini juga yang mengakibatkan terjadinya masalah *overfitting* pada model CNN-SVM sehingga mengakibatkan kinerja model yang buruk pada data pengujian. Dapat dilihat pada Tabel 4.5 dan Tabel 4.6 sebagai contoh pada CNN-SVM dengan kernel *polynomial* dengan hasil training 90% sedangkan hasil testing hanya 80%.

Dari penjelasan di atas dapat disimpulkan bahwa penggunaan SVM bersama dengan CNN menghasilkan arsitektur dengan tingkat kompleksitas yang lebih tinggi, yang menyebabkan terjadinya *overfitting* dan kesulitan dalam menggeneralisasi model terhadap data uji yang belum pernah ditemui sebelumnya.

Kedua, tentang bagian efisiensi komputasional, walaupun CNN terkenal karena efisiensinya dalam menangani tugas pengolahan citra. Dengan dataset sebanyak 21 ribu gambar dan 7 kelas penyakit, penggabungan CNN dengan SVM, komputer melakukan lebih banyak pekerjaan, tapi ternyata hasil penelitian menunjukkan bahwa hal ini tidak memberikan peningkatan pada hasil kinerja. Malah sebaliknya, model CNN-SVM cenderung memberikan hasil yang lebih

rendah, seperti akurasi, presisi, recall, dan F1 score, dibandingkan dengan model CNN yang lebih sederhana.

#### **4.6. Perbandingan dengan penelitian sebelumnya**

Penelitian ini akan dibandingkan dengan penelitian-penelitian sebelumnya yang juga meneliti tentang klasifikasi jenis penyakit kulit menggunakan dataset HAM10000. Tujuannya adalah untuk mengevaluasi temuan studi ini dalam konteks yang serupa dan untuk melihat seberapa jauh kontribusi studi ini dibandingkan dengan penelitian sebelumnya dalam memahami klasifikasi jenis penyakit kulit manusia. Melalui perbandingan ini, diharapkan kita dapat mendapatkan pemahaman yang lebih baik tentang keunggulan, keterbatasan, dan temuan yang signifikan dari metode yang diusulkan dalam studi ini. Tabel 4.10. di bawah ini memuat hasil perbandingan antara model pada penelitian ini dengan beberapa model pada penelitian terdahulu.

Tabel 4.10. Perbandingan Kinerja Model Dengan Penelitian Sebelumnya

Ref.	Model	Optimizer	Epoch	Batch Size	Learning rate	Akurasi	Presisi	Recall	F1-Score
(Deif & Hammam, 2020)	VGG16	Adam	200	32	0.05	87%	87%	87%	87%
	VGG19	Adam	200	32	0.05	85%	85%	85%	85%
	MobileNet	Adam	200	32	0.05	88%	89%	88%	88%
	<b>InceptionV3</b>	Adam	200	32	0.05	<b>89%</b>	<b>89%</b>	<b>89%</b>	<b>89%</b>
(Aker et al., 2022)	VGG-16	Adam	30	32	0.0001	73%	71%	73%	71%
	CNN	Adam	30	32	0.0001	77%	73%	77%	73%
	Resenet-50	Adam	30	32	0.0001	82%	80%	82%	81%
	Mobilenet	Adam	30	32	0.0001	87%	88%	87%	86%
	Xception	Adam	30	32	0.0001	88%	88%	88%	87%
	Densenet	Adam	30	32	0.0001	88%	88%	88%	87%
	<b>InceptionV3</b>	Adam	30	32	0.0001	<b>90%</b>	<b>90%</b>	<b>90%</b>	<b>90%</b>
	<b>InceptionV3</b>	SDGM	30	32	0.0001	<b>91.56%</b>	<b>89%</b>	<b>89%</b>	<b>89%</b>
(Chaturvedi et al., 2020)	Xception	SDGM	30	32	0.0001	91.47%	89%	88%	88%
	NASNetLarge	SDGM	30	32	0.0001	91.11%	86%	86%	86%
	InceptionResNet V2	SDGM	30	32	0.0001	93.20%	87%	88%	88%
	<b>ResNetXt101</b>	SDGM	30	32	0.0001	<b>93.20%</b>	88%	88%	88%
	<b>ResNet50</b>	<b>SGDM</b>	<b>100</b>	<b>64</b>	<b>0.001</b>	<b>94.76%</b>	<b>94.85 %</b>	<b>94.94 %</b>	<b>94.87%</b>
<b>Penelitian ini</b>	CNN-SVM (Poly)	-	-	-	-	80%	80%	80%	80%



Dari Tabel 4.10 perbandingan kinerja di atas, dapat dilihat bahwa model ResNet50 pada penelitian ini secara konsisten mencapai tingkat akurasi dan metrik evaluasi lainnya yang lebih tinggi dibandingkan dengan model-model pada 3 penelitian sebelumnya. Hal ini menandakan bahwa pendekatan yang diusulkan memiliki kinerja yang lebih baik dalam mengklasifikasikan jenis penyakit kulit manusia pada dataset HAM10000.

Pada Tabel 4.10. perbandingan diatas dapat dilihat bahwa Hyperparameter Tuning yang dilakukan oleh (Deif & Hammam, 2020) dan (Akteer et al., 2022) menggunakan optimizer "adam" dan "batch size" yang sama yaitu 32 batch pada semua model. akan tetapi hasil tertinggi pada kedua penelitian tersebut terdapat pada model InceptionV3 dan hasil akurasi yang tidak terlalu jauh yaitu 89% dan 90%. Hal ini membuktikan bahwa Jumlah Epoch dan Learning Rate yang berbeda signifikan tidak terlalu mempengaruhi hasil dari model InceptionV3.

Adapun penelitian ini dan penelitian yang dilakukan oleh (Chaturvedi et al., 2020) membuktikan bahwa penggunaan optimizer "SGDM" dapat meningkatkan hasil akurasi yang diperoleh. Jika dilihat pada penelitian (Chaturvedi et al., 2020) dan (Akteer et al., 2022) pada model InceptionV3 dengan Jumlah Epoch, Learning Rate dan Batch Size yang sama, mengalami peningkatan akurasi sebesar 1.56% dan penurunan pada presisi, recall, f1-score masing-masing 1%.

Selanjutnya pada penelitian ini dan penelitian yang dilakukan oleh (Chaturvedi et al., 2020) menggunakan arsitektur dua berbeda yaitu, pada penelitian ini menggunakan arsitektur ResNet50 dengan optimizer SGDM=0.9, batch size 64, Learning Rate 0.001 dan 100 epoch memperoleh hasil akurasi sebesar 94.76%.



Sedangkan penelitian yang dilakukan oleh (Chaturvedi et al., 2020) menggunakan ResNet50 dengan optimizer SGDM=0.9, batch size 32, Learning Rate 0.0001 dan 30 epoch memperoleh akurasi sebesar 93.20%. Dari hasil tersebut dapat disimpulkan bahwa penelitian ini mengalami peningkatan akurasi sebesar 1,47%. Adapun pada penelitian ini presisi, recall, f1-score mengalami peningkatan sebesar 4.80%, 4.82%, dan 4,76% dibandingkan dengan 3 hasil penelitian sebelumnya.

Peningkatan hasil akurasi presisi, recall, f1-score pada penelitian ini tidak hanya dipengaruhi oleh hyperparameter tuning arsitektur yang digunakan, tetapi juga oleh proses augmentasi dan blancing dataset yang berbeda dari yang dilakukan oleh peneliti sebelumnya. Kemudian peneliti juga telah merekonstruksi dengan dataset yang sudah dibalancing pada penelitian yang diajukan dengan hasil seperti pada Gambar 4.18. dibawah.



Gambar 4.18. Perbandingan hasil dengan penelitian sebelumnya

Berdasarkan hasil dari tiga penelitian pada Gambar 4.18 **Error! Reference source not found.** diatas, selain dari hal-hal yang sudah dijelaskan pada pembahasan terkait arsitektur pada Tabel 4.10. Penerapan balancing dataset dalam mengklasifikasi multi-kelas jenis penyakit kulit manusia memiliki pengaruh yang signifikan terhadap kinerja model.

## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Berdasarkan hasil evaluasi dan analisis yang dilakukan dua pendekatan utama, yaitu CNN dan CNN-SVM dengan arsitektur ResNet50 dalam mengklasifikasi multi-kelas jenis penyakit kulit manusia. Dapat diambil kesimpulan sebagai berikut:

1. Metode CNN arsitektur ResNet50 dengan optimizer SGDM=0.9, batch size 64, Learning Rate 0.001, dropout (0.7) dan penerapan *Balancing* pada data terbukti konsisten unggul dalam tugas klasifikasi multi-kelas jenis penyakit kulit manusia dengan akurasi 94.76%. Dibandingkan metode CNN-SVM dengan kernel Polynomial yang memiliki akurasi tertinggi sebesar 80%. CNN-SVM dengan kernel RBF, Linear, dan Sigmoid menunjukkan performa lebih rendah, dengan Sigmoid memberikan hasil terendah. Secara keseluruhan performa CNN-SVM tidak melampaui CNN.
2. Model CNN menunjukkan kinerja yang sangat baik dengan presisi, recall, dan F1-score melebihi 94%. Kelas dengan hasil klasifikasi tertinggi adalah *vasc*, mencapai nilai 100%. Ini menandakan bahwa CNN memberikan hasil yang konsisten, andal, dan akurat dalam mengklasifikasikan multi-kelas jenis penyakit kulit manusia. dibandingkan CNN-SVM dengan kernel Polynomial, dengan hasil presisi, recall, dan F1-score di 80%. CNN-SVM mencapai hasil klasifikasi tertinggi pada kelas *vasc* dengan nilai 96%, *nv* 90% dan *df* 90%.


Namun, baik model klasifikasi CNN maupun CNN-SVM yang digunakan dalam penelitian ini menunjukkan adanya keterbatasan yang mencolok. Dari tujuh kelas penyakit yang diklasifikasi, terlihat keterbatasan terutama dalam menghadapi jenis penyakit kelas BKL dan MEL yang memiliki hasil klasifikasi yang lebih rendah dari yang lainnya. Meskipun dataset telah diolah secara cermat, akurasi yang rendah pada kelas-kelas ini menunjukkan adanya kendala yang perlu diatasi. Karakteristik intrinsik dari jenis penyakit kulit ini menjadi faktor kunci yang mempengaruhi kinerja model.

## 5.2. Saran

Berdasarkan hasil penelitian ini, beberapa saran dapat diajukan untuk pengembangan selanjutnya:

1. Lakukan pendekatan yang lebih mendalam untuk mengatasi keterbatasan CNN dan CNN-SVM untuk kasus kelas BKL dan MEL. Dengan cara eksplorasi teknik augmentasi data yang lebih spesifik diharapkan dapat meningkatkan performa dari model.
2. Sebaiknya melakukan eksplorasi lebih lanjut terhadap arsitektur CNN untuk meningkatkan keakuratan dan kestabilan model.
3. Mengoptimalkan pengaturan pada parameter SVM sehingga dapat mengatasi masalah overfitting yang terjadi pada model CNN-SVM.
4. Sebaiknya melakukan validasi hasil dengan menggunakan dataset internal untuk memastikan generalitas model terhadap variasi data yang lebih luas.

5. Peneliti juga mengharapkan penelitian ini dapat diimplementasikan menjadi Aplikasi/perangkat lunak sehingga manfaat dari penelitian ini dapat terlihat secara nyata.



## DAFTAR PUSTAKA

### PUSTAKA ELEKTRONIK, JURNAL ILMIAH ATAU PROSIDING

- Akter, M. S., Shahriar, H., Sneha, S., & Cuzzocrea, A. (2022). Multi-class Skin Cancer Classification Architecture Based on Deep Convolutional Neural Network. *Proceedings - 2022 IEEE International Conference on Big Data, Big Data* 2022, 5404–5413. <https://doi.org/10.1109/BigData55660.2022.10020302>
- Al., M. O. K. et. (2020). A Hybrid Model of Faster R-CNN and SVM for Tumor Detection and Classification of MRI Brain Images. *International Journal of Mechanical and Production Engineering Research and Development*, 10(3), 6863–6876. <https://doi.org/10.24247/ijmperdjun2020651>
- Aljohani, K., & Turki, T. (2022). Automatic Classification of Melanoma Skin Cancer with Deep Convolutional Neural Networks. *Ai*, 3(2), 512–525. <https://doi.org/10.3390/ai3020029>
- Chaturvedi, S. S., Tembhone, J. V., & Diwan, T. (2020). A multi-class skin Cancer classification using deep convolutional neural networks. *Multimedia Tools and Applications*, 79(39–40), 28477–28498. <https://doi.org/10.1007/s11042-020-09388-2>
- Deif, M. A., & Hammam, R. E. (2020). Skin Lesions Classification Based on Deep Learning Approach. *Journal of Clinical Engineering*, 45(3), 155–161. <https://doi.org/10.1097/jce.0000000000000405>
- Gong, W., Chen, H., Zhang, Z., Zhang, M., Wang, R., Guan, C., & Wang, Q. (2019). A Novel Deep Learning Method for Intelligent Fault.



- Jean, A. K., Diarra, M., Bakary, B. A., Pierre, G., Jérôme, A. K., & Franche-comté, U. B. (2022). Application based on Hybrid CNN-SVM and PCA- SVM Approaches for Classification of Cocoa Beans. *13(9)*, 231–238.
- Junayed, M. S., Anjum, N., Sakib, A. N. M., & Islam, M. B. (2021). A Deep CNN Model for Skin Cancer Detection and Classification. *Computer Science Research Notes*, *3101(Dvd)*, 71–80. <https://doi.org/10.24132/CSRN.2021.3101.8>
- Kassem, M. A., Hosny, K. M., & Fouad, M. M. (2020). Skin Lesions Classification into Eight Classes for ISIC 2019 Using Deep Convolutional Neural Network and Transfer Learning. *IEEE Access*, *8*, 114822–114832. <https://doi.org/10.1109/ACCESS.2020.3003890>
- Keerthana, D., Venugopal, V., Nath, M. K., & Mishra, M. (2023). Hybrid convolutional neural networks with SVM classifier for classification of skin cancer. *Biomedical Engineering Advances*, *5(December 2022)*, 100069. <https://doi.org/10.1016/j.bea.2022.100069>
- Khairandish, M. O., Sharma, M., Jain, V., Chatterjee, J. M., & Jhanjhi, N. Z. (2022). A Hybrid CNN-SVM Threshold Segmentation Approach for Tumor Detection and Classification of MRI Brain Images. *Irbm*, *43(4)*, 290–299. <https://doi.org/10.1016/j.irbm.2021.06.003>
- Kose, U., & Alzubi, J. (Editors). (2021). *Deep Learning for Cancer Diagnosis*. In Springer- Studies in Computational Intelligence 908 (Vol. 908, Issue September). <https://doi.org/10.1007/978-981-15-6321-8>

- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Mukkapati, N., & Anbarasi, M. S. (2022). Multi-Class Classification Framework for Brain Tumor MR Image Classification by Using Deep CNN with Grid-Search Hyper Parameter Optimization Algorithm. *International Journal of Computer Science & Network Security*, 22(4), 101–110. <https://doi.org/10.22937/IJCSNS.2022.22.4.14>
- Refianti, R., Mutiam, A. B., & Priyandini, R. P. (2019). Classification of melanoma skin cancer using convolutional neural network. *International Journal of Advanced Computer Science and Applications*, 10(3), 409–417. <https://doi.org/10.14569/IJACSA.2019.0100353>
- Santos, C. A., & Welfer, D. (2019). A Novel Hybrid SVM-CNN Method for Extracting Characteristics and Classifying Cattle Branding. *Latin American Journal of Computing*, VI(1), 9–16. <https://lajc.epn.edu.ec/index.php/LAJC/article/view/157>
- Savas, C., & Dervis, F. (2019). The impact of different kernel functions on the performance of scintillation detection based on support vector machines. *Sensors (Switzerland)*, 19(23), 1–16. <https://doi.org/10.3390/s19235219>
- Srinivasu, P. N., Sivasai, J. G., Ijaz, M. F., Bhoi, A. K., Kim, W., & Kang, J. J. (2021). Networks with MobileNet V2 and LSTM. 1–27.
- Tschandl, P., Rosendahl, C., & Kittler, H. (2018). Data descriptor: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common

- pigmented skin lesions. *Scientific Data*, 5, 1–9.  
<https://doi.org/10.1038/sdata.2018.161>
- Ünver, H. M., & Ayan, E. (2019). Skin lesion segmentation in dermoscopic images with combination of yolo and grabcut algorithm. *Diagnostics*, 9(3).  
<https://doi.org/10.3390/diagnostics9030072>
- Wan, S., Yeh, M. L., & Ma, H. L. (2021). An innovative intelligent system with integrated CNN and SVM: Considering various crops through hyperspectral image data. *ISPRS International Journal of Geo-Information*, 10(4).  
<https://doi.org/10.3390/ijgi10040242>
- Wang, P., Fan, E., & Wang, P. (2021). Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*, 141, 61–67.  
<https://doi.org/10.1016/j.patrec.2020.07.042>
- Wang, Y., Sun, L., Ma, K., & Fang, J. (2018). Breast Cancer Microscope Image Classification Based on CNN with Image Deformation. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: Vol. 10882 LNCS. Springer International Publishing. [https://doi.org/10.1007/978-3-319-93000-8\\_96](https://doi.org/10.1007/978-3-319-93000-8_96)
- Xue, D. X., Zhang, R., Feng, H., & Wang, Y. L. (2016). CNN-SVM for Microvascular Morphological Type Recognition with Data Augmentation. *Journal of Medical and Biological Engineering*, 36(6), 755–764.  
<https://doi.org/10.1007/s40846-016-0182-4>

- Yanagisawa, Y., Shido, K., Kojima, K., & Yamasaki, K. (2023). Convolutional neural network-based skin image segmentation model to improve classification of skin diseases in conventional and non-standardized picture images. *Journal of Dermatological Science*, 109(1), 30–36. <https://doi.org/10.1016/j.jdermsci.2023.01.005>
- Yang, J., Zhao, Y., Chan, J. C. W., & Yi, C. (2016). Hyperspectral image classification using two-channel deep convolutional neural network. In *International Geoscience and Remote Sensing Symposium (IGARSS) (Vols. 2016-Novem.* pp. 5079–5082). <https://doi.org/10.1109/IGARSS.2016.7730324>
- Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 4(January), 3320–3328.
- Hartini, S., Rustam, Z., & Hidayat, R. (2022). Designing Hybrid CNN-SVM Model for COVID-19 Classification Based on X-ray Images Using LGBM Feature Selection. *International Journal on Advanced Science, Engineering and Information Technology*, 12(5), 1895-1906. <https://doi.org/10.18517/ijaseit.12.5.16875>
- Rahin, A., 2021, Analisis Komparasi Convolution Neural Network (CNN) Dengan Support Vector Machine (SVM) Untuk Klasifikasi Citra Pengguna Masker, Tesis, S2 Teknik Informatika, STMIK AMIKOM, Yogyakarta
- Rahin, A., 2021, Analisis Kombinasi Convolution Neural Network (CNN) Dengan Support Vector Machine (SVM) Dalam Deteksi Otomatis Non-Proliferative

Diabetic Retinopathy, Tesis, S2 Teknik Informatika, STMIK AMIKOM,  
Yogyakarta

Géron, A. (2017). Hands-On Machine Learning with Scikit-Learn and TensorFlow:  
Concepts, Tools, and Techniques to Build Intelligent Systems.  
<http://oreilly.com/safari>

Mohamed Elgendy. (2020). Deep Learning for Vision Systems. Manning  
Publications.

