

**KLASIFIKASI PENYAKIT DIABETES MELITUS NEUROPATI
BERDASARKAN CITRA MEDIS KAPILAROSKOPI MENGGUNAKAN
ALGORITMA *DEEP LEARNING***

TUGAS AKHIR



SIUSIU TRIFENA HALIM

NIM : 312110013

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI DAN DESAIN
UNIVERSITAS MA CHUNG
MALANG
2025**

LEMBAR PENGESAHAN

TUGAS AKHIR

**KLASIFIKASI PENYAKIT DIABETES MELITUS NEUROPATI
BERDASARKAN CITRA MEDIS KAPILAROSKOPI MENGGUNAKAN
ALGORITMA *DEEP LEARNING***

Oleh:

SIUSIU TRIFENA HALIM

NIM. 312110013

dari:

PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNOLOGI DAN DESAIN

UNIVERSITAS MA CHUNG

Telah dinyatakan lulus dalam melaksanakan Tugas Akhir sebagai syarat kelulusan
dan berhak mendapatkan gelar Sarjana Komputer (S.Kom)

Dosen Pembimbing I,



Windra Swastika, S.Kom., MT., Ph.D.

NIP. 20070039

Dosen Pembimbing II,



Paulus Lucky Tirma Irawan, S.Kom., MT.

NIP. 20100005

Dekan Fakultas Teknologi dan Desain,



Prof. Dr.Eng. Romy Budhi, ST., MT., M.Pd.

NIP. 20070035

**PERNYATAAN KEASLIAN
TUGAS AKHIR**

Dengan ini saya menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya dengan judul “KLASIFIKASI PENYAKIT DIABETES MELITUS NEUROPATI BERDASARKAN CITRA MEDIS KAPILAROSKOPI MENGGUNAKAN ALGORITMA *DEEP LEARNING*” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku

Malang, 23 Juli 2025



Siusiu Trifena Halim

NIM. 312110013

UNIVERSITAS
MA CHUNG

**KLASIFIKASI PENYAKIT DIABETES MELITUS NEUROPATI
BERDASARKAN CITRA MEDIS KAPILAROSKOPI
MENGUNAKAN ALGORITMA *DEEP LEARNING***

Siusiu Trifena Halim, Windra Swastika, Paulus Lucky Tirma Irawan

Teknik Informatika

Universitas Ma Chung

Abstrak

Komplikasi diabetes melitus pada pembuluh darah kapiler memerlukan deteksi dini yang akurat untuk mencegah progresivitas penyakit. Penelitian ini mengembangkan sistem klasifikasi citra pembuluh darah kapiler menggunakan teknik deep learning dengan empat arsitektur Convolutional Neural Network (CNN) yang berbeda yaitu EfficientNet, ResNet-50, VGG16, dan YOLOv11. Dataset penelitian terdiri dari 2.490 citra pembuluh darah kapiler yang diperoleh melalui teknik *Nailfold Capillaroscopy* menggunakan perangkat *CapillaryScope 500 (MEDL4N5)* dengan resolusi 1280×1024 piksel. Evaluasi dilakukan pada berbagai tingkat kompleksitas klasifikasi meliputi klasifikasi biner (normal/abnormal), klasifikasi 3 kelas (sehat, DM Neuropati, DM Non Neuropati), dan klasifikasi 6 kelas dimana masing masing kelas sehat, DM Neuropati dan DM Non Neuropati memiliki data normal dan abnormal. Parameter evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, *balanced accuracy*, dan *Matthews Correlation Coefficient (MCC)*. Hasil penelitian menunjukkan EfficientNet memberikan performa terbaik dengan akurasi 96,80% pada klasifikasi biner, 86,80% pada klasifikasi 3 kelas, dan 78,10% pada klasifikasi 6 kelas. Implementasi pendekatan hierarkis berhasil meningkatkan akurasi overall menjadi 81,10%, menunjukkan efektivitas strategi klasifikasi bertingkat untuk aplikasi diagnostik pembuluh darah kapiler.

Kata kunci : *Convolutional Neural Network, Deep Learning*, Kapilaroskopi, Klasifikasi Citra Medis, Pembuluh Darah Kapiler, ResNet-50, VGG16, YOLOv11, EfficientNet.

CLASSIFICATION OF DIABETES MELLITUS NEUROPATHY BASED ON CAPILLAROSCOPY MEDICAL IMAGE USING DEEP LEARNING ALGORITHM

Siusiu Trifena Halim, Windra Swastika, Paulus Lucky Tirma Irawan

Teknik Informatika

Universitas Ma Chung

Abstract

Complications of diabetes mellitus in capillary blood vessels require accurate early detection to prevent disease progression. This study develops a capillary blood vessel image classification system using deep learning techniques with four different Convolutional Neural Network (CNN) architectures namely EfficientNet, ResNet-50, VGG16, and YOLOv11. The research dataset consists of 2.490 capillary blood vessel images obtained through Nailfold Capillaroscopy technique using CapillaryScope 500 (MEDL4N5) device with 1280×1024 pixel resolution. Evaluation was performed at various levels of classification complexity including binary classification (normal/abnormal), 3-class classification (healthy, DM Neuropathy, DM Non Neuropathy), and 6-class classification where each class of healthy, DM Neuropathy and DM Non Neuropathy has normal and abnormal data. Evaluation parameters use accuracy, precision, recall, F1-score, balanced accuracy, and Matthews Correlation Coefficient (MCC). The results showed EfficientNet gave the best performance with 96.80% accuracy in binary classification, 86.80% in 3-class classification, and 78.10% in 6-class classification. The implementation of the hierarchical approach successfully improved the overall accuracy to 81.10%, demonstrating the effectiveness of the multilevel classification strategy for capillary vascular diagnostic applications.

Kata kunci : Convolutional Neural Network, Deep Learning, Capillaroscopy, Medical Image Classification, Capillary Blood Vessels, ResNet-50, VGG16, YOLOv11, EfficientNet.

Kata Pengantar

Puji syukur saya kepada Tuhan Yang Maha Esa, karena berkat kasih dan rahmat yang diberikan selama laporan penelitian hasil Tugas Akhir dengan judul “KLASIFIKASI PENYAKIT DIABETES MELITUS NEUROPATI BERDASARKAN CITRA MEDIS KAPILAROSKOPI MENGGUNAKAN ALGORITMA *DEEP LEARNING*” dapat terselesaikan dengan baik. Laporan ini tidak akan terwujud tanpa dukungan, bimbingan, dan bantuan dari berbagai pihak yang telah memberikan kontribusi berharga. Oleh karena itu, izinkanlah saya untuk mengucapkan terima kasih yang tulus kepada semua pihak yang telah terlibat dalam proses penelitian ini. Pihak-pihak tersebut antara lain:

1. Tuhan Yang Maha Esa karena berkat dan rahmat yang diberikan sehingga proses tugas akhir dapat berjalan lancar.
2. Bapak Hendry Setiawan, S.T., M.Kom. selaku kepala program studi Teknik Informatika.
3. Bapak Windra Swastika, S.Kom., MT., Ph.D. selaku dosen pembimbing saya yang selalu membimbing dan membantu dalam menyelesaikan tugas akhir.
4. Bapak Paulus Lucky Tirma Irawan, S.Kom., MT. selaku dosen pembimbing kedua yang selalu sabar membimbing dan mendukung saya dalam pengerjaan tugas akhir.
5. Bapak Bitu Parga Zen, S.Kom., M.Han. selaku dosen penguji yang telah berkenan memberikan evaluasi dan saran perbaikan dalam penelitian ini.
6. Keluarga dan kakak saya yang selalu menemani dan memberikan doa terbaik bagi saya dalam segala hal.
7. Johan Chenwidy yang selalu mendukung dan memotivasi setiap langkah yang saya ambil.
8. Teman-teman saya yang selalu mendukung selama masa perkuliahan.
9. Semua pihak yang tidak dapat disebutkan satu per satu, namun telah memberikan kontribusi dalam penyelesaian penelitian ini.

Saya sadar bahwa laporan ini jauh dari kata sempurna. Semoga laporan ini dapat memberikan manfaat dan kontribusi yang berarti bagi perkembangan ilmu pengetahuan. Kritik, saran, dan masukan yang membangun sangat diharapkan untuk perbaikan di masa mendatang.

Malang, 23 Juli 2025



Penulis



UNIVERSITAS
MA CHUNG

Daftar Isi

Daftar Isi	i
Daftar Tabel	iv
Daftar Gambar	v
Bab I Pendahuluan	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah	3
1.3 Batasan Masalah	3
1.4 Rumusan Masalah	4
1.5 Tujuan Penelitian	4
1.6 Manfaat Penelitian	4
1.7 Rencana Penelitian	5
1.8 Luaran	6
Bab II Tinjauan Pustaka	7
2.1 Diabetes Melitus	7
2.2 Diabetes Melitus Neuropati	7
2.3 Pembuluh Darah Kapiler	8
2.4 Kapilaroskopi	9
2.5 <i>Artificial Intelligence (AI)</i>	11
2.6 <i>Machine Learning</i>	11
2.6.1 <i>Supervised Learning</i>	12
2.6.2 <i>Unsupervised Learning</i>	12
2.7 <i>Deep Learning</i>	12
2.8 <i>Convolutional Neural Network (CNN)</i>	13

2.9 Preprocessing Citra	13
2.9.1 <i>Cropping</i> (Pemotongan Citra)	13
2.9.2 <i>Resizing</i> (Pengubahan Ukuran)	13
2.10 Augmentasi Data	14
2.10.1 <i>Flipping</i>	14
2.10.2 Rotasi	14
2.10.3 <i>Scaling</i>	15
2.10.4 Translasi	15
2.10.5 <i>Brightness dan Contrast Augmentation</i>	15
2.11 VGG16	15
2.12 ResNet	16
2.13 YOLOv11	17
2.14 EfficientNet	18
2.15 Confusion Matrix	20
2.15.1 <i>Accuracy</i>	20
2.15.2 <i>Precision</i>	21
2.15.3 <i>Recall (Sensitivity)</i>	21
2.15.4 <i>F1 Score</i>	22
2.15.5 <i>Balanced Accuracy</i>	22
2.15.6 <i>Matthews Correlation Coefficient (MCC)</i>	22
2.15.7 <i>Confidence</i>	23
2.16 Python	23
2.16.1 NumPy	23
2.16.2 Pandas	24
2.16.3 Matplotlib dan Seaborn	24
2.16.4 Scikit-learn	24
2.16.5 TensorFlow dan Keras	24
2.16.6 OpenCV	25
2.16.7 Ultralytics	25
2.17 Penelitian Terdahulu	25

Bab III Analisis dan Perancangan Sistem	28
3.1 Analisis Kebutuhan	29
3.2 Pengumpulan Dataset	29
3.3 <i>Preprocessing</i>	30
3.4 Augmentasi Data	31
3.5 Perancangan Model CNN	33
3.5.1 Arsitektur ResNet-50	33
3.5.2 Arsitektur VGG16	34
3.5.3 Arsitektur YOLOv11	35
3.5.4 Arsitektur EfficientNet	36
3.5.5 Skema Pelatihan	36
3.7 Evaluasi Model	37
3.8 Eksperimen	38
Bab IV Hasil dan Pembahasan	40
4.1 Data Penelitian	40
4.2 Hasil Pengujian	46
4.2.1 Hasil Model Klasifikasi 2 Kelas	46
4.2.2 Hasil Model Klasifikasi 3 Kelas	57
4.2.3 Hasil Model Klasifikasi 6 Kelas	67
4.2.4 Hasil Model Hierarchical Klasifikasi 3 Kelas	75
Bab V Kesimpulan dan Saran	83
5.1 Kesimpulan	83
5.2 Saran	84
Daftar Pustaka	86

Daftar Tabel

Tabel 1. 1 Rencana Penelitian	5
Tabel 3. 1 Parameter Arsitektur ResNet-50	33
Tabel 3. 2 Parameter Arsitektur VGG16.....	34
Tabel 3. 3 Parameter Arsitektur YOLOv11	35
Tabel 3. 4 Parameter Arsitektur EfficientNet	36
Tabel 3. 5 Eksperimen berdasarkan kelas	38
Tabel 4. 1 Contoh Citra Kapilaroskopi	40
Tabel 4. 2 Sebaran dataset untuk fase pengujian 1	41
Tabel 4. 3 Sebaran dataset untuk fase pengujian 2	42
Tabel 4. 4 Sebaran dataset untuk fase pengujian 3	42
Tabel 4. 5 Jumlah dataset	43
Tabel 4. 6 Distribusi Data 2 Kelas	44
Tabel 4. 7 Distribusi Data 3 Kelas	45
Tabel 4. 8 Distribusi Data 6 kelas	45
Tabel 4. 9 Hasil Klasifikasi Model 2 Kelas (A).....	46
Tabel 4. 10 Hasil Klasifikasi Model 2 Kelas (B)	52
Tabel 4. 11 Hasil Klasifikasi Model 3 Kelas (A).....	57
Tabel 4. 12 Hasil Klasifikasi Model 3 Kelas (B).....	64
Tabel 4. 13 Hasil Klasifikasi Model 6 Kelas (A).....	67
Tabel 4. 14 Hasil Klasifikasi Model 6 Kelas (B).....	71
Tabel 4. 15 Hasil Klasifikasi Model Hierarchical 3 Kelas.....	75

Daftar Gambar

Gambar 2. 1 Pembuluh darah kapiler.....	8
Gambar 2. 2 <i>CapillaryScope 500 (MEDL4N5)</i>	9
Gambar 2. 3 Hasil <i>Nailfold Capillaroscopy</i>	10
Gambar 2. 4 Arsitektur VGG16.....	16
Gambar 2. 5 Arsitektur YOLOv11 (Sapkota dkk., 2025).....	18
Gambar 2. 6 Arsitektur EfficientNet	19
Gambar 2. 7 <i>Confusion Matrix</i>	20
Gambar 3. 1 Tahapan Penelitian	28
Gambar 3. 2 Urutan <i>Preprocessing</i>	30
Gambar 3. 3 Contoh pengambilan objek.....	31
Gambar 3. 4 Contoh hasil <i>Horizontal</i> dan <i>Vertical Flip</i>	32
Gambar 3. 5 Contoh hasil <i>Rotating</i>	32
Gambar 4. 1 <i>Confusion Matrix</i> Klasifikasi EfficientNet 2 Kelas (A).....	49
Gambar 4. 3 Grafik <i>Training Accuracy</i> EfficientNet 2 kelas (A).....	50
Gambar 4. 4 <i>Confusion Matrix</i> Klasifikasi YOLOv11 untuk 2 Kelas (A)	51
Gambar 4. 5 Grafik <i>Training Accuracy</i> YOLOv11 untuk 2 kelas (A)	52
Gambar 4. 6 <i>Confusion Matrix</i> Klasifikasi EfficientNet 2 Kelas (B).....	54
Gambar 4. 7 Grafik <i>Training Accuracy</i> EfficientNet 2 kelas (B).....	55
Gambar 4. 8 <i>Confusion Matrix</i> Klasifikasi YOLOv11 untuk 2 Kelas (B).....	56
Gambar 4. 9 Grafik <i>Training Accuracy</i> YOLOv11 untuk 2 kelas (B).....	57
Gambar 4. 10 <i>Confusion Matrix</i> Klasifikasi EfficientNet 3 Kelas (A).....	60
Gambar 4. 11 Grafik <i>Training Accuracy</i> EfficientNet 3 kelas (A).....	61
Gambar 4. 12 <i>Confusion Matrix</i> Klasifikasi YOLOv11 untuk 3 Kelas (A)	62
Gambar 4. 13 Grafik <i>Training Accuracy</i> YOLOv11 untuk 3 kelas (A)	63
Gambar 4. 14 <i>Confusion Matrix</i> Klasifikasi ResNet-50 untuk 3 Kelas (B).....	65
Gambar 4. 15 Grafik <i>Training Accuracy</i> ResNet-50 untuk 3 kelas (B)	66
Gambar 4. 16 <i>Confusion Matrix</i> Klasifikasi EfficientNet 6 Kelas (A).....	69
Gambar 4. 17 Grafik <i>Training Accuracy</i> EfficientNet 6 kelas (A).....	70
Gambar 4. 18 <i>Confusion Matrix</i> Klasifikasi EfficientNet 6 Kelas (B).....	73
Gambar 4. 19 Grafik <i>Training Accuracy</i> EfficientNet 6 kelas (B)	74

Gambar 4. 20 <i>Confusion Matrix</i> Klasifikasi EfficientNet Stage 1 untuk 2 Kelas	77
Gambar 4. 21 Grafik <i>Training Accuracy</i> EfficientNet Stage 1 untuk 2 Kelas	78
Gambar 4. 22 <i>Confusion Matrix</i> EfficientNet Stage 2 untuk 2 Kelas.....	79
Gambar 4. 23 Grafik <i>Training Accuracy</i> EfficientNet Stage 2 untuk 2 Kelas	80
Gambar 4. 24 <i>Confusion Matrix</i> Model EfficientNet Hierarchical.....	81



UNIVERSITAS
MA CHUNG

Bab I

Pendahuluan

1.1 Latar Belakang

Diabetes melitus (DM) adalah penyakit kronis yang memerlukan pemantauan dan penanganan yang konstan, bukan hanya mengontrol glukosa darah. Salah satu komplikasi serius yang dapat terjadi pada penderita diabetes melitus tipe 2 adalah ulkus kaki diabetik (UKD), yang menyebabkan tingginya angka amputasi pada pasien diabetes. UKD umumnya disebabkan oleh tekanan berulang pada pasien dengan neuropati perifer (Armstrong dkk., 2017). Neuropati perifer merupakan salah satu bentuk neuropati diabetik yang paling sering ditemukan pada pasien diabetes melitus (IDF, 2017). Neuropati perifer terjadi karena adanya peningkatan stres pada sel saraf yang menyebabkan kepekaan yang berkurang terhadap rangsangan seperti nyeri, suhu, sentuhan yang beresiko mengakibatkan UKD (Ahmad, 2016). Diabetes neuropati menjadi penyebab utama morbiditas dan mortalitas pada pasien diabetes melitus, serta menghasilkan beban ekonomi yang besar (Salawu dkk., 2018). Frekuensi terjadinya ulkus kaki diabetik pada penderita diabetes melitus tipe 2 cukup tinggi, terutama pada pasien yang telah menderita diabetes melitus selama lebih dari 10 tahun, dan 60% mengalami kecacatan bahkan sampai amputasi kaki (Rismayanti dkk., 2022).

Penilaian tingkat keparahan ulkus sangat penting dalam perawatan pasien dengan DFU dan telah dilaporkan memiliki dampak yang lebih besar pada keberhasilan pengobatan akhir daripada lokasi ulkus. Oleh karena itu, strategi pencegahan, termasuk pemeriksaan kaki diabetik tahunan, telah diterapkan untuk memungkinkan identifikasi dini pasien diabetes yang berisiko tinggi mengalami komplikasi kaki diabetik. Deteksi dini neuropati perifer, perawatan kaki, dan kontrol glikemik yang baik dapat mengurangi tingkat penyakit akibat neuropati perifer (Gogia dan Rao, 2017). Selain itu, ketika telah dilakukan pendeteksian dini, petugas kesehatan mengetahui resiko pasien dan dapat memberikan pengarahan mengenai perawatan kaki pada pasien diabetes, yang akhirnya akan membantu pencegahan ulkus kaki diabetik (Anggreni dkk., 2025).

Salah satu intervensi kesehatan yang dapat dieksplorasi dalam manajemen kaki diabetik adalah teknologi pemrosesan citra digital dan kecerdasan buatan. Kecerdasan buatan (AI) mencakup deskripsi penggunaan komputer dan teknologi untuk mensimulasikan perilaku cerdas dan pemikiran kritis. Berbagai metode mengatasi masalah ini jumlah data kesehatan yang berbeda dan semakin meningkat, memungkinkan otonomi pasien yang lebih besar dan perawatan yang dipersonalisasi. Algoritma yang digunakan belajar mengenali data yang kompleks dengan cepat, dan dari konsep yang tidak berstruktur sekalipun. Kemajuan dalam pemrosesan dan analisis citra mengurangi kebutuhan pemeriksaan manual yang dapat mengabaikan perbedaan kecil. Peningkatan ini memungkinkan AI untuk meningkatkan akurasi dalam kasus yang berbelit belit. Selain itu, penggunaan AI juga dapat mengurangi kesalahan manusia yang disebabkan oleh kelelahan dan pengawasan yang terbatas.

Teknologi kecerdasan buatan yang berbasis pemrosesan citra digital telah banyak digunakan untuk skrining kaki diabetes. Salah satu model pengembangan untuk deteksi dini menggunakan dekomposisi citra digital menggunakan citra termograf untuk melakukan pencarian zona risiko pada telapak kaki penderita diabetes melitus. Termografi juga merupakan salah satu metode non-invasif yang dapat digunakan untuk memprediksi risiko, karena perbedaan suhu pada kaki dapat mengindikasikan masalah yang berhubungan dengan kaki diabetik. Namun, termografi memiliki keterbatasan dalam membedakan penyebab spesifik perubahan suhu, karena hanya dapat mendeteksi perbedaan suhu permukaan tanpa memberikan informasi tentang struktur mikrovaskular yang mendasarinya (Bagavathiappan dkk., 2010). Termografi tidak dapat secara langsung memvisualisasikan perubahan morfologi mikrovaskular yang merupakan manifestasi awal neuropati diabetik (Chatchawan dkk., 2018).

Pada penelitian ini, pengambilan data pembuluh darah pasien diabetes dilakukan dengan menggunakan teknik *Nailfold Capillaroscopy (NFC)*. Teknik ini dilakukan dengan menggunakan alat bernama *CapillaryScope 500 (MEDL4N5)*. *Nailfold Capillaroscopy (NFC)* adalah teknik pencitraan yang menganalisis mikrovaskular pada jari tangan dan kaki (Lisco dan Triggiani,

2023). Pengamatan mikrovaskular tidak hanya menyangkut pada penyakit rematologi, tetapi juga pada penyakit sistemik seperti diabetes melitus (Yilmas dkk., 2022). Pada individu yang sehat, NFC biasanya menunjukkan kapiler berbentuk jepit rambut yang tersusun secara seragam dalam pola yang menyerupai sisir, pada lipatan kuku proksimal (Srivastava dkk., 2024).

Penelitian ini bertujuan untuk mengembangkan model kecerdasan buatan (AI) dalam mengklasifikasikan pembuluh darah kapiler pada proses skrining kaki diabetik melalui analisis citra digital. Luaran yang diharapkan adalah peningkatan akurasi dan efisiensi skrining dengan memanfaatkan teknologi AI dan pencitraan digital. Temuan penelitian diharapkan dapat mendorong pengembangan sistem diagnosis dini, yang pada akhirnya membantu mencegah komplikasi lebih efektif. Selain itu, penelitian ini juga mendukung penerapan sistem tersebut dalam setting klinis dengan mempertimbangkan aspek metodologis dan praktis.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang sudah dipaparkan, dapat disimpulkan identifikasi masalahnya adalah sebagai berikut ini.

1. Kesulitan dalam menentukan kondisi kesehatan pasien berdasarkan gejala luar yang tampak pada pasien diabetes.
2. Pemeriksaan manual pada pasien DM memakan waktu yang lama dan dapat menghasilkan interpretasi yang berbeda beda.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Proses klasifikasi pembuluh darah pasien diabetes melitus (DM) akan dilakukan menggunakan algoritma *Deep Learning*.
2. Algoritma *Deep Learning* yang digunakan yaitu EfficientNet, ResNet, VGG16, dan YOLOv11.
3. Dilakukan 3 fase pengujian. Pengujian pertama akan dilakukan dengan membagi dataset ke dalam 2 class (*binary class*), yakni kelas pembuluh darah normal dan pembuluh darah abnormal. Fase pengujian

kedua dilakukan dengan membagi dataset ke dalam 3 kelas, yakni pembuluh darah orang sehat, pembuluh darah penderita DM Neuropati, dan pembuluh darah penderita DM Non Neuropati. Sementara pada fase pengujian ketiga, dataset akan dibagi ke dalam 6 class yang terdiri dari pembuluh darah normal orang sehat, pembuluh darah abnormal orang sehat, pembuluh darah normal penderita DM Neuropati, pembuluh darah abnormal penderita DM Neuropati, pembuluh darah normal penderita DM Non Neuropati dan pembuluh darah abnormal penderita DM Non Neuropati

1.4 Rumusan Masalah

Rumusan masalah dari penelitian ini adalah:

1. Bagaimana mengetahui kondisi pembuluh darah pasien diabetes melitus (DM) melalui pendekatan citra medis yg diambil melalui teknik *Nailfold Capillaroscopy (NFC)* menggunakan perangkat *CapillaryScope 500 (MEDL4N5)*?
2. Bagaimana mengukur performa model dari keempat arsitektur *Deep Learning* yaitu EfficientNet, ResNet, VGG16, dan YOLOv11.

1.5 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengetahui kondisi pembuluh darah pasien diabetes melitus (DM) melalui pendekatan citra medis yang diambil melalui teknik *Nailfold Capillaroscopy (NFC)* menggunakan perangkat *CapillaryScope 500 (MEDL4N5)* dengan pendekatan algoritma *Deep Learning*.
2. Memilih arsitektur terbaik dari keempat algoritma *Deep Learning* yaitu EfficientNet, ResNet, VGG16, dan YOLOv11.

1.6 Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Hasil penelitian dapat membantu dalam pengembangan model AI berbasis pemrosesan citra digital yang mampu mendeteksi tanda-tanda awal UKD dengan lebih akurat dan efisien dibandingkan metode konvensional.
2. Adanya deteksi dini yang lebih baik membantu pasien diabetes dapat menerima intervensi yang lebih cepat, sehingga mengurangi risiko amputasi dan komplikasi yang lebih parah.
3. Hasil penelitian ini dapat menjadi dasar bagi pengembangan dan penerapan sistem berbasis AI dalam skrining kaki diabetik, sehingga mempercepat adopsi teknologi dalam dunia medis dan meningkatkan efisiensi layanan kesehatan.

1.7 Rencana Penelitian

Tabel 1. 1 Rencana Penelitian

Proses	Maret				April				Mei				Juni				Juli	
	W2	W3	W4	W1	W2	W3	W4	W1	W2	W3	W4	W1	W2	W3	W4	W1	W2	
Studi Literatur																		
Eksperimen																		
Analisa Performa Model																		
Pelaporan																		
Sidang Akhir																		

Penelitian ini direncanakan untuk berlangsung selama lima bulan, mulai dari pertengahan Maret hingga pertengahan Juli 2025. Setiap tahapan kegiatan disusun secara sistematis agar saling mendukung dan memastikan kelancaran proses penelitian. Tahap awal yang dilakukan adalah studi literatur, yang dilaksanakan sejak pertengahan Maret hingga awal April. Kegiatan ini bertujuan untuk memperkuat pemahaman terhadap landasan teori serta mengumpulkan referensi yang relevan guna menunjang perancangan dan pelaksanaan penelitian. Setelah itu, eksperimen dimulai pada akhir Maret dan berlangsung hingga akhir

Juni, berjalan secara paralel dengan studi literatur agar proses pengujian model dapat segera dilakukan.

Memasuki bulan Juni, kegiatan penelitian difokuskan pada analisa performa model untuk mengevaluasi dan membandingkan hasil eksperimen dari masing-masing arsitektur yang digunakan. Hal ini bertujuan menentukan model yang paling sesuai dengan kebutuhan klasifikasi citra kapilaroskopi. Seluruh rangkaian kegiatan tersebut dilakukan bersamaan dengan proses pelaporan, yang mencakup penyusunan laporan akhir serta penulisan artikel ilmiah. Kegiatan pelaporan ini berlangsung secara berkesinambungan sejak pertengahan Maret hingga pertengahan Juli. Rangkaian kegiatan penelitian diakhiri dengan Sidang Akhir pada minggu kedua Juli. Rencana waktu pelaksanaan secara lengkap disajikan dalam bentuk Gantt Chart seperti yang ditampilkan pada Tabel 1. 1.

1.8 Luaran

Luaran dari penelitian ini mencakup model *deep learning* yang dikembangkan serta publikasi dalam bentuk artikel ilmiah. Model *deep learning* yang dihasilkan dirancang untuk menyelesaikan permasalahan spesifik sesuai dengan pusat penelitian, dengan proses *training* data dan evaluasi menggunakan dataset yang relevan.

Bab II

Tinjauan Pustaka

2.1 Diabetes Melitus

Diabetes melitus atau penyakit kencing manis merupakan penyakit kronis yang dapat ditandai dengan adanya gangguan metabolisme karbohidrat, lemak, dan protein yang terjadi akibat kurangnya insulin. Insulin adalah hormon yang dihasilkan pankreas yang berfungsi untuk mengatur glukosa pada darah (Waldman dkk., 2020). Diabetes melitus ditandai dengan kondisi hiperglikemia kronis dan perubahan pada struktur pembuluh darah (Maldonado dkk., 2017). Diabetes melitus (DM) memiliki 2 tipe, yaitu DM tipe 1 dan DM tipe 2. DM tipe 1 diakibatkan oleh destruksi autoimun sel pankreas yang mengakibatkan defisiensi insulin absolut. Sedangkan DM tipe 2 diakibatkan oleh resistensi insulin pada jaringan yang disertai defisiensi insulin relatif (Marasabessy dkk., 2020).


Pada tahun 2021, *International Diabetes Federation (IDF)* mencatat ada 537 juta orang dewasa (mulai usia 20-79 tahun) atau 1 dari 10 orang terserang diabetes. Salah satu komplikasi penyakit diabetes melitus yaitu kaki diabetik, yang dapat memunculkan ulkus, infeksi, dan gangren. Seorang penderita diabetes, akan memiliki luka kaki sebesar 15-20% dengan tingkat kekambuhan 50-70% dalam 5 tahun, dimana 85% penderita yang mengalami luka pada kaki akan menjalani amputasi (Rosaline dkk., 2025). Sebagian besar komplikasi kaki diabetik yang mengakibatkan amputasi dimulai dari adanya pembentukan ulkus kaki diabetik. Amputasi dapat dicegah hingga 85% dengan adanya deteksi dini dan pengobatan yang tepat (Al-Mahroos, 2007).

2.2 Diabetes Melitus Neuropati

Diabetes melitus tipe 2 sering diiringi oleh komplikasi serius, seperti neuropati diabetik dan ulkus diabetik (Hendrico dkk., 2025). Neuropati diabetik adalah komplikasi mikroangiopati yang menyebabkan kerusakan saraf. Kondisi ini dapat memicu nyeri kronis, gangguan sensorik, hingga kecacatan (Wayunah dkk., 2024). Pada kondisi terparah, neuropati diabetik dapat menyebabkan

kematian sel neuron di bagian perifer sehingga saat terdapat luka, neuron tidak akan menghantarkan rangsangan dan pasien tidak akan merasakan sakit (Asmara dkk., 2023). Setengah dari pasien neuropati diabetik menderita gejala neuropatik yang menyakitkan. Gejala gelaja ini umumnya menyebabkan depresi, kecemasan, gangguan tidur, dan penurunan kualitas hidup (Yang dkk., 2020). Dengan meningkatnya beban diabetes dan pradiabetes di seluruh dunia, prevalensi diabetes melitus juga akan meningkat dalam beberapa dekade mendatang. Oleh karena itu, ada kebutuhan krisis untuk mengatasi tantangan diagnostik utama untuk komplikasi neuropati diabetik, dengan mengidentifikasi strategi terbaik untuk mendiagnosis diabetes melitus pada tahap awal perjalanan penyakit (Jensen dkk., 2021)

2.3 Pembuluh Darah Kapiler



Gambar 2. 1 Pembuluh darah kapiler
sumber : <https://www.britannica.com/science/capillary>

Pembuluh darah kapiler atau yang biasa disebut pembuluh rambut adalah pembuluh darah tipis oleh membran dalam, yang mendorong pertukaran zat pada pembuluh darah, sel, dan jaringan. Pembuluh darah ini merupakan persimpangan antara pembuluh darah vena dan arteri (Sandy, 2021). Kapiler memiliki diameter yang sangat kecil, berkisar antara 5-10 mikrometer, yang lebih kecil dari diameter sel darah merah (7-8 mikrometer), sehingga tidak mungkin terlihat oleh mata telanjang yang hanya mampu melihat objek dengan ukuran minimal sekitar 100

mikrometer (Guyton, 2020). Pembuluh darah kapiler berfungsi sebagai penghubung antara pembuluh darah vena dan pembuluh darah arteri. Pembuluh darah kapiler juga merupakan tempat pertukaran zat antara darah dan cairan jaringan. Selain itu, pembuluh darah kapiler juga berfungsi mengambil hasil dari kelenjar, menyerap makanan pada usus, dan menyaring darah pada ginjal (Maola, 2018).

2.4 Kapilaroskopi

Kapilaroskopi adalah metode mikroskopi sederhana non-invasif yang memungkinkan evaluasi morfologi dasar pembuluh darah secara kualitatif dan semi kuantitatif untuk mendeteksi area abnormal (Londono-Mora dkk., 2020). Visualisasi pembuluh darah kapiler pada kuku diawali oleh dokter yang bernama Johan Christophorous Kolhaus pada tahun 1663 (Dima dkk., 2021). Kapilaroskopi diterapkan untuk memprediksi risiko perkembangan komplikasi dan ulkus pada pasien (Senet dkk., 2014). Evaluasi pola kapilaroskopi dihasilkan dari kombinasi karakteristik numerik dan morfologis seperti diameter kapiler (lebar), panjang kapiler, bentuk, distribusi, kepadatan rata rata kapiler, keberadaan area avaskular, dna pendarahan (Ingegnoli dkk., 2013). Kapiler pada lipatan kuku terlihat sejajar dengan kulit yang memungkinkan seluruh lengkung kapiler dapat divisualisasikan (Hosking dkk., 2013).



Gambar 2. 2 *CapillaryScope 500 (MEDL4N5)*

Sumber: <http://dino-lite.eu/en/capillaryscope-500-pro-medl4n5-pro> (Accesed 10 April 2025)

Pada penelitian ini, metode kapilaroskopi dilakukan menggunakan alat bernama *CapillaryScope 500 (MEDL4N5)*. Alat ini berfungsi untuk melihat sirkulasi mikro (fungsi mikrokapiler) pembuluh darah di bawah kuku jari. Dengan *CapillaryScope* digital yang ringkas dan serbaguna ini, mudah untuk menangkap dan menyimpan gambar kapilaroskopi lipatan kuku yang sangat detail pada tingkat pembesaran tinggi 500x. Gambar yang dihasilkan oleh *CapillaryScope* berukuran 1280x1024.



Gambar 2. 3 Hasil *Nailfold Capillaroscopy*

Sumber: <http://dino-lite.eu/en/capillaryscope-500-pro-medl4n5-pro> (Accessed 10 April 2025)

Nailfold Capillaroscopy (NFC) adalah teknik pencitraan yang mengevaluasi morfologi pembuluh darah kapiler (mikro) pada jari kaki dan jari tangan. Beberapa penelitian telah menunjukkan manfaat kapilaroskopi lipatan kuku dalam mengevaluasi mikrovaskular pada diabetes melitus seperti retinopati, nefropati, dan neuropati (Lekakis dkk., 2020). Perubahan yang diamati yaitu hilangnya pembuluh darah kapiler, berkurangnya kepadatan kapiler, dan meningkatnya lengkungan kapiler (Anandh dkk., 2023). Metode ini digunakan dalam menilai kerusakan atau cedera pada pembuluh darah mikro dalam kondisi termasuk hipertensi dan diabetes tipe 2, dan penyakit endokrin (Lisco dan Triggiani, 2023).

2.5 *Artificial Intelligence (AI)*

Artificial Intelligence (AI) adalah cabang ilmu yang fokus menciptakan cara kerja cerdas yang mampu meniru kemampuan berpikir dan perilaku manusia. *Artificial Intelligence* bertujuan untuk mengembangkan perangkat lunak yang dapat berpikir secara rasional, mengambil keputusan, menyelesaikan masalah kompleks, dan belajar dari pengalaman (Russel dan Norvig, 2010).

Artificial Intelligence membawa revolusi signifikan dalam kemampuan otomatisasi proses visual yang kompleks. Klasifikasi citra menggunakan AI melibatkan penggunaan algoritma *machine learning* untuk mengidentifikasi dan mengkategorikan objek atau pola dalam citra digital (Szeliski, 2022). Teknologi ini menjadi pondasi dalam *computer vision*, memungkinkan komputer menafsirkan dunia visual seperti yang dilakukan oleh manusia (Goodfellow dkk., 2016).

Pendekatan klasifikasi citra didominasi *Deep Learning* khususnya *Convolutional Neural Network (CNN)*, yang mampu mempelajari representasi hirarkis dari gambar (Prince, 2012). CNN bekerja dengan mengenali pola visual secara bertahap, mulai dari fitur yang sederhana seperti tepi hingga konsep yang kompleks seperti wajah (LeCun dkk., 2015). Keuntungan utama CNN adalah kemampuan otomatisasi dalam mengekstrak fitur relevan tanpa rekayasa fitur manual yang ekstensif.

2.6 *Machine Learning*

Machine Learning merupakan subdomain *Artificial Intelligence* yang memungkinkan sistem komputer belajar dan berkembang dari pengalaman atau sistem yang sudah ada tanpa perlu pemrograman secara eksplisit. Konsep dasar *machine learning* yaitu membuat algoritma yang dapat menganalisis data, mengenali pola, membuat prediksi, dan meningkatkan performa secara mandiri manual (Géron, 2019).

2.6.1 *Supervised Learning*

Supervised Learning adalah metode *machine learning* di mana algoritma dilatih menggunakan dataset yang memiliki label. Karakteristik supervised learning yaitu memiliki input dan output yang sudah diketahui, model belajar memetakan input ke output yang benar, dan tujuan utamanya adalah memprediksi output untuk data baru (Bishop, 2006). Contoh algoritma *supervised learning* adalah Regresi Linier, Regresi Logistik, *Support Vector Machine*, *Decision Trees*, dan *Neural Networks*. Pada penelitian ini menggunakan *supervised learning Convolutional Neural Networks (CNN)*.

2.6.2 *Unsupervised Learning*

Unsupervised Learning adalah metode *machine learning* di mana algoritma berusaha menemukan struktur tersembunyi dalam data tanpa label atau output yang jelas (Bishop, 2006). Karakteristik *unsupervised learning* yaitu tidak adanya target *output* yang ditentukan, algoritma fokus pada pengelompokkan, pengurangan dimensi, dan deteksi pola (Géron, 2019). Tipe utama *unsupervised learning* yaitu *Clustering* (pengelompokkan), *Dimensionality Reduction* (pengurangan dimensi), *Anomaly Detection* (deteksi anomali).

2.7 *Deep Learning*

Deep learning merupakan bentuk dari *machine learning* yang memanfaatkan jaringan saraf tiruan yang berlapis lapis (Nugroho dkk., 2020). Dalam metode ini, terdapat pembelajaran yang dilakukan mesin untuk dapat memahami dan mengklasifikasikan suatu objek dalam bentuk citra (Putera dkk., 2020). Ekstraksi fitur dan klasifikasi di dalam jaringan *deep learning* tidak dilakukan secara eksplisit. *Deep learning* dapat mempelajari metode komputasinya sendiri tanpa bantuan eksternal (Swapna dkk., 2018). Meskipun membutuhkan waktu yang lama untuk melakukan *training* model, waktu yang dibutuhkan saat pengujian lebih cepat dibandingkan metode *machine learning* lainnya (Sarker, 2021).

2.8 *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) merupakan salah satu algoritma yang dapat digunakan untuk mengelola informasi citra. Model CNN banyak digunakan untuk memproses citra karena memiliki tingkat akurasi tinggi dalam mengenali citra (Rijal dkk., 2016 cit. Nugroho, 2024). Algoritma CNN memiliki beberapa keunggulan termasuk akurasi tinggi, kinerja yang signifikan dalam mendeteksi objek, kemampuan untuk mengklasifikasikan gambar, mengidentifikasi pola dan fitur, pembelajaran transfer, pemrosesan *real-time*, dan penggunaan dataset yang diperbanyak (Desiani et al., 2021; Tasnim et al., 2021).

2.9 *Preprocessing Citra*

Preprocessing Citra merupakan serangkaian teknik dalam pengolahan citra digital yang bertujuan mempersiapkan dataset citra untuk proses berikutnya (Richards, 2012). Proses ini menjadi langkah penting dalam berbagai aplikasi *computer vision*, *machine learning*, dan analisis pencitraan (Jain, 2010). Tujuan utama dari *preprocessing* citra ini adalah untuk mengoptimalkan kualitas citra, mengurangi variasi yang tidak diinginkan, dan mempersiapkan data untuk masuk ke algoritma (Jahne, 2014).

2.9.1 *Cropping (Pemotongan Citra)*

Cropping adalah proses memotong bagian spesifik dari sebuah citra untuk fokus pada area yang relevan (Szeliski, 2010). Teknik ini membantu menghilangkan bagian foto yang tidak digunakan seperti *background* dan mengekstraksi *region of interest (ROI)* dengan presisi (Nixon dan Aguado, 2019). Dalam *machine learning*, *cropping* secara signifikan dapat mengurangi kompleksitas dan meningkatkan akurasi model (Forsyth dan Ponce, 2019).

2.9.2 *Resizing (Pengubahan Ukuran)*

Resizing merupakan transformasi dalam *preprocessing* citra yang menghasilkan perubahan dimensi citra (Shapiro dan Stockman, 2001). Tujuan dari

resizing adalah untuk menyesuaikan ukuran citra dengan kebutuhan arsitektur jaringan seperti pada CNN, menstandarisasi input agar model lebih konsisten, mengurangi kebutuhan komputasi, dan mengoptimalkan penggunaan memori (Sonka dkk., 2014).

2.10 Augmentasi Data

Augmentasi data adalah teknik yang digunakan untuk memperbanyak dataset dengan menghasilkan beberapa variasi dari data yang sudah ada. Tujuan utama dilakukan proses augmentasi data ini adalah untuk meningkatkan performa dan akurasi model sehingga tidak terjadi *overfitting* (Santoso, 2024). Selain meningkatkan jumlah data, teknik ini juga membantu model dalam training data terhadap berbagai kondisi yang berbeda (Amrulloh dkk., 2024). Data yang digunakan berupa potongan gambar pembuluh darah kapiler pada kuku. Hasil augmentasi data dapat digunakan sebagai dataset pelatihan model kecerdasan buatan.

2.10.1 Flipping

Flipping adalah salah satu teknik augmentasi citra dengan membalik citra secara horizontal atau vertikal untuk menciptakan varian baru (Zhang, 2019). Teknik ini membantu model menjadi bervariasi terhadap orientasi objek (Chollet, 2017).

2.10.2 Rotasi

Teknik rotasi dilakukan dengan memutar citra dalam berbagai sudut untuk mensimulasikan variasi orientasi (Géron, 2019). Rentang rotasi antara -10 hingga 90 derajat, hal ini bertujuan membangun ketahanan model terhadap perubahan sudut (Brownlee, 2018).

2.10.3 *Scaling*

Scaling bertujuan untuk mengubah citra untuk melatih model mengenali objek dalam berbagai skala (Howard, 2013). *Scaling* dilakukan dengan melakukan *zoom in*, *zoom out*, atau penskalaan parsial (Krizhevsky dkk., 2012).

2.10.4 Translasi


Translasi adalah metode untuk memindahkan objek dalam citra secara acak untuk mengurangi bias spasial (Szegedy, 2015). Teknik ini mengajarkan model untuk mengenali objek selain pada posisi absolutnya (He dkk., 2016).

2.10.5 *Brightness* dan *Contrast Augmentation*

Teknik ini melakukan manipulasi parameter pencahayaan dan kontras untuk mensimulasikan kondisi akuisisi citra yang berbeda (Kingma dan Ba, 2014). Teknik ini juga dapat membangun ketahanan model terhadap variasi pencahayaan (Ioffe dan Szegedy, 2015).

2.11 VGG16

VGG16 merupakan singkatan dari “*Very Deep Convolutional Networks for large-scale Image Recognition 16-layer*” (Saswono dkk., 2020). Arsitektur ini memiliki 16 layer, termasuk 13 *convolutional layers* dan 3 *fully connected layers*. VGG16 telah terbukti menghasilkan tingkat akurasi tinggi dalam pengenalan gambar dari jutaan data dan ribuan kelas yang berbeda (Rizki dan Marina, 2020). Dengan banyaknya dataset yang digunakan dalam penelitian ini, arsitektur VGG16 dirasa sesuai karena kemampuannya dalam menangani kompleksitas data visual dan menghasilkan generalisasi yang baik.



Gambar 2. 4 Arsitektur VGG16

Sumber: https://www.researchgate.net/figure/Gambar-4-Arsitektur-VGG16-9_fig1_350115831

(Accesed 29 Maret 2025)

Kelebihan dari VGG16 yaitu arsitektur sederhana dan seragam yang mudah diimplementasikan (Raschka dan Mirjalili, 2019), ekstraksi fitur yang dangat baik dari citra (Szeliski, 2010), dan kedalaman model yang memberikan representasi yang beragam (Parker, 2010). Sedangkan kekurangan VGG16 sendiri yaitu jumlah parameter yang sangat besar membutuhkan memori dan komputasi yang tinggi (LeCun dkk., 2015), waktu training yang lebih lama dibandingkan arsitektur lain (Karpathy dkk., 2014), dan tidak mengimplementasikan teknik modern seperti *batch normalization* (Dumoulin dan Visin, 2018).

2.12 ResNet

ResNet adalah salah satu arsitektur CNN yaitu *Residual Network*. Arsitektur ini dirancang untuk mengklasifikasikan gambar dengan menggunakan konsep *residual learning* (Ryandra, 2022). *Residual learning* dalam ResNet menggunakan konsep *residual blocks* yang memungkinkan jaringan belajar lebih efektif dengan menambah shortcut connections sehingga informasi penting dapat melewati beberapa layer tanpa modifikasi. Dalam analisis citra medis, arsitektur ini telah terbukti efektif untuk mengekstraksi fitur dari gambar yang kompleks sehingga menghasilkan akurasi tinggi dalam klasifikasi (Syaripudin dkk., 2025). Arsitektur ini memiliki berbagai jenis mulai dari 18, 34, 50, 101, hingga 152 layer (Ganda dan Bunyamin, 2021).


Kelebihan ResNet yaitu mampu melatih jaringan dengan sangat dalam tanpa degradasi performa (Hastie dkk., 2016), konvergensi lebih cepat karena menggunakan *residual connections* (Haykin, 2008), dan penggunaan parameter yang lebih sedikit (Alpaydin, 2020). Sedangkan kekurangannya yaitu kompleksitas implementasi yang lebih tinggi dibanding arsitektur konvensional (Forsyth dan Ponce, 2011), memerlukan optimasi khusus untuk perangkat *mobile* dan *edge computing* (Kaehler dan Bradski, 2016), dan membutuhkan jumlah parameter yang signifikan untuk varian yang dalam (Davies, 2017).

2.13 YOLOv11

YOLO (You Only Look Once) merupakan salah satu metode deteksi objek yang digunakan untuk pemrosesan data secara *real-time* (Lathifah dkk., 2020). Metode deteksi objek bertugas untuk menentukan letak objek dalam gambar dan menentukan objek ke dalam kelas tertentu (Phadnis dkk., 2018). Cara kerja YOLO yaitu melihat keseluruhan gambar selama waktu training dan testing sehingga secara implisit menyimpan informasi tentang kelas dan tampilannya (Girshick, 2015).

Arsitektur YOLO terdiri dari 27 layer CNN, yaitu 24 layer yang terdiri dari ukuran 2×2 , kemudian diikuti 2 *fully connected layer* dan 1 *final decision layer* dengan ukuran kernel 1×1 . YOLO membagi citra yang dimasukkan menjadi suatu *grid* berukuran $S \times S$ dimana tiap sel dan grid akan memprediksi *bounding box* dan menghasilkan nilai untuk tiap kelas. Masing masing *bounding box* terdiri dari 5 nilai prediksi yaitu pusat koordinat x , koordinat y , lebar sel (w), tinggi sel (h) dan nilai *confidence*.

Convolutional layer menggunakan *filter* sebagai parameter dalam proses training. *Filter* diinisialisasi dengan suatu nilai, kemudian dari kalkulasi *grid* pada citra dengan nilai *filter* dihasilkan *output* nilai berbentuk array. Kemudian, dengan menggeser *filter* di setiap kemungkinan posisi pada citra untuk dihasilkan sebuah *activation map* (Azhar dkk., 2021).




Gambar 2. 5 Arsitektur YOLOv11 (Sapkota dkk., 2025)

Salah satu fitur YOLOv11 yaitu kemampuan menyeimbangkan presisi dan efisiensi komputasi, sehingga cocok untuk berbagai aplikasi hingga penerapan skala besar. Pada versi ini juga memiliki tingkat akurasi deteksi yang tinggi dan pemrosesan *real-time* dalam berbagai kondisi (Sapkota dkk., 2025). Model ini menggabungkan C3k2 (*Cross Stage Partial* dengan ukuran kernel 2), dengan peningkatan komputasi yang lebih efisien (Sapkota dkk., 2024). YOLOv11 juga mempertahankan SPPF (*Spatial Pyramid Pooling-Fast*) dan memperkenalkan C2PSA (*Convolutional block with Parallel Spatial Attention*). Peningkatan arsitektur ini memungkinkan penangkapan detail gambar yang rumit dengan presisi yang tinggi, khususnya yang melihatkan objek kecil (Sapkota dkk., 2024).

2.14 EfficientNet

EfficientNet merupakan arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan dengan metode scaling yang secara bersamaan menyeimbangkan kedalaman jaringan, lebar, dan resolusi untuk menghasilkan performa yang lebih baik. Metode ini menggunakan koefisien compound yang sederhana namun sangat efektif untuk menyeimbangkan semua dimensi kedalaman/lebar/resolusi secara seragam (Tan dan Le, 2019).



Gambar 2. 6 Arsitektur EfficientNet

sumber : <https://viso.ai/deep-learning/efficientnet/> (Accesed : 4 Juli 2025)

Arsitektur EfficientNet terdiri dari beberapa komponen utama. EfficientNet menggunakan *Mobile Inverted Bottleneck (MBConv) layers*, yang merupakan kombinasi dari *depth-wise separable convolutions* dan *inverted residual blocks*. Selain itu, arsitektur model menggunakan optimisasi *Squeeze-and-Excitation (SE)* untuk lebih meningkatkan performa model (Roboflow, 2024).

Pada inti EfficientNet adalah prinsip *compound scaling*, metode yang secara seragam melakukan scaling pada kedalaman, lebar, dan resolusi jaringan, memastikan keseimbangan harmonis antara dimensi-dimensi tersebut (Herath, 2024). Dengan melakukan scaling setiap aspek secara proporsional, EfficientNet mencapai akurasi yang luar biasa dengan parameter minimal dan sumber daya komputasi (Herath, 2024). EfficientNet terdiri dari 8 model, mulai dari EfficientNet-B0 hingga EfficientNet-B7, dimana EfficientNet-B0 adalah fondasi di mana seluruh keluarga EfficientNet dibangun dan merupakan model terkecil dan paling efisien dalam varian EfficientNet (Viso.ai, 2025).

2.15 Confusion Matrix

Confusion Matrix adalah sebuah tabel yang menggambarkan performa model klasifikasi. *Confusion matrix* merupakan alat fundamental untuk menganalisis model klasifikasi dapat mengenali sampel dari kelas yang berbeda sejauh mana (Sokolova dan Lapalme, 2009). Tabel ini terdiri dari baris dan kolom sebanyak jumlah kolom yang menunjukkan nilai *false positives* (FP) yaitu data negatif namun terdeteksi sebagai data positif, *false negatives* (FN) yaitu data positif yang terdeteksi sebagai data negatif, *true positives* (TP) yaitu data positif yang terdeteksi benar, dan *true negatives* (TN) yaitu jumlah data negatif yang terdeteksi benar (Kurniadi dkk., 2020).

Nilai Aktual		Nilai Prediksi	
TP (True Positif)	FP (False Positif) error tipe 1		
	TN (True Negatif)	FN (False Negatif) error tipe 2	

Gambar 2. 7 *Confusion Matrix*

2.15.1 Accuracy

Menurut Powers (2011), *accuracy* adalah proporsi total prediksi yang benar. Nilai *accuracy* menggambarkan seberapa akurat model dapat mengklasifikasikan dengan benar. Nilai *accuracy* dapat diperoleh dengan persamaan:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2-1)$$

Keterangan:

$TP = \text{True Positif}$

$TN = \text{True Negatif}$

$FP = \text{False Positif}$

$FN = \text{False Negatif}$

2.15.2 Precision

Precision merupakan proporsi kasus positif yang diprediksi dengan benar dari total kasus yang diprediksi positif (Fawcett 2006). *Precision* berfokus pada meminimalisir *false positive* (Davis dan Goadrich, 2006). Nilai *precision* dapat diperoleh dengan persamaan:

$$precision = \frac{TP}{TP+FP} \quad (2-2)$$

Keterangan:

$TP = \text{True Positif}$

$FP = \text{False Positif}$

2.15.3 Recall (Sensitivity)

Recall digunakan untuk mengukur kemampuan model untuk mendeteksi sampel positif (Hossin dan Sulaiman, 2015). Perhitungan *recall* penting dalam konteks medis dimana mendeteksi semua kasus positif lebih penting daripada menghindari false positif (Japkowicz dan Shah, 2011). Nilai *recall* dapat diperoleh dari persamaan:

$$recall = \frac{TP}{TP+FN} \quad (2-3)$$

Keterangan:

$TP = \text{True Positif}$

$FN = \text{False Negatif}$

2.15.4 *F1 Score*

F1 Score adalah perbandingan rata rata *precision* dan *recall* yang dibobotkan. Nilai *F1 score* dapat diperoleh dengan persamaan:

$$f1\ score = 2 \times \frac{precision \times recall}{(precision+recall)} \quad (2-4)$$

Keterangan:

precision = Nilai *precision*

recall = Nilai *recall*

2.15.5 *Balanced Accuracy*

Rata-rata aritmatik dari *sensitivity* dan *specificity*, memberikan bobot yang sama untuk setiap kelas terlepas dari proporsinya. Nilai *Balanced Accuracy* dapat diperoleh dengan persamaan:

$$balanced\ accuracy = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \quad (2-5)$$

Keterangan:

TP = *True Positif*

TN = *True Negatif*

FP = *False Positif*

FN = *False Negatif*

2.15.6 *Matthews Correlation Coefficient (MCC)*

Metrik yang menghasilkan nilai tinggi hanya jika model berkinerja baik pada semua kategori (*TP*, *TN*, *FP*, *FN*). Nilai *MCC* dapat diperoleh dengan persamaan:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (2-6)$$

Keterangan:

$TP = True$ Positif

$TN = True$ Negatif

$FP = False$ Positif

$FN = False$ Negatif

2.15.7 *Confidence*

Confidence adalah tingkat keyakinan model terhadap prediksi di kelas tertentu. Setelah data melewati lapisan konvolusi dan *fully connected layer*, CNN menghasilkan output berbentuk numerik pada setiap kelas. Nilai ini kemudian dilewatkan melalui aktivasi *softmax* untuk menghasilkan nilai probabilitas *confidence* tiap kelas. *Softmax* memodifikasi output dari model menjadi distribusi probabilitas dengan jumlah total 1. Nilai probabilitas tertinggi menunjukkan sebagai *confidence score*. Misalnya, jika model menghasilkan probabilitas [0.85, 0.10, 0.05] untuk tiga kelas berbeda, maka *confidence* terhadap kelas pertama adalah 85% (Aggarwal, 2018).

2.16 Python

Python menawarkan keunggulan signifikan dalam pengembangan sistem analisis citra medis karena sintaks yang mudah dibaca, *library* yang komprehensif, serta dukungan komunitas yang luas (Chollet, 2021). Python memiliki keunggulan fleksibilitas yang memungkinkan peneliti menguji algoritma dan arsitektur *deep learning*, yang penting dalam domain medis karena akurasi dan performa yang menjadi prioritas utama (Géron, 2022).

2.16.1 NumPy

NumPy merupakan *library* fundamental untuk komputasi ilmiah di Python. NumPy menyediakan dukungan terhadap *array* dan *matriks* multidimensi, beserta fungsi matematika tingkat tinggi yang dapat diaplikasikan pada *array*.

Dalam analisis citra kapilaroskopi, NumPy digunakan untuk representasi dan manipulasi citra dalam bentuk *array* multidimensi, operasi matematika untuk menormalisasi *pixel*, ekstraksi *region of interest* dari citra kapilaroskopi, serta transformasi citra dalam proses augmentasi (Harrison, 2020).

2.16.2 Pandas

Pandas memiliki struktur data dan *tools* untuk menganalisis data secara efektif. Dalam konteks klasifikasi citra medis, Pandas digunakan untuk mengelola metadata citra, analisis hasil klasifikasi dan metrik evaluasi, pengelolaan dataset, dan ekspor hasil untuk analisis statistik.

2.16.3 Matplotlib dan Seaborn

Matplotlib dan Seaborn merupakan *library* visualisasi dalam Python. *Library* visualisasi sangat penting dalam analisis citra medis (Géron, 2022). Fungsi utama *library* ini yaitu untuk visualisasi citra kapilaroskopi dalam tahap *preprocessing*, *plotting* fitur pada citra, visualisasi hasil segmentasi, pembuatan grafik performa model, dan visualisasi *confusion matrix* untuk evaluasi model (Rosebrock, 2022).

2.16.4 Scikit-learn

Scikit-learn menyediakan implementasi algoritma *machine learning* dan tools evaluasi. *Library* ini digunakan untuk pembagian dataset menjadi data *train*, *test*, dan *validation*, evaluasi model (*precision*, *recall*, *f1-score*), implementasi teknik *cross-validation*, *feature selection*, dan kalibrasi dan *fine-tuning model* (Géron, 2022).

2.16.5 TensorFlow dan Keras

TensorFlow dengan API Keras merupakan framework *deep learning* yang dikembangkan oleh Google (Ramsundar dan Zadeh, 2018). TensorFlow dan Keras digunakan untuk implementasi CNN (VGG-16, ResNet), *transfer learning*,

augmentasi data untuk memperkaya dataset, *custom loss functions*, dan *deployment* model. Menurut Chollet (2021), Keras memiliki keunggulan dalam pengembangan *prototype* yang cepat dan implementasi arsitektur kompleks untuk analisis citra medis.

2.16.6 OpenCV

OpenCV adalah *library computer vision* yang menyediakan fungsi *preprocessing* citra. *Library* ini digunakan untuk *loading* dan *saving* citra dalam berbagai format, *preprocessing* citra, segmentasi citra, ekstraksi fitur morfologi citra, dan kalkulasi metrik bentuk dan struktur pada citra. OpenCV memiliki peran krusial dalam *preprocessing* citra medis untuk meningkatkan performa algoritma klasifikasi (Rosebrock, 2022).

2.16.7 Ultralytics

Ultralytics merupakan implementasi modern dari algoritma *YOLO* (*You Only Look Once*). *Library* ini digunakan untuk mendeteksi dan melokalisasi objek pada citra, melakukan segmentasi *instance*, pelacakan perubahan objek (*object tracking*), serta klasifikasi secara *real-time* untuk aplikasi klinis. *Framework* ini memungkinkan pendeteksian objek dengan kecepatan tinggi sambil mempertahankan tingkat akurasi yang baik (Jocher, 2023).

2.17 Penelitian Terdahulu

Penelitian terdahulu yang pertama ialah penelitian yang dilakukan oleh Gusti pada tahun 2024 dengan judul “Implementasi Algoritma *Convolutional Neural Network* (ResNet-50) dalam Klasifikasi Kanker Kulit *Benign* dan *Malignant*”. Penelitian ini menggunakan dataset dari *International Skin Image Collaborating (ISIC)* yang memiliki 2 kelas yaitu *benign* dan *malignant*. Data latih kanker kulit *benign* yaitu 5000 data dan kanker kulit *malignant* terdapat 4600 data. Pada penelitian ini terdapat *preprocessing* data dengan ekstraksi label data dan augmentasi data.

Penelitian ini menggunakan masing masing 1000 data uji tiap kelas dengan *epoch* 50, *optimizer* Adam dan *batch size* sebesar 54. Hasil dari penelitian ini yaitu model klasifikasi kanker kulit benign dan malignant dengan akurasi sebesar 93,88% dan *loss* sebesar 13,24%. Persamaan penelitian ini dengan penelitian terdahulu adalah penggunaan arsitektur CNN ResNet-50 untuk klasifikasi citra. Sedangkan perbedaannya terdapat pada jumlah klasifikasi kelas dari citra medis yang digunakan.

Penelitian yang kedua adalah penelitian yang dilakukan oleh Taha dkk., 2025 dengan judul “*Detecting Glioma, Meningioma, and Pituitary Tumors, and Normal Brain Tissues based on Yolov11 and Yolov8 Deep Learning Models*”. Penelitian ini membandingkan performa arsitektur YOLOv8 dan YOLOv11 untuk mengklasifikasikan 2107 citra Magnetic Resonance Imaging (MRI). Dataset kemudian dibagi menjadi tumor glioma, meningioma, pituitary, dan kondisi normal. Dari keseluruhan dataset dibagi menjadi data training dan testing.

Penggunaan arsitektur YOLOv8 menunjukkan hasil akurasi 99.49% sedangkan YOLOv11 menunjukkan performa sangat baik dengan akurasi 99.56%. Hasil ini menunjukkan bahwa model YOLOv11 memiliki performa yang baik dalam melakukan klasifikasi citra medis. Persamaan penelitian ini dengan penelitian terdahulu adalah penggunaan arsitektur YOLOv11 dalam klasifikasi objek pada citra medis. Namun, terdapat juga perbedaan antar penelitian terdahulu dan penelitian ini yaitu penelitian terdahulu membandingkan 2 model YOLOv8 dan YOLOv11 serta beberapa teknik augmentasi seperti rescaling, shearing dan zooming yang tidak digunakan di penelitian ini.

Penelitian yang ketiga adalah penelitian yang dilakukan oleh Agustina dkk., 2022 dengan judul “Klasifikasi Kanker Kulit menggunakan Metode *Convolutional Neural Network* dengan Arsitektur VGG-16”. Penelitian ini melakukan klasifikasi menggunakan arsitektur VGG-16. Hasil dari penelitian terdahulu yang ketiga ini yaitu sistem berhasil melakukan klasifikasi 4 kelas kanker kulit dengan akurasi 99,70%, *loss* 0,0055, *presisi* 0.9975, *recall* 0,9975, dan *f1-score* 0,9950.

Pada penelitian terdahulu terdapat *optimizer* yang memiliki skenario testing untuk menemukan performa parameter yang terbaik yang digunakan untuk mendeteksi objek. Persamaan penelitian ini dengan penelitian terdahulu adalah penggunaan arsitektur VGG-16. Namun, terdapat juga perbedaan antar penelitian terdahulu dan penelitian ini pada jumlah klasifikasi.

Penelitian terdahulu yang keempat ialah penelitian yang dilakukan oleh Islam dkk., 2024 dengan judul "*Precision Brain Tumor Classification with Optimized EfficientNet Architecture*". Penelitian ini menggunakan dataset citra MRI tumor otak dengan klasifikasi terhadap 4 kelas yaitu *glioma*, *meningioma*, *pituitary tumor*, dan normal (*non-tumor*). Dataset yang digunakan terdiri dari 3.064 citra dengan pembagian data yang seragam untuk setiap kelas penelitian.


Penelitian ini menggunakan arsitektur EfficientNet dengan berbagai varian (B0 hingga B7) untuk melakukan perbandingan performa, dengan fokus utama pada EfficientNet-B3 yang terbukti memberikan hasil optimal yaitu akurasi 99,69%. Persamaan penelitian ini dengan penelitian yang akan dilakukan adalah penggunaan arsitektur EfficientNet-B3 untuk klasifikasi citra medis dan penerapan *transfer learning* untuk meningkatkan akurasi. Sedangkan perbedaannya terdapat pada jenis citra medis yang digunakan (tumor otak vs klasifikasi kesehatan lainnya) dan jumlah kelas klasifikasi yang berbeda.

UNIVERSITAS
MA CHUNG

Bab III

Analisis dan Perancangan Sistem

Penelitian ini didasarkan pada metode klasifikasi citra medis dengan pendekatan *deep learning*. Objek penelitian berupa citra pembuluh darah kapiler yang diperoleh melalui teknik kapilaroskopi (*Nailfold Capillaroscopy*) menggunakan perangkat *CapillaryScope 500 (MEDL4N5)*. Uji coba dilakukan dengan tiga arsitektur CNN, yaitu ResNet-50, YOLOv11, dan VGG16. Proses penelitian dibagi menjadi beberapa tahapan sebagaimana ditunjukkan pada Gambar 3.1.



Gambar 3. 1 Tahapan Penelitian

3.1 Analisis Kebutuhan

Pada tahap ini dilakukan identifikasi terhadap kebutuhan yang diperlukan dalam pelaksanaan penelitian agar dapat berjalan secara sistematis dan optimal. Analisis kebutuhan mencakup perangkat lunak (*software*), perangkat keras (*hardware*), serta literatur pendukung.


Software yang digunakan antara lain *Visual Studio Code* sebagai *Integrated Development Environment (IDE)*, serta *library* Python seperti *TensorFlow/Keras* untuk pembangunan dan pelatihan model deep learning, *NumPy* untuk pengolahan data numerik, *Matplotlib* untuk visualisasi data, serta *library* tambahan lain yang mendukung proses klasifikasi citra.

Selain itu, dilakukan juga studi literatur yang bertujuan untuk menelusuri dan mengevaluasi penelitian-penelitian terdahulu yang relevan. Studi literatur ini menjadi dasar dalam menentukan metode yang tepat dan arsitektur model CNN yang akan digunakan. Dengan memahami teori dan pendekatan yang telah ada, peneliti dapat merancang sistem yang sesuai dengan tujuan dan permasalahan penelitian.

3.2 Pengumpulan Dataset


Dataset dalam penelitian ini diperoleh melalui kerja sama dengan tenaga ahli dari institusi medis. Data dikumpulkan menggunakan metode kapilaroskopi (*Nailfold Capillaroscopy*), yakni teknik non-invasif untuk mengamati kondisi mikrosirkulasi kapiler pada lipatan kuku. Proses pengambilan dilakukan menggunakan *CapillaryScope 500 (MEDL4N5)*, yang mampu menghasilkan citra mikroskopik dengan resolusi 1,3 megapiksel (1280x1024 piksel) dalam format JPG. Total data yang diperoleh mencakup 415 citra pembuluh darah kapiler normal dan 2.075 citra tidak normal.

3.3 *Preprocessing*



Gambar 3. 2 Urutan *Preprocessing*

Setelah dataset yang merupakan data mentah terkumpul, akan dilakukan proses *preprocessing*. Tahapan pertama dalam proses *preprocessing* yaitu memotong bagian citra agar fokus hanya pada area yang relevan, dalam hal ini adalah pembuluh darah yang terlihat dari hasil kapilaroskopi. Citra hasil perekaman sering kali mengandung latar belakang atau bagian-bagian lain yang tidak diperlukan dalam proses pelatihan model. Dengan mengambil objek utama, bagian-bagian yang tidak berkontribusi terhadap klasifikasi dapat dihilangkan sehingga *noise* dapat dikurangi. Hasil pengambilan objek dapat diatur untuk memiliki ukuran yang sama yaitu 128x128. Langkah ini membantu model untuk lebih fokus mengenali fitur penting dari pembuluh darah, serta mengurangi beban komputasi karena ukuran data menjadi lebih kecil.




Gambar 3. 3 Contoh pengambilan objek

Selanjutnya, citra diklasifikasikan oleh tenaga ahli ke dalam tiga kelas utama: normal, diabetes melitus non-neuropati, dan diabetes melitus neuropati. Kategori ini kemudian diperluas menjadi enam kelas, yaitu: (1) pembuluh darah normal pada pasien normal, (2) pembuluh darah abnormal pada pasien normal, (3) pembuluh darah normal pada pasien DM neuropati, (4) pembuluh darah abnormal pada pasien DM neuropati, (5) pembuluh darah normal pada pasien DM non-neuropati, dan (6) pembuluh darah abnormal pada pasien DM non-neuropati. Klasifikasi dilakukan berdasarkan morfologi pembuluh darah, mencakup diameter, panjang, bentuk, distribusi, kepadatan, keberadaan area avaskular, dan indikasi pendarahan. Hasil klasifikasi ini menjadi dasar dataset yang digunakan dalam pelatihan dan pengujian model.

3.4 Augmentasi Data

Untuk meningkatkan variasi data latih dan memperkuat kemampuan generalisasi model, perlu dilakukan proses augmentasi data. Melihat jumlah asli dataset yang terbatas, augmentasi dapat membantu mengurangi risiko *overfitting* dan membuat model lebih teliti terhadap variasi pada data uji. Dalam penelitian ini, augmentasi dilakukan menggunakan beberapa pendekatan sederhana namun efektif, seperti *flipping* dan rotasi citra.



Gambar 3. 4 Contoh hasil *Horizontal* dan *Vertical Flip*

Teknik *flipping* menciptakan variasi baru dari citra dengan cara membalik gambar secara horizontal dan/atau vertikal. *Flipping* tidak mengubah makna atau label dari citra, tetapi memberikan model lebih banyak contoh visual dari arah yang berbeda. Dengan demikian, model akan belajar mengenali fitur penting dari objek (pembuluh darah) meskipun dilihat dari sudut atau orientasi berbeda. Hal ini efektif untuk meningkatkan kemampuan generalisasi model terhadap data uji yang tidak terlihat sebelumnya.



Gambar 3. 5 Contoh hasil *Rotating*

Selanjutnya, dilakukan augmentasi dengan rotasi citra. Pada tahap ini, citra diputar secara acak hingga ± 90 derajat, baik searah jarum jam maupun berlawanan. Tujuan dari rotasi adalah menambahkan variasi posisi objek dalam dataset agar model tidak terlalu bergantung pada orientasi tertentu dalam pengenalan pola. Sama seperti *flipping*, metode ini mempertahankan label citra yang asli namun memperkaya sudut pandang data.

3.5 Perancangan Model CNN

Penelitian ini menggunakan pendekatan *comparative modeling*, yaitu membandingkan kinerja dari tiga arsitektur CNN yang berbeda dalam mengklasifikasikan citra pembuluh darah kapiler. Ketiga arsitektur yang digunakan adalah ResNet-50, VGG16, dan YOLOv11. ResNet-50 dikenal dengan kemampuan *deep residual learning* yang efektif dalam mengatasi masalah pada jaringan yang sangat dalam. VGG16 merupakan arsitektur konvolusional klasik yang sederhana namun efektif untuk klasifikasi citra. Sementara itu, YOLOv11 merupakan pendekatan terbaru dalam deteksi objek yang dapat diterapkan untuk mendeteksi dan mengklasifikasikan objek pembuluh darah dalam satu proses inferensi.

3.5.1 Arsitektur ResNet-50

3.5.1.1 Parameter dan Strategi Training

Tabel 3. 1 Parameter Arsitektur ResNet-50

Komponen	Nilai / Strategi
<i>Learning Rate</i>	1×10^{-4} (<i>Exponential Decay</i> , rate 0.96 tiap 5 <i>epoch</i>)
<i>Batch Size</i>	32
<i>Optimizer</i>	Adam ($\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 1 \times 10^{-8}$)
<i>Weight Decay</i>	1×10^{-5}
<i>Loss Function</i>	<i>Categorical Cross-Entropy + Class Weights</i>
<i>Regularization</i>	<i>L2 Regularization</i> (1×10^{-4}) pada <i>fully connected layer</i>
<i>Initialization</i>	<i>Pre-trained ImageNet (convolutional base)</i> , <i>He init</i> (<i>fully connected</i>)
<i>Epoch</i>	100
<i>Early Stopping</i>	<i>Monitoring: val_loss</i> , <i>Patience: 15</i> , <i>Min delta: 0.001</i> , <i>Restore best: True</i>
<i>LR Scheduler</i>	<i>ReduceLROnPlateau</i> (<i>Factor: 0.5</i> , <i>Patience: 8</i> , <i>Min LR:</i> 1×10^{-7})
<i>Checkpointing</i>	<i>ModelCheckpoint</i> (<i>validation accuracy tertinggi</i>)

Tabel 3.1 Parameter Arsitektur ResNet-50 (Lanjutan)

Komponen	Nilai / Strategi
<i>Transfer Learning</i>	<i>Fine-tuning</i> seluruh model setelah 10 <i>epoch</i> pertama (<i>base frozen</i> sebelumnya)
Augmentasi	<i>Real-time augmentation</i> (<i>flipping, rotating, dsb.</i>)

3.5.1.2 Framework Implementasi

Framework deep learning menggunakan TensorFlow 2.6.0 dengan Keras API. Training environment pada arsitektur ini yaitu Visual Studio Code dengan Workstation lokal dengan GPU NVIDIA RTX 3060.

3.5.2 Arsitektur VGG16

3.5.2.1 Parameter dan Strategi Training

Tabel 3. 2 Parameter Arsitektur VGG16

Komponen	Nilai / Strategi
<i>Learning Rate</i>	5×10^{-5} (<i>Step Decay</i> , 50% tiap 10 <i>epoch</i>)
<i>Batch Size</i>	16
<i>Optimizer</i>	SGD (<i>Momentum</i> : 0.9, <i>Nesterov</i> : <i>True</i>)
<i>Weight Decay</i>	5×10^{-4}
<i>Loss Function</i>	<i>Categorical Cross-Entropy</i> + <i>Class Weights</i>
<i>Regularization</i>	<i>Dropout</i> (rate: 0.5 setelah FC layer)
<i>Initialization</i>	<i>Pre-trained ImageNet</i> (seluruh layer)
<i>Epoch</i>	80
<i>Early Stopping</i>	<i>Monitoring</i> : <i>val_accuracy</i> , <i>Patience</i> : 12, <i>Min delta</i> : 0.005, <i>Restore best</i> : <i>True</i>
<i>LR Scheduler</i>	<i>StepDecay</i> (<i>step size</i> : 10, <i>gamma</i> : 0.5)
<i>Checkpointing</i>	<i>ModelCheckpoint</i> (F1-score tertinggi)
<i>Transfer Learning</i>	<i>Freezing</i> 10 layer awal, <i>fine-tuning</i> sisanya
Augmentasi	<i>Flipping</i> dan <i>rotating</i>

3.5.2.2 Framework Implementasi

Framework deep learning menggunakan PyTorch 1.10.0 dengan *training environment* menggunakan *Workstation* lokal dengan GPU NVIDIA RTX 3060.

3.5.3 Arsitektur YOLOv11

3.5.3.1 Parameter dan Strategi Training

Tabel 3. 3 Parameter Arsitektur YOLOv11

Komponen	Nilai / Strategi
<i>Learning Rate</i>	<i>Cosine annealing</i> ($1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$)
<i>Batch Size</i>	8
<i>Optimizer</i>	AdamW ($\beta_1 = 0.9$, $\beta_2 = 0.999$, $\varepsilon = 1 \times 10^{-8}$, WD: 0.01, <i>decoupled</i>)
<i>Loss Function</i>	<i>Categorical Cross-Entropy</i>
<i>Regularization</i>	<i>Dropout</i> (0.2) + <i>Droppath</i> (0.1) pada <i>deep layers</i>
<i>Initialization</i>	<i>Pretrained ImageNet</i>
<i>Epoch</i>	150
<i>Early Stopping</i>	<i>Monitoring: val_accuracy</i> , <i>Patience</i> : 20, <i>Min delta</i> : 0.005
<i>LR Scheduler</i>	<i>OneCycleLR</i> (<i>peak LR</i> : di 1/3 total <i>epoch</i>)
<i>Checkpointing</i>	<i>ModelCheckpoint</i> (<i>validation accuracy tertinggi</i>)
<i>Transfer Learning</i>	<i>Progressive unfreezing</i> (dari <i>head</i> $\rightarrow$ <i>backbone</i>)
<i>Augmentasi</i>	<i>Geometric augmentation</i> (<i>flipping</i> , <i>rotating</i>)

3.5.3.2 Framework Implementasi

Framework deep learning menggunakan PyTorch dengan Ultralytics YOLOv11 *framework*. *Training environment* menggunakan *workstation* lokal dengan GPU NVIDIA RTX 3060.

3.5.4 Arsitektur EfficientNet

3.5.4.1 Parameter dan Strategi Training

Tabel 3. 4 Parameter Arsitektur EfficientNet

Komponen	Nilai / Strategi
<i>Learning Rate</i>	<i>Cosine annealing</i> ($1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$)
<i>Batch Size</i>	8
<i>Optimizer</i>	AdamW ($\beta_1 = 0.9$, $\beta_2 = 0.999$, $\varepsilon = 1 \times 10^{-8}$, WD: 0.01, <i>decoupled</i>)
<i>Loss Function</i>	<i>Categorical Cross-Entropy</i>
<i>Regularization</i>	<i>Dropout</i> (0.2) + <i>Droppath</i> (0.1) pada <i>deep layers</i>
<i>Initialization</i>	<i>Pretrained ImageNet</i>
<i>Epoch</i>	150
<i>Early Stopping</i>	<i>Monitoring: val_accuracy</i> , <i>Patience</i> : 20, Min delta: 0.005
<i>LR Scheduler</i>	<i>OneCycleLR</i> (<i>peak LR</i> : di 1/3 total <i>epoch</i>)
<i>Checkpointing</i>	<i>ModelCheckpoint</i> (<i>validation accuracy tertinggi</i>)
<i>Transfer Learning</i>	<i>Progressive unfreezing</i> (dari <i>head</i> $\rightarrow$ <i>backbone</i>)
<i>Augmentasi</i>	<i>Geometric augmentation</i> (<i>flipping, rotating</i>)

3.5.4.2 Framework Implementasi

Framework deep learning menggunakan *PyTorch* dengan *Ultralytics YOLOv11 framework*. *Training environment* menggunakan *workstation* lokal dengan GPU NVIDIA RTX 3060.

3.5.5 Skema Pelatihan

Seluruh model dilatih menggunakan dataset yang telah melalui proses preprocessing dan augmentasi. Dataset dibagi menjadi tiga bagian, yaitu data latih sebesar 70%, data validasi sebesar 20%, dan data uji sebesar 10%. Evaluasi model dilakukan berdasarkan kemampuan dalam mengklasifikasikan gambar ke dalam dua kelas, tiga kelas, dan enam kelas kapilaroskopi. Pemilihan empat arsitektur

CNN ini diharapkan dapat memberikan gambaran yang komprehensif mengenai kekuatan dan keterbatasan masing-masing pendekatan dalam klasifikasi citra medis.

3.7 Evaluasi Model

Setelah seluruh model selesai dilatih, dilakukan proses evaluasi untuk mengukur performa masing-masing model dalam mengklasifikasikan citra pembuluh darah kapiler. Evaluasi ini menggunakan sejumlah metrik yang umum digunakan dalam bidang klasifikasi, antara lain *accuracy*, *precision*, *recall*, *F1-score*, *confidence* dan *confusion matrix*. *Accuracy* menunjukkan sejauh mana model mampu mengklasifikasikan citra dengan benar secara keseluruhan. *Precision* dan *recall* memberikan gambaran mengenai ketepatan dan kelengkapan klasifikasi untuk setiap kelas, sedangkan *F1-score* digunakan untuk menyeimbangkan *precision* dan *recall*. Sementara itu, *confusion matrix* digunakan untuk menganalisis distribusi prediksi model terhadap label sebenarnya, sehingga memudahkan dalam mengidentifikasi pola kesalahan klasifikasi.

Dalam penelitian ini, terdapat perbedaan jumlah data yang signifikan antar kelas (*class imbalance*), sehingga diperlukan metrik evaluasi tambahan yang mampu menangani ketidakseimbangan tersebut. Metrik tambahan yang digunakan adalah *Balanced Accuracy*, yang merupakan rata-rata aritmatika dari *sensitivity* dan *specificity*, serta *Matthews Correlation Coefficient (MCC)* yang memberikan nilai tinggi hanya jika model menunjukkan kinerja yang baik pada semua kelas secara konsisten. Evaluasi ini juga menjadi dasar dalam menentukan model yang paling tepat untuk diterapkan dalam sistem klasifikasi pembuluh darah kapiler, khususnya dalam konteks deteksi dini komplikasi pada pasien diabetes melitus. Hasil dari proses evaluasi ini akan menjadi dasar dalam penarikan kesimpulan dan penyusunan saran pada bab selanjutnya.

3.8 Eksperimen

Tabel 3. 5 Eksperimen berdasarkan kelas

Eksperimen ke-	Arsitektur CNN	Jenis Kelas
1	VGG16	<i>Binary class</i>
2	Resnet-50	
3	YOLOv11	
4	Efficient-Net	
5	VGG16	<i>6 Class</i>
6	Resnet-50	
7	YOLOv11	
8	Efficient-Net	
9	VGG16	<i>3 Class</i>
10	Resnet-50	
11	YOLOv11	
12	Efficient-Net	
13	VGG16	<i>Hierarchical 3 Class</i>
14	Resnet-50	
15	YOLOv11	
16	Efficient-Net	

Eksperimen dalam penelitian ini dirancang secara bertahap untuk mengevaluasi performa empat arsitektur CNN, yaitu EfficientNet, ResNet-50, YOLOv11, dan VGG16, dalam mengklasifikasikan citra kapiler. Tahap awal eksperimen difokuskan pada klasifikasi biner (*binary class*) untuk menguji kemampuan dasar model dalam membedakan citra pembuluh darah normal dan abnormal. Jika model menunjukkan performa yang baik pada skenario biner ini, eksperimen dilanjutkan ke klasifikasi multi kelas (*multi class*), yaitu enam kelas kondisi pembuluh darah. Terakhir, jika hasil eksperimen dirasa kurang memuaskan akan dilakukan eksperimen untuk klasifikasi 3 kelas yaitu Sehat, DM Neuroprati, dan DM Non Neuropati.

Selain perbandingan jenis kelas, dilakukan pula variasi *hyperparameter*

penting seperti *learning rate*, *batch size*, *image size*, dan jumlah *epochs*. Evaluasi performa dilakukan menggunakan metrik standar seperti *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*. Untuk mengatasi *imbalanced data*, digunakan metrik *balanced accuracy* dan *Matthews Correlation Coefficient (MCC)*. Rangkaian eksperimen ini diharapkan mampu mengidentifikasi kombinasi parameter dan arsitektur model yang paling optimal dalam klasifikasi citra kapiler, khususnya dalam konteks deteksi komplikasi dini pada pasien diabetes melitus.



UNIVERSITAS
MA CHUNG





Bab IV

Hasil dan Pembahasan

4.1 Data Penelitian

Data yang digunakan pada penelitian merupakan data sekunder berupa citra kaliparoskopi pembuluh darah. Data dikumpulkan melalui kerjasama tenaga ahli medis. Data diperoleh menggunakan teknik *Nailfold Capillaroscopy* dengan perangkat *CapillaroScope 500 (MEDL4N5)* yang menghasilkan citra mikroskopik dengan resolusi 1,3 megapiksel (1280x1024 piksel) dalam format jpg. Dataset mencakup 3 kategori utama dari pasien sehat, pasien diabetes melitus neuropati, dan pasien diabetes non neuropati. Dataset kemudian dibagi menjadi 3 fase pengujian. Pengujian pertama akan dilakukan dengan membagi datasetA ke dalam 2 kelas (*binary class*) dari ketiga kategori utama, yakni kelas pembuluh darah normal dan pembuluh darah abnormal.

Tabel 4. 1 Contoh Citra Kapilaroskopi

Subtipe	Sehat	DM Neuropati	DM Non Neuropati
Normal			
Abnormal			

Berdasarkan Tabel 4.1, seluruh citra kapilaroskopi yang digunakan dalam penelitian ini telah melalui proses klasifikasi awal yang dilakukan oleh tenaga ahli medis. Proses klasifikasi ini didasarkan pada sejumlah kriteria morfologis pembuluh darah, termasuk diameter, panjang, bentuk, distribusi, kepadatan, keberadaan area avaskular, serta berbagai indikator morfologi lainnya yang relevan dalam konteks diagnosis klinis. Klasifikasi yang dilakukan oleh para ahli ini dianggap sebagai ground truth atau label acuan yang memiliki tingkat validitas tinggi, dan selanjutnya digunakan sebagai dasar dalam proses pelatihan (training) serta evaluasi performa model CNN. Dengan demikian, model yang dikembangkan diharapkan mampu mereplikasi proses klasifikasi manual secara otomatis dan konsisten.

Fase pengujian kedua dilakukan dengan membagi dataset ke dalam 3 kelas, yakni pembuluh darah orang sehat, pembuluh darah penderita DM Neuropati, dan pembuluh darah penderita DM Non Neuropati. Sementara pada fase pengujian ketiga, dataset akan dibagi ke dalam 6 class yang terdiri dari pembuluh darah normal orang sehat, pembuluh darah abnormal orang sehat, pembuluh darah normal penderita DM Neuropati, pembuluh darah abnormal penderita DM Neuropati, pembuluh darah normal penderita DM Non Neuropati dan pembuluh darah abnormal penderita DM Non Neuropati

Tabel 4. 2 Sebaran dataset untuk fase pengujian 1

No	Data	Total
1	Pembuluh darah Normal	148 citra
2	Pembuluh darah Abnormal	945 citra

Data pembuluh darah normal dan pembuluh darah abnormal berisi data pasien sehat, DM Neuropati, dan DM Non Neuropati yang di klasifikasikan ke normal dan abnormal berdasarkan karakteristik numerik dan morfologis seperti diameter kapiler (lebar), panjang kapiler, bentuk, distribusi, kepadatan rata rata kapiler, keberadaan area avaskular, dan pendarahan. Proses klasifikasi dataset pada fase pengujian 1 dilakukan oleh pakar sehingga didapatkan sebaran data

seperti tertera pada tabel 4.2.

Tabel 4. 3 Sebaran dataset untuk fase pengujian 2

No	Data	Total
1	Pembuluh darah orang sehat	148
2	Pembuluh darah penderita DM Neuropati	812
3	Pembuluh darah penderita DM Non Neuropati	621

Klasifikasi 3 kelas membagi data berdasarkan kondisi medis pasien. Kelas Sehat terdiri dari data pembuluh darah normal pada pasien sehat, kelas DM Neuropati mencakup data dari pasien diabetes dengan komplikasi neuropati, dan kelas DM Non Neuropati berisi data dari pasien diabetes tanpa komplikasi neuropati. Proses klasifikasi dataset pada fase pengujian 2 juga dilakukan oleh pakar sehingga didapatkan sebaran data seperti tertera pada tabel 4.3.

Tabel 4. 4 Sebaran dataset untuk fase pengujian 3

No	Data	Normal	Abnormal
1	Pembuluh darah orang Sehat	148	485
2	Pembuluh darah pasien DM Neuropati	113	373
3	Pembuluh darah pasien DM Non Neuropati	124	572

Klasifikasi 6 kelas merupakan kombinasi dari kondisi medis pasien dan status normalitas pembuluh darah, menghasilkan enam kategori yang lebih spesifik untuk analisis mendalam. Dari data sehat, DM Neuropati, dan DM Non Neuropati akan dipisahkan kondisi normal dan abnormal. Proses klasifikasi dataset pada fase pengujian 3 juga dilakukan oleh pakar sehingga didapatkan sebaran data seperti tertera pada tabel 4.4.

Pada penelitian ini, terdapat penyimpangan jumlah pembagian data di tiap kategori kelas. Ketidakseimbangan ini dapat mempengaruhi performa model machine learning, dimana model cenderung bias terhadap kelas mayoritas. Oleh

karena itu, diperlukan strategi khusus untuk mengatasi masalah ini. Untuk mengatasi ketidakseimbangan data, dilakukan augmentasi balancing untuk menyamakan jumlah dataset dari setiap kategori. Jumlah data hasil augmentasi akan ter-generate menyesuaikan jumlah data terbanyak dalam 1 kelas tersebut.

Tabel 4. 5 Jumlah dataset

Jumlah Kelas	Kelas	Sebelum Augmentasi	Sesudah Augmentasi
2 Kelas	Pembuluh darah Normal	148 citra	945 citra
	Pembuluh darah Abnormal	945 citra	945 citra
3 Kelas	Pembuluh darah orang Sehat	148 citra	812 citra
	Pembuluh darah pasien DM Neuropati	812 citra	812 citra
	Pembuluh darah pasien DM Non Neuropati	621 citra	812 citra
6 Kelas	Pembuluh darah orang Sehat Abnormal	485 citra	572 citra
	Pembuluh darah pasien DM Neuropati Abnormal	373 citra	572 citra
	Pembuluh darah pasien DM Non Neuropati Abnormal	572 citra	572 citra
	Pembuluh darah orang Sehat Normal	148 citra	572 citra
	Pembuluh darah pasien DM Neuropati Normal	113 citra	572 citra
	Pembuluh darah pasien DM Non Neuropati Normal	124 citra	572 citra

Distribusi awal data mentah terbagi menjadi 2 kelas, 3 kelas, dan 6 kelas. Pada klasifikasi 2 kelas, terdapat data normal dengan jumlah 148 citra, data abnormal 945 citra. Pada data klasifikasi 3 kelas, terdapat data sehat sejumlah 148 citra, data DM Neuropati sejumlah 812 citra, dan DM Non Neuropati sebanyak

621 citra. Pada klasifikasi 6 kelas, terdapat data sehat normal 148 citra, sehat abnormal sejumlah 485 citra, DM Neuropati normal 113 citra, DM Neuropati abnormal 373 citra, DM Non Neuropati normal 124 citra, dan DM Non Neuropati abnormal sebanyak 572 citra.

Karena adanya ketidakseimbangan data yang signifikan dan jumlah data yang terbatas, dilakukan augmentasi data citra. Jenis augmentasi yang dilakukan bervariasi setiap model. Pada parameter yang sudah disebutkan di Bab III sebelumnya, augmentasi yang dilakukan hanya *flipping* dan *rotating*. Saat dilakukan *tuning parameter*, dicobakan augmentasi yang bervariasi termasuk *RandomBrightnessContrast*, *Shift*, dan *HueSaturationValue*. Dari berbagai augmentasi yang dilakukan akan menghasilkan jumlah data terbanyak di setiap kategori. Untuk klasifikasi 2 kelas, akan terbentuk 945 data tiap kelas, untuk 3 kelas terbentuk menjadi 812 citra tiap kelas, dan untuk 6 kelas akan terbentuk 572 citra tiap kelas.

Tabel 4. 6 Distribusi Data 2 Kelas

Data	Train	Validasi	Test
Normal	648	185	95
Abnormal	675	193	94
Total	1.323	378	189

Klasifikasi 2 kelas mengelompokkan seluruh citra pembuluh darah kapiler ke dalam dua kategori normal dan abnormal. Pendekatan ini merupakan strategi klasifikasi paling sederhana namun penting dalam konteks *screening* medis awal. Pembagian data *train*, *validation*, dan *test* menggunakan rasio 70:20:10. Pada data training menggunakan 1.323 sample citra, data validasi menggunakan 378 sample citra, dan pada data *test* menggunakan 189 sample data. Distribusi data ini digunakan sebagai input citra dalam proses pengembangan model klasifikasi.

Tabel 4. 7 Distribusi Data 3 Kelas

Data	Train	Validasi	Test
Sehat	568	162	81
DM Neu	569	163	82
DM Non	568	162	81
Total	1.705	487	244

Klasifikasi 3 kelas memberikan granularitas yang lebih tinggi dengan membedakan kondisi berdasarkan status medis pasien Sehat, DM Neuropati, dan DM Non Neuropati. Pendekatan ini lebih spesifik secara klinis dan memberikan informasi diagnostik yang lebih detail. Pembagian data *train*, *validation*, dan *test* menggunakan rasio yang sama yaitu 70:20:10. Pada data training menggunakan 1.705 sample citra, data validasi menggunakan 487 sample citra, dan pada data test menggunakan 244 sample data.

Tabel 4. 8 Distribusi Data 6 kelas

Data	Train	Validasi	Test
Sehat Normal	400	114	57
Sehat Abnormal	400	115	56
DM Neu Normal	400	114	57
DM Neu Abnormal	401	115	58
DM Non Neuropati Normal	400	114	57
DM Non Neuropati Abnormal	401	115	58
Total	2.402	687	343

Klasifikasi 6 kelas merupakan pendekatan paling granular yang menggabungkan kondisi pasien dengan morfologi pembuluh darah. Setiap kondisi Sehat, DM Neuropati, dan DM Non Neuropati dipecah menjadi dua subkategori berdasarkan kondisi pembuluh darah Normal dan Abnormal. Pada data *training*

menggunakan 2.402 sample citra, data validasi menggunakan 687 sample citra, dan pada data *test* menggunakan 343 sample data.

4.2 Hasil Pengujian

Uji coba yang dilakukan dalam penelitian ini mencakup evaluasi komprehensif terhadap empat arsitektur CNN yaitu EfficientNet, ResNet-50, VGG16, dan YOLOv11 pada tiga fase pengujian. Setiap arsitektur diuji dengan dua set parameter yaitu parameter sesuai spesifikasi Bab III dan parameter hasil tuning untuk mendapatkan performa optimal.

Mengingat keterbatasan ukuran dataset dan ketidakseimbangan kelas yang signifikan dalam penelitian ini, seluruh model menggunakan pendekatan *transfer learning* dengan *pre-trained weights* dari *ImageNet* dataset. *ImageNet* merupakan dataset besar yang berisi lebih dari 1,4 juta gambar dengan 1.000 kategori objek, sehingga model yang telah dilatih pada dataset ini memiliki representasi fitur yang kaya untuk pengenalan pola visual dasar seperti *edge detection*, *texture analysis*, dan *shape recognition* yang relevan untuk analisis citra medis kapilaroskopi.

Evaluasi dilakukan menggunakan dataset yang telah melalui proses augmentasi dan *balancing* untuk mengatasi ketidakseimbangan kelas. Setiap model dilatih dengan *callback early stopping* untuk mencegah *overfitting* dan memastikan konvergensi yang optimal. Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.

4.2.1 Hasil Model Klasifikasi 2 Kelas

Tabel 4. 9 Hasil Klasifikasi Model 2 Kelas (A)

Parameter	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	128×128	224×224	160×160	224×224
Batch Size	16	32	16	8
Learning Rate	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$	1×10^{-4}	5×10^{-5}	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$
Optimizer	AdamW	Adam	SGD	AdamW

Tabel 4.9 Hasil Klasifikasi Model 2 Kelas (A) (Lanjutan)

Parameter	EfficientNet	ResNet-50	VGG16	YOLOv11
Epoch	150	100	80	150
Accuracy	96,80%	49,70%	91,50%	93,40%
Precision	96,90%	49,70%	86,70%	94,20%
Recall	96,80%	100,00%	98,90%	93,40%
F1-score	96,80%	66,40%	92,00%	93,40%
Balanced Accuracy	96,80%	50,00%	91,50%	93,20%
MCC	93,70%	0,00%	84,00%	87,60%
Confidence	96,80%	50,00%	87,30%	94,20%

Tahap pertama eksperimen menggunakan parameter yang telah ditetapkan dalam metodologi penelitian. EfficientNet menunjukkan performa yang baik dengan akurasi 96,80% menggunakan konfigurasi *image size* 128×128, *batch size* 16, *learning rate* adaptif yang menurun dari 1×10^{-3} hingga 1×10^{-6} , *optimizer* AdamW, dan durasi pelatihan 150 *epoch*. Keunggulan EfficientNet dapat dijelaskan melalui beberapa aspek teknis seperti arsitektur *compound scaling* yang mengoptimalkan keseimbangan antara kedalaman, lebar, dan resolusi jaringan memungkinkan ekstraksi fitur yang efisien.

Model ini juga menunjukkan konsistensi yang tinggi dengan nilai *precision* 96,90%, *recall* 96,80%, dan *F1-score* 96,80%, mengindikasikan kemampuan generalisasi yang baik pada kedua kelas (normal dan abnormal). Nilai *Balanced Accuracy* 96,80% menunjukkan bahwa model tidak bias terhadap kelas mayoritas, sementara nilai MCC 93,70% mengkonfirmasi kualitas prediksi yang sangat baik bahkan pada dataset yang mungkin tidak seimbang sempurna.

YOLOv11 mencapai posisi kedua dengan akurasi 93,40%, menggunakan *image size* 224×224, *batch size* 8, *learning rate* yang menurun dari 1×10^{-3} hingga 1×10^{-4} , *optimizer* AdamW, dan 150 *epoch* pelatihan. Performa yang konsisten

terlihat dari nilai *precision* 94,20%, *recall* 93,40%, dan *F1-score* 93,40%. Nilai *confidence* yang tinggi (94,20%) menunjukkan bahwa model memiliki tingkat kepercayaan yang baik terhadap prediksi yang dihasilkan, aspek kritis dalam aplikasi medis.


VGG16 menunjukkan akurasi 91,50%. Model ini menggunakan *image size* 160×160 , *batch size* 16, *learning rate* 5×10^{-5} , *optimizer* *SGD*, dan 80 *epoch* pelatihan. Model menunjukkan *recall* yang tinggi (98,90%), mengindikasikan kemampuan yang sangat baik dalam mendeteksi kasus abnormal (sensitivitas tinggi), aspek yang sangat penting dalam screening medis. Namun, *precision* yang relatif lebih rendah (86,70%) menunjukkan adanya *false positive* yang perlu diperhatikan dalam implementasi klinis.

ResNet-50 menghasilkan akurasi yang rendah yaitu 49,70% dengan konfigurasi *image size* 224×224 , *batch size* 32, *learning rate* 1×10^{-4} , *optimizer* *Adam*, dan 100 *epoch* pelatihan. Performa yang tidak optimal ini kemungkinan disebabkan oleh beberapa faktor seperti konfigurasi *hyperparameter* yang tidak sesuai untuk dataset spesifik ini, kemungkinan terjadinya *overfitting* akibat kompleksitas model yang tinggi pada dataset yang relatif kecil, atau ketidaksesuaian strategi transfer learning yang diterapkan.

Nilai *recall* yang sangat tinggi (100,00%) namun *precision* yang rendah (49,70%) menunjukkan bahwa model cenderung mengklasifikasikan semua sampel sebagai satu kelas tertentu, mengindikasikan masalah *overfitting*. Nilai MCC yang sangat rendah (0,00%) mengkonfirmasi bahwa prediksi model tidak lebih baik dari penebakan, menunjukkan perlunya revisi fundamental dalam pendekatan training.

Penggunaan *early stopping* pada model tidak menghasilkan perubahan performa yang signifikan. Hal ini diperkuat setelah dilakukan pemodelan tanpa *early stopping*, dimana hasilnya hanya menunjukkan perubahan yang sangat kecil dan tidak signifikan terhadap indikator performa model. Meski demikian, penggunaan *early stopping* tetap dipertahankan dengan tujuan untuk menghindari *overfitting* pada model dan menjaga konsistensi pelatihan.

Selain itu, pada tabel hasil eksperimen ini dan tabel-tabel hasil eksperimen berikutnya, terlihat bahwa terdapat arsitektur yang menggunakan *optimizer* berbeda dibandingkan tiga arsitektur lainnya. Pemilihan *optimizer* pada masing-masing arsitektur didasarkan pada hasil terbaik yang diperoleh setelah mencoba berbagai *optimizer* pada setiap model. Hal ini disesuaikan juga dengan karakteristik masing-masing arsitektur. VGG16 yang relatif sederhana lebih stabil dengan pembaruan bertahap seperti pada SGD, ResNet-50 yang lebih dalam memanfaatkan kemampuan Adam untuk menyesuaikan learning rate per-parameter, sedangkan EfficientNet dan YOLOv11 yang kompleks dan modern lebih optimal dengan AdamW, yang juga menambahkan regularisasi bobot untuk membantu mencegah *overfitting*.



Gambar 4. 1 *Confusion Matrix* Klasifikasi EfficientNet 2 Kelas (A)


Analisis confusion matrix EfficientNet menunjukkan distribusi prediksi yang sangat baik dengan 90 *True Positive*, 93 *True Negative*, 5 *False Negative*, dan hanya 1 *False Positive*. Sensitivitas tinggi (94,7%) dan spesifisitas yang sangat baik (98,9%) mengindikasikan bahwa model mampu mendeteksi hampir semua kasus patologis sambil meminimalkan *false alarm*. Karakteristik ini sangat

penting dalam konteks medis dimana missed diagnosis dapat berdampak serius pada kondisi diagnosa.




Gambar 4. 2 Grafik *Training Accuracy EfficientNet* 2 kelas (A)

Dinamika pelatihan EfficientNet menunjukkan *validation loss* yang mengalami peningkatan tinggi mencapai sekitar 300 pada *epoch* ke-8, sementara *training loss* tetap stabil dan rendah. Fenomena ini kemungkinan mengindikasikan terjadinya *learning instability* atau *gradient explosion* sementara pada fase tertentu, namun model berhasil mencapai konvergensi yang baik. Setelah peningkatan tersebut, *validation loss* turun drastis dan stabil dengan *training loss* pada nilai yang sangat rendah mendekati 0, menunjukkan kemampuan adaptasi dan stabilisasi yang baik dari arsitektur EfficientNet.



Gambar 4. 3 *Confusion Matrix* Klasifikasi YOLOv11 untuk 2 Kelas (A)

Sebagai perbandingan, *confusion matrix* YOLOv11 pada eksperimen dengan parameter Bab III menunjukkan karakteristik yang sedikit berbeda dengan 95 *True Positive*, 77 *True Negative*, 0 *False Negative*, dan 12 *False Positive*. YOLOv11 berhasil mencapai sensitivitas sempurna (100%) dengan tidak ada kasus abnormal yang terlewat, namun menghasilkan spesifisitas yang lebih rendah dibandingkan EfficientNet. Pola ini mengindikasikan bahwa YOLOv11 cenderung lebih konservatif dalam klasifikasi, lebih memilih mengklasifikasikan kasus yang meragukan sebagai abnormal daripada melewatkan potensi patologi. Dari perspektif klinis, karakteristik ini dapat dianggap menguntungkan karena prioritas utama dalam skrining medis adalah mendeteksi semua kasus abnormal, meskipun dengan konsekuensi *false positive* yang sedikit lebih tinggi.



Gambar 4. 4 Grafik *Training Accuracy* YOLOv11 untuk 2 kelas (A)

Grafik pelatihan YOLOv11 menunjukkan karakteristik pembelajaran yang lebih stabil dan *predictable*. *Training loss* dimulai dari sekitar 0,45 dan menunjukkan penurunan konsisten dengan fluktuasi kecil hingga mencapai 0,28 pada *epoch* ke-20. *Validation loss* memiliki pola serupa, dimulai dari 0,375 dan konvergen pada sekitar 0,24 di akhir pelatihan. Hubungan paralel antara *training* dan *validation loss* yang saling mengikuti menunjukkan tidak adanya overfitting yang serius, sementara kurva yang *smooth* mengindikasikan bahwa *learning rate* dan *optimizer settings* bekerja optimal untuk mencapai konvergensi yang stabil.

Tabel 4. 10 Hasil Klasifikasi Model 2 Kelas (B)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	224×224	224×224	224×224	224×224
Batch Size	16	16	32	8
Learning Rate	1×10^{-4}	1×10^{-4}	5×10^{-5}	1×10^{-3}
Optimizer	AdamW	Adam	SGD	AdamW

Tabel 4.10 Hasil Klasifikasi Model 2 Kelas (B) (Lanjutan)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Epoch	100	100	100	120
Accuracy	95,70%	93,60%	93,60%	94,00%
Precision	95,70%	92,70%	95,50%	94,00%
Recall	95,70%	94,60%	91,40%	94,00%
F1-Score	95,70%	93,60%	93,40%	94,00%
Balanced Accuracy	95,70%	93,60%	93,40%	94,00%
MCC	91,50%	87,30%	87,30%	88,00%
Confidence	93,40%	93,30%	86,00%	97,00%

Tahap kedua eksperimen dilakukan dengan melakukan *fine-tuning* parameter untuk mencapai performa optimal. EfficientNet tetap mempertahankan posisi teratas dengan akurasi 95,70%, menggunakan konfigurasi yang dimodifikasi. Pada model ini, *image size* ditingkatkan menjadi 224×224, *batch size* tetap 16, *learning rate* disesuaikan menjadi 1×10^{-4} , *optimizer AdamW*, dan durasi pelatihan dikurangi menjadi 100 *epoch*.


Metrik evaluasi menunjukkan konsistensi yang sangat baik dengan nilai *precision*, *recall*, dan *F1-score* yang identik (95,70%), mengindikasikan keseimbangan yang optimal antara sensitivitas dan spesifisitas. Nilai MCC yang tinggi (91,50%) mengkonfirmasi kualitas prediksi yang superior, sementara *confidence level* 93,40% menunjukkan tingkat kepercayaan model yang memadai untuk implementasi klinis.

ResNet-50 menunjukkan peningkatan performa yang paling dramatis dengan akurasi 93,60%, menggunakan konfigurasi *image size* 224×224, *batch size* 16, *learning rate* 1×10^{-4} , *optimizer Adam*, dan 100 *epoch*. Peningkatan akurasi dari 49,70% menjadi 93,60% menunjukkan pentingnya optimasi *hyperparameter* yang tepat. Nilai *precision* 92,70%, *recall* 94,60%, dan *confidence level* 93,30%

menunjukkan performa yang seimbang dan dapat diandalkan.


VGG16 mencapai akurasi identik dengan ResNet-50 (93,60%) menggunakan konfigurasi image size 224×224 , batch size 32, learning rate 5×10^{-5} , optimizer SGD, dan 100 epoch. Peningkatan signifikan dari 91,50% ke 93,60% menunjukkan bahwa arsitektur klasik masih dapat bersaing ketika dikonfigurasi optimal. Nilai precision tinggi (95,50%) menunjukkan deteksi yang presisi dengan false positive minimal, meskipun recall sedikit lebih rendah (91,40%).

YOLOv11 mencapai akurasi 94,00% dengan konfigurasi *image size* 224×224 , *batch size* 8, *learning rate* 1×10^{-3} , *optimizer* AdamW, dan 150 *epoch*. Sedikit peningkatan dari 93,40% ke 94,00% menunjukkan stabilitas yang sangat baik dan konvergensi optimal. Keunggulan YOLOv11 terletak pada adaptabilitas superior untuk klasifikasi medis meskipun dirancang untuk deteksi objek. *Confidence level* tertinggi (97,00%) menunjukkan kepercayaan prediksi yang luar biasa untuk implementasi klinis.




Gambar 4. 5 *Confusion Matrix* Klasifikasi EfficientNet 2 Kelas (B)

Confusion matrix EfficientNet hasil optimisasi menunjukkan 92 citra abnormal terdeteksi dengan benar namun 3 citra salah diklasifikasikan sebagai normal, serta 89 citra normal teridentifikasi dengan benar namun 5 sampel salah diklasifikasikan sebagai abnormal. Meskipun terjadi sedikit penurunan sensitivitas dibandingkan eksperimen sebelumnya, distribusi kesalahan yang lebih seimbang mengindikasikan pembelajaran yang lebih general.




Gambar 4. 6 Grafik *Training Accuracy* EfficientNet 2 kelas (B)

Analisis grafik pelatihan EfficientNet versi optimisasi menunjukkan karakteristik pembelajaran yang lebih stabil. *Training loss* dimulai dari 0,7 dan mengalami penurunan konsisten hingga 0,28 di akhir epoch, sementara *validation loss* dimulai dari 0,43 dan berjalan stabil ke nilai serupa. Tidak adanya peningkatan ekstrem seperti pada eksperimen sebelumnya mengindikasikan bahwa parameter yang dioptimisasi menghasilkan proses pembelajaran yang lebih baik. Implementasi *Cosine Learning Rate Schedule* yang menurun gradual dari 1×10^{-3} hingga 1×10^{-6} memungkinkan *fine-tuning* yang lebih baik, menghasilkan akurasi training 96,52% dan akurasi validasi 94,97% dengan gap yang minimal, menunjukkan generalisasi yang membaik.



Gambar 4. 7 *Confusion Matrix* Klasifikasi YOLOv11 untuk 2 Kelas (B)

Performa YOLOv11 pada eksperimen *fine-tuning* juga menunjukkan peningkatan dalam stabilitas pembelajaran. *Confusion matrix* hasil optimisasi menunjukkan 89 citra abnormal terdeteksi dengan benar namun 6 citra salah diklasifikasikan sebagai normal, serta 84 citra normal teridentifikasi dengan benar namun 5 sampel salah diklasifikasikan sebagai abnormal. Meskipun terjadi sedikit penurunan sensitivitas dibandingkan eksperimen sebelumnya, distribusi kesalahan yang lebih seimbang mengindikasikan pembelajaran yang lebih general.



Gambar 4. 8 Grafik *Training Accuracy* YOLOv11 untuk 2 kelas (B)

Grafik pelatihan menunjukkan *training loss* yang dimulai dari 0,42 dan turun konsisten hingga 0,1, sementara *validation loss* dari 0,4 hingga 0,12-0,13. Stabilitas yang ditunjukkan dengan gap minimal antara akurasi training dan validasi mengkonfirmasi bahwa optimisasi parameter berhasil mencegah *overfitting* sambil mempertahankan kemampuan pembelajaran yang baik.

4.2.2 Hasil Model Klasifikasi 3 Kelas

Tabel 4. 11 Hasil Klasifikasi Model 3 Kelas (A)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	128×128	224×224	160×160	224×224
Batch Size	16	32	16	8
Learning Rate	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$	1×10^{-4}	5×10^{-5}	1×10^{-3}
Optimizer	AdamW	Adam	SGD	AdamW
Epoch	150	100	80	150

Tabel 4.11 Hasil Klasifikasi Model 3 Kelas (A) (Lanjutan)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Accuracy	86,80%	74,10%	65,70%	79,40%
Precision	86,70%	76,70%	65,20%	79,20%
Recall	86,80%	74,10%	65,60%	79,40%
F1-Score	86,70%	74,60%	65,10%	79,10%
Balanced Accuracy	86,90%	74,10%	65,60%	79,50%
MCC	80,00%	62,00%	48,80%	69,30%
Confidence	90,90%	73,50%	57,40%	76,90%

EfficientNet mempertahankan akurasi cukup tinggi 86,80% menggunakan konfigurasi *image size* 128×128, *batch size* 16, *learning rate* adaptif dari 1×10^{-3} hingga 1×10^{-6} , *optimizer AdamW*, dan 150 *epoch*. Meskipun mengalami penurunan dari klasifikasi biner dari 96,80% ke 3 kelas 86,80%, EfficientNet tetap menunjukkan adaptabilitas yang baik dalam menangani kompleksitas yang meningkat. Metrik evaluasi menunjukkan konsistensi yang sangat baik dengan nilai *precision* 86,70%, *recall* 86,80%, dan *F1-score* 86,70%. Nilai MCC tinggi (80,00%) mengkonfirmasi kualitas prediksi yang baik, sementara nilai *confidence* 90,90% menunjukkan tingkat kepercayaan model yang sangat baik untuk implementasi klinis.


YOLOv11 mencapai posisi kedua dengan akurasi 79,40%, menggunakan *image size* 224×224, *batch size* 8, *learning rate* 1×10^{-3} , *optimizer AdamW*, dan 150 *epoch*. Performa YOLOv11 menunjukkan bahwa adaptasi arsitektur deteksi objek untuk klasifikasi dapat memberikan hasil yang cukup baik. Penggunaan *batch size* yang relatif kecil memungkinkan *gradient* yang lebih stabil dalam pembelajaran representasi fitur yang kompleks untuk diferensiasi sub tipe diabetes. Nilai *precision*, *recall*, dan *F1-score* yang konsisten menunjukkan keseimbangan klasifikasi yang baik. Nilai *confidence* 76,90% menunjukkan tingkat kepercayaan

yang memadai, meskipun lebih rendah dari EfficientNet.

ResNet-50 mencapai akurasi 74,10% dengan konfigurasi *image size* 224×224, *batch size* 32, *learning rate* 1×10^{-4} , *optimizer Adam*, dan 100 *epoch*. Meskipun menggunakan resolusi input yang lebih tinggi dan arsitektur yang terbukti baik, performa ResNet-50 masih lebih rendah dari EfficientNet dan YOLOv11. Hal ini mengindikasikan bahwa dalam konteks klasifikasi citra medis dengan perbedaan visual citra, efisiensi arsitektur dan strategi scaling menjadi lebih penting daripada depth model semata. Nilai *precision* 76,70% dan *recall* 74,10% menunjukkan *trade-off* antara deteksi *false positive* dan *false negative*. MCC 62,00% mengindikasikan kualitas prediksi yang cukup baik namun masih dapat ditingkatkan. Nilai *confidence* 73,50% menunjukkan tingkat kepercayaan yang moderat.

VGG16 menunjukkan performa terendah dengan akurasi 65,70%, menggunakan *image size* 160×160, *batch size* 16, *learning rate* 5×10^{-5} , *optimizer SGD*, dan 80 *epoch*. Nilai *precision* dan *recall* yang rendah mengindikasikan kesulitan dalam membedakan karakteristik pembuluh darah normal dan abnormal. MCC yang rendah menunjukkan kualitas prediksi yang masih memerlukan perbaikan signifikan. *Confidence level* terendah (57,40%) mencerminkan ketidakpastian model dalam prediksi.

UNIVERSITAS
MA CHUNG




Gambar 4. 9 *Confusion Matrix* Klasifikasi EfficientNet 3 Kelas (A)

Dari *confusion matrix* diatas, terlihat bahwa model EfficientNet menunjukkan performa yang cukup baik namun dengan beberapa tantangan klasifikasi. Untuk kelas DM Neuropati, model berhasil mengklasifikasikan 65 sampel dengan benar, namun terdapat 15 sampel yang salah diklasifikasikan sebagai DM Non Neuropati dan 1 sampel yang salah diklasifikasikan sebagai Sehat. Pada kelas DM Non Neuropati, model mengklasifikasikan 66 sampel dengan benar, tetapi terdapat 10 sampel yang salah diklasifikasikan sebagai DM Neuropati dan 6 sampel sebagai Sehat. Sementara untuk kelas Sehat, model menunjukkan performa yang sangat baik dengan mengklasifikasikan 81 sampel dengan benar tanpa kesalahan klasifikasi ke kelas lain, menunjukkan bahwa model dapat membedakan kondisi normal dengan sangat efektif.



Gambar 4. 10 Grafik *Training Accuracy* EfficientNet 3 kelas (A)


Setelah melakukan pelatihan menggunakan pengelompokan 2 kelas, dilakukan tambahan pelatihan dengan 3 kelas, yaitu Sehat, DM Neuropati, dan DM Non Neuropati. Klasifikasi citra medis ke 3 kelas membutuhkan pembelajaran yang lebih kompleks. Dengan menggunakan beberapa parameter pada Bab III, ditemukan hasil pelatihan model terbaik menggunakan algoritma EfficientNet. Hasil pelatihan model klasifikasi 3 kelas EfficientNet yaitu 86,80%. Terdapat penurunan akurasi yang dapat disebabkan oleh kesalahan klasifikasi, dimana ada salah prediksi antara DM Neuropati dan DM Non Neuropati, serta *feature overlap* dimana karakteristik visual yang mirip antar kelas sehingga menyebabkan ambiguitas.



Gambar 4. 11 *Confusion Matrix* Klasifikasi YOLOv11 untuk 3 Kelas (A)

Untuk kelas DM Neuropati, model berhasil mengklasifikasikan mayoritas sampel dengan benar, namun terdapat 12 sampel yang salah diklasifikasikan sebagai DM Non Neuropati dan 1 sampel sebagai Sehat. Kesalahan klasifikasi yang relatif tinggi antara DM Neuropati dan DM Non Neuropati mengindikasikan bahwa YOLOv11, meskipun awalnya dirancang untuk deteksi objek, menghadapi tantangan dalam membedakan subtype diabetes yang memiliki karakteristik visual serupa pada tingkat mikrosirkulasi kapiler.

Pada kelas DM Non Neuropati, model menunjukkan performa yang cukup seimbang dengan mengklasifikasikan sebagian besar sampel dengan benar, namun terdapat 12 sampel yang salah diklasifikasikan sebagai DM Neuropati dan 16 sampel sebagai Sehat. Pola kesalahan yang simetris antara DM Neuropati dan DM Non Neuropati menunjukkan kesulitan dalam membedakan kedua subtype diabetes, yang merupakan tantangan klinis yang wajar mengingat kesamaan patofisiologis keduanya. Sementara itu, untuk kelas Sehat, model menunjukkan performa yang sangat baik dengan mengklasifikasikan 72 sampel dengan benar, hanya 4 sampel yang salah diklasifikasikan sebagai DM Neuropati dan 5 sampel sebagai DM Non Neuropati.



Gambar 4. 12 Grafik *Training Accuracy* YOLOv11 untuk 3 kelas (A)

Grafik *training loss* menunjukkan penurunan yang konsisten dan stabil dari nilai awal sekitar 1.0 hingga mencapai sekitar 0.55 pada *epoch* ke-100, mengindikasikan bahwa model berhasil meminimalkan error pada data pelatihan dengan pola konvergensi yang sehat tanpa fluktuasi yang berlebihan. Grafik *validation loss* menampilkan hasil serupa dengan *validation loss* yang turun dari sekitar 1.0 hingga stabil di kisaran 0.6-0.7, menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan dan mampu mempertahankan kemampuan generalisasi yang baik.

Grafik *metrics accuracy* menunjukkan peningkatan akurasi *training* yang konsisten dari sekitar 0.5 hingga mencapai plateau di sekitar 0.78-0.80 pada *epoch* akhir. Kurva pembelajaran yang gradual ini mengindikasikan bahwa strategi pelatihan *progressive unfreezing* bekerja dengan efektif, memungkinkan model untuk belajar secara bertahap tanpa *gradient explosion*.

Tabel 4. 12 Hasil Klasifikasi Model 3 Kelas (B)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	224×224	224×224	160×160	224×224
Batch Size	16	16	8	8
Learning Rate	1×10^{-4}	1×10^{-4}	5×10^{-5}	1×10^{-3}
Optimizer	AdamW	Adam	SGD	AdamW
Epoch	100	100	100	120
Accuracy	75,80%	78,60%	68,00%	76,50%
Precision	75,70%	79,20%	67,80%	76,50%
Recall	75,80%	78,60%	67,90%	76,50%
F1-Score	75,60%	78,90%	67,10%	76,40%
Balanced Accuracy	75,80%	78,70%	67,90%	76,60%
MCC	63,80%	68,00%	52,50%	64,90%
Confidence	84,60%	74,00%	57,70%	86,50%


Pada training ini, ResNet-50 mencapai akurasi tertinggi dengan 78,60%, menggunakan konfigurasi *image size* 224×224, *batch size* 16, *learning rate* 1×10^{-4} dengan *optimizer Adam* selama 100 *epoch*. Keunggulan ResNet-50 ini menunjukkan bahwa arsitektur *deep residual learning* dengan *skip connections* dan kombinasi parameter yang sesuai terbukti efektif dalam menangkap hierarki fitur kompleks pada citra pembuluh darah kapiler, terutama dalam membedakan tiga kondisi klinis yang berbeda (Sehat, DM Neuropati, dan DM Non Neuropati). Nilai *precision* 79,20%, *recall* 78,60%, dan *F1-score* 78,90% menunjukkan keseimbangan yang baik dalam klasifikasi multi-kelas. MCC 68,00% mengkonfirmasi kualitas prediksi yang solid, sementara nilai *confidence* 74,00% menunjukkan tingkat kepercayaan yang memadai untuk aplikasi klinis.

YOLOv11 menempati posisi kedua dengan akurasi 76,50%, menggunakan *image size* 224×224, *batch size* yang lebih kecil (8), *learning rate* yang lebih tinggi (1×10^{-3}) dengan *optimizer AdamW*, dan durasi pelatihan yang lebih panjang

(150 *epoch*). Konsistensi metrik dengan *precision*, *recall*, dan *F1-score* menunjukkan keseimbangan klasifikasi yang optimal. Nilai *confidence* yang tinggi (86,50%) menunjukkan kepercayaan prediksi yang sangat baik.

EfficientNet mencapai akurasi 75,80% dengan konfigurasi *image size* 224×224, *batch size* 16, *learning rate* 1×10^{-4} menggunakan *optimizer AdamW* selama 100 *epoch*. Nilai *precision*, *recall*, dan *F1-score* yang konsisten menunjukkan stabilitas prediksi. MCC 63,80% dan *confidence level* 84,60% tetap menunjukkan performa yang dapat diterima untuk implementasi klinis.


VGG16 menunjukkan performa terendah dengan akurasi 68,00%, menggunakan *image size* yang lebih kecil (160×160), *batch size* 8, *learning rate* 5×10^{-5} dengan *optimizer SGD* tradisional selama 100 *epoch*. Performa yang relatif rendah ini dapat dijelaskan oleh beberapa faktor, yaitu arsitektur VGG16 yang lebih sederhana mungkin kurang mampu menangkap kompleksitas fitur halus dalam citra kapiler. Nilai *precision* 67,80%, *recall* 67,90%, dan *F1-score* 67,10% menunjukkan konsistensi yang relatif baik meskipun pada level akurasi yang lebih rendah. MCC 52,50% dan *confidence level* terendah (57,70%) mengindikasikan perlunya optimasi lebih lanjut untuk implementasi klinis.



Gambar 4. 13 *Confusion Matrix* Klasifikasi ResNet-50 untuk 3 Kelas (B)

Untuk kelas Sehat, model menunjukkan performa yang sangat baik dengan mengklasifikasikan 71 sampel dengan benar, namun terdapat 4 sampel yang salah diklasifikasikan sebagai DM Neuropati dan 6 sampel sebagai DM Non Neuropati. Tingkat akurasi tinggi pada kelas Sehat ini menunjukkan bahwa ResNet-50 dengan arsitektur *deep residual learning* berhasil menangkap karakteristik khas pembuluh darah kapiler normal.

Pada kelas DM Neuropati, model berhasil mengklasifikasikan 61 sampel dengan benar, tetapi mengalami kesulitan dengan 2 sampel yang salah diklasifikasikan sebagai Sehat dan 18 sampel yang salah diklasifikasikan sebagai DM Non Neuropati. Kesalahan klasifikasi yang relatif tinggi antara DM Neuropati dan DM Non Neuropati mengindikasikan bahwa kedua kondisi diabetes ini memiliki karakteristik visual yang mirip pada tingkat mikrosirkulasi kapiler, sehingga menantang kemampuan diskriminasi model. Untuk kelas DM Non Neuropati, model mengklasifikasikan 60 sampel dengan benar, dengan 2 sampel salah diklasifikasikan sebagai Sehat dan 20 sampel sebagai DM Neuropati. Pola kesalahan yang simetris antara DM Neuropati dan DM Non Neuropati menunjukkan bahwa meskipun ResNet-50 dapat membedakan kondisi normal dari abnormal dengan baik, pembedaan subtype diabetes mellitus masih menjadi tantangan yang memerlukan optimisasi lebih lanjut dalam ekstraksi fitur atau strategi pelatihan.



Gambar 4. 14 Grafik *Training Accuracy* ResNet-50 untuk 3 kelas (B)

Grafik sebelah kiri menampilkan evolusi akurasi pelatihan dan validasi, dimana terlihat jelas penerapan strategi dua fase yang telah diimplementasikan sesuai dengan spesifikasi Bab III. Pada fase awal (*epoch* 1-10), model menunjukkan akurasi yang relatif stagnan di sekitar 30-40% karena base ResNet-50 yang di-*freeze*, memungkinkan hanya *classification head* yang dilatih untuk beradaptasi dengan tugas klasifikasi pembuluh darah kapiler.

Setelah titik *fine-tuning* dimulai, terjadi peningkatan akurasi yang konsisten, dengan *training accuracy* meningkat secara eksponensial hingga mencapai sekitar 95% pada epoch ke-20, sementara *validation accuracy* sedikit lebih rendah sekitar 78-80%. Pola ini menunjukkan bahwa strategi *progressive unfreezing* berhasil mencegah *overfitting* yang berlebihan dan memungkinkan model untuk belajar secara bertahap dari fitur-fitur tingkat rendah hingga tinggi.

Grafik sebelah kanan menampilkan evolusi *loss function* yang komplementer dengan grafik akurasi. *Training loss* dan *validation loss* keduanya menunjukkan penurunan yang stabil setelah fase *fine-tuning* dimulai, dengan *validation loss* mencapai nilai minimum sekitar 0.6-0.8. Terdapat peningkatan yang tajam pada *validation loss* di sekitar *epoch* ke-12-13 yang kemudian cepat turun, kemungkinan menunjukkan periode adaptasi model terhadap *unfreezing* seluruh layer. Konvergensi yang stabil dari kedua *loss curves* dan tidak adanya divergensi yang signifikan antara *training* dan *validation loss* mengindikasikan bahwa model telah mencapai keseimbangan optimal.

4.2.3 Hasil Model Klasifikasi 6 Kelas

Tabel 4. 13 Hasil Klasifikasi Model 6 Kelas (A)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	128×128	224×224	160×160	224×224
Batch Size	8	32	16	8
Learning Rate	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$	1×10^{-4}	5×10^{-5}	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$
Optimizer	AdamW	Adam	SGD	AdamW
Epoch	150	100	80	150

Tabel 4.13 Hasil Klasifikasi Model 6 Kelas (A) (Lanjutan)


Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Accuracy	78,10%	60,10%	43,30%	45,90%
Precision	78,20%	61,30%	45,00%	45,30%
Recall	78,10%	60,10%	43,30%	45,90%
F1-Score	77,90%	59,80%	38,90%	43,70%
Balanced Accuracy	78,10%	60,20%	43,30%	45,80%
MCC	73,80%	52,40%	33,50%	35,60%
Confidence	94,50%	75,50%	24,70%	44,60%

EfficientNet mempertahankan akurasi tertinggi yaitu 78,10%, menggunakan konfigurasi *image size* 128×128, *batch size* 8, *learning rate* adaptif dari 1×10^{-3} hingga 1×10^{-6} dengan *optimizer AdamW* selama 150 *epoch*. Konsistensi metrik dengan *precision* 78,20%, *recall* 78,10%, dan *F1-score* 77,90% menunjukkan keseimbangan klasifikasi yang sangat baik. MCC tertinggi (73,80%) mengkonfirmasi kualitas prediksi yang superior, sementara *confidence level* tinggi menunjukkan tingkat kepercayaan model yang sangat baik untuk implementasi klinis yang kompleks.

ResNet-50 mengalami penurunan performa hingga akurasi 60,10%, menggunakan *image size* 224×224, *batch size* 32, *learning rate* 1×10^{-4} dengan *optimizer Adam* selama 100 *epoch*. Penurunan signifikan ini mengindikasikan bahwa meskipun arsitektur *deep residual learning* efektif untuk klasifikasi yang lebih sederhana, kompleksitas tambahan dari pembedaan enam subkategori kondisi pembuluh darah kapiler menjadi tantangan yang substansial. Nilai *precision* 61,30%, *recall* 60,10%, dan *F1-score* 59,80% menunjukkan konsistensi yang cukup baik namun menunjukkan kesulitan dalam diferensiasi antar kelas. MCC 52,40% dan *confidence level* 75,50% mengindikasikan kualitas prediksi yang moderat namun memerlukan optimasi lebih lanjut.

VGG16 menunjukkan performa yang rendah dengan akurasi 43,30%. Konfigurasi menggunakan *image size* 160×160, *batch size* 16, *learning rate* 5×10^{-5} , dan menggunakan *optimizer SGD* selama 80 *epoch*. Nilai *precision* 45,00%, *recall* 43,30%, dan *F1-score* terendah (38,90%) menunjukkan kesulitan signifikan dalam diferensiasi kelas. MCC terendah (33,50%) dan *confidence level* yang sangat rendah (24,70%) mengindikasikan prediksi yang mendekati *random guess*. Kombinasi *learning rate* konservatif dengan durasi pelatihan yang singkat tidak memberikan kesempatan yang cukup untuk konvergensi pada kompleksitas yang tinggi.

YOLOv11 menggunakan *image size* 224×224, *batch size* 8, *learning rate* 1×10^{-3} hingga 1×10^{-6} dengan *optimizer AdamW* selama 150 *epoch*. Konsistensi metrik dengan *precision* dan *recall* yang identik menunjukkan keseimbangan namun pada level akurasi yang rendah. MCC 35,60% dan *confidence level* 44,60% mengindikasikan ketidakpastian yang tinggi dalam prediksi.



Gambar 4. 15 *Confusion Matrix* Klasifikasi EfficientNet 6 Kelas (A)

Untuk kelas DM Neuropati Abnormal, model berhasil mengklasifikasikan sebagian besar sampel dengan benar, namun terdapat beberapa kesalahan klasifikasi yang tersebar ke kelas lain, menunjukkan kompleksitas dalam membedakan subtype abnormal pada pasien diabetes dengan neuropati. Kelas DM Neuropati Normal menunjukkan performa yang relatif stabil dengan mayoritas prediksi benar, sementara DM Non Neuropati Abnormal dan DM Non Neuropati Normal memperlihatkan pola kesalahan yang mengindikasikan kesulitan model dalam membedakan kondisi pembuluh darah pada pasien diabetes tanpa neuropati. Hal ini dapat dipahami mengingat karakteristik mikrosirkulasi yang serupa antara kedua kondisi tersebut.

Kelas Sehat Normal menunjukkan performa yang sangat baik dengan mayoritas prediksi yang akurat, mengindikasikan bahwa EfficientNet berhasil menangkap karakteristik khas pembuluh darah normal pada pasien sehat. Pola kesalahan yang relatif minimal pada kelas ini menunjukkan bahwa arsitektur compound scaling dari EfficientNet efektif dalam mengidentifikasi kondisi baseline normal.



Gambar 4. 16 Grafik *Training Accuracy* EfficientNet 6 kelas (A)

Grafik *Training and Validation Loss* menunjukkan pola yang sangat baik, dimana *training loss* turun secara konsisten dari nilai awal sekitar 2.5 hingga mencapai nilai rendah sekitar 0.5, sementara *validation loss* memberi hasil serupa namun dengan fluktuasi yang lebih tinggi. Penurunan *loss* yang stabil tanpa *overfitting* yang signifikan mengindikasikan bahwa strategi regularisasi yang diterapkan (*dropout* 0.2 dan *droppath* 0.1) bekerja dengan efektif dalam mencegah model dari menghafalkan data pelatihan. Grafik *Training and Validation Accuracy* menunjukkan peningkatan yang konsisten, dimana *training accuracy* meningkat secara monoton hingga mencapai sekitar 95% pada epoch akhir, sementara *validation accuracy* stabil di kisaran 80-85%.

Tabel 4. 14 Hasil Klasifikasi Model 6 Kelas (B)

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	224×224	224×224	160×160	224×224
Batch Size	16	32	8	16
Learning Rate	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$	1×10^{-4}	5×10^{-5}	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$
Optimizer	AdamW	Adam	SGD	AdamW
Epoch	100	100	100	120
Accuracy	68,50%	59,00%	52,60%	53,60%
Precision	67,40%	59,40%	51,50%	54,50%
Recall	68,50%	59,00%	52,60%	53,60%
F1-Score	67,40%	58,50%	51,30%	53,10%
Balanced Accuracy	68,50%	59,00%	52,60%	53,40%
MCC	62,40%	51,00%	43,30%	44,50%
Confidence	72,60%	77,90%	39,20%	60,70%


Hasil dari *tuning* parameter di model 6 kelas, EfficientNet tetap menghasilkan akurasi tertinggi yaitu 68,50%, menggunakan *image size* 224×224, *batch size* 16, *learning rate* adaptif dari 1×10^{-3} hingga 1×10^{-6} dengan *optimizer AdamW* selama 100 *epoch*. Meski mengalami penurunan dari hasil sebelumnya, EfficientNet masih menunjukkan konsistensi sebagai arsitektur dengan akurasi tertinggi untuk klasifikasi 6 kelas. Perubahan dari *image size* 128×128 ke 224×224 dan peningkatan *batch size* dari 8 ke 16 menunjukkan upaya optimisasi parameter, namun durasi pelatihan yang lebih pendek mungkin berkontribusi pada penurunan performa ini. Nilai *precision* 67,40%, *recall* 68,50%, dan *F1-score* 67,40% menunjukkan keseimbangan yang baik. MCC 62,40% dan *confidence level* 72,60% mengkonfirmasi kualitas prediksi yang solid meskipun dengan tingkat kepercayaan yang lebih moderat.

ResNet-50 menunjukkan akurasi 59,00% dengan konfigurasi yang konsisten menggunakan *image size* 224×224, *batch size* 32, *learning rate* 1×10^{-4} dengan *optimizer Adam* selama 100 *epoch*. Meskipun mengalami sedikit penurunan dari hasil sebelumnya (60,10%), ResNet-50 tetap mempertahankan posisi kedua, mengindikasikan bahwa arsitektur *deep residual learning* masih memberikan stabilitas dalam menghadapi kompleksitas klasifikasi 6 kelas. Nilai *precision* 59,40%, *recall* 59,00%, dan *F1-score* 58,50% menunjukkan konsistensi prediksi. MCC 51,00% dan *confidence level* yang cukup tinggi (77,90%) menunjukkan tingkat kepercayaan yang baik meskipun dengan akurasi yang moderat.

VGG16 mengalami peningkatan performa yang signifikan menjadi 52,60% dibandingkan dengan hasil sebelumnya, dengan perubahan konfigurasi dari *image size* 160×160 ke standar yang sama dengan arsitektur lain, serta peningkatan *batch size* dari 16 ke 8 dan *epoch* dari 80 ke 100. Nilai *precision* 51,50%, *recall* 52,60%, dan *F1-score* 51,30% menunjukkan konsistensi yang membaik. Namun, MCC 43,30% dan *confidence level* yang rendah (39,20%) masih mengindikasikan keterbatasan dalam diferensiasi kelas yang kompleks.

YOLOv11 juga menunjukkan peningkatan menjadi 53,60%, dengan perubahan *batch size* dari 8 ke 16 dan pengurangan durasi pelatihan dari 150 ke

120 *epoch*. Konsistensi metrik dengan *precision* 54,50%, *recall* 53,60%, dan *F1-score* 53,10% menunjukkan keseimbangan klasifikasi yang membaik. MCC 44,50% dan *confidence level* 60,70% mengindikasikan peningkatan kualitas prediksi yang substansial.




Gambar 4. 17 *Confusion Matrix* Klasifikasi EfficientNet 6 Kelas (B)

Untuk kelas DM Neuropati Abnormal, terlihat kesalahan prediksi yang cukup tinggi dengan 19 sampel diprediksi dengan benar, namun terdapat kesalahan klasifikasi yang tersebar ke berbagai kelas lain, mengindikasikan kesulitan model dalam mengidentifikasi karakteristik spesifik pembuluh darah abnormal pada pasien diabetes neuropati. Kelas DM Neuropati Normal menunjukkan performa yang lebih baik dengan 51 prediksi benar, namun masih terdapat konfusi dengan kelas lain terutama DM Non Neuropati Normal. DM Non Neuropati Abnormal dan DM Non Neuropati Normal menampilkan pola

kesalahan yang mengindikasikan karakteristik visual yang signifikan antara kondisi pembuluh darah pada pasien diabetes tanpa neuropati.

Sehat Normal menunjukkan performa yang stabil dengan akurasi prediksi yang tinggi. Hal ini membuktikan bahwa EfficientNet berhasil menangkap karakteristik pembuluh darah normal pada pasien sehat dengan baik. Pola *confusion matrix* ini mencerminkan kompleksitas dalam diferensiasi *fine-grained* antara enam kategori yang memerlukan pemahaman mendalam tentang perubahan mikrovaskular yang terkait dengan berbagai tipe diabetes melitus dan status neuropati.



Gambar 4. 18 Grafik *Training Accuracy* EfficientNet 6 kelas (B)

Grafik *Training and Validation Loss* menunjukkan pola penurunan yang konsisten dan sehat, dimana training loss turun secara perlahan dari nilai awal sekitar 2.0 hingga stabil di sekitar 1.0, sementara *validation loss* mengikuti tren serupa dengan fluktuasi yang moderat. Perbedaan yang stabil antara *training* dan *validation loss* mengindikasikan bahwa strategi regularisasi yang diterapkan berhasil mencegah *overfitting* meskipun menghadapi tugas klasifikasi yang sangat kompleks.

Grafik *Training and Validation Accuracy* memperlihatkan peningkatan yang gradual, dimana *training accuracy* meningkat secara konsisten dari sekitar 20% hingga mencapai sekitar 75% pada *epoch* akhir. *Validation accuracy* menunjukkan nilai yang sedikit lebih rendah, stabil di kisaran 65-70%, menunjukkan selisih yang dapat diterima antara *training* dan *validation performance*. Pola pembelajaran tanpa lonjakan yang berlebihan mengindikasikan bahwa kombinasi parameter yang digunakan (*learning rate adaptive*, *batch size* 16, *AdamW optimizer*) berhasil menciptakan kondisi pelatihan yang optimal untuk konvergensi model.

4.2.4 Hasil Model Hierarchical Klasifikasi 3 Kelas

Tabel 4. 15 Hasil Klasifikasi Model Hierarchical 3 Kelas

Arsitektur	EfficientNet	ResNet-50	VGG16	YOLOv11
Image Size	224×224	224×224	160×160	224×224
Batch Size	16	16	8	16
Learning Rate	$1 \times 10^{-4} \rightarrow 1 \times 10^{-7}$	1×10^{-4}	5×10^{-5}	$1 \times 10^{-3} \rightarrow 1 \times 10^{-6}$
Optimizer	AdamW	Adam	SGD	AdamW
Epoch	100	100	100	120
Test Accuracy	81,10%	78,20%	76,20%	74,00%
Precision	81,00%	78,70%	76,90%	73,90%
Recall	81,10%	78,20%	76,20%	74,00%
F1-Score	81,00%	78,30%	76,50%	73,70%
Balanced Accuracy	81,20%	78,20%	76,20%	74,10%
MCC	71,70%	67,60%	64,30%	61,30%
Confidence	79,10%	87,90%	72,30%	79,20%

EfficientNet menghasilkan akurasi tertinggi dengan nilai 81,10%, menggunakan konfigurasi image size 224×224 , batch size 16, learning rate adaptif dari 1×10^{-4} hingga 1×10^{-7} dengan optimizer AdamW selama 100 epoch. Keunggulan pendekatan hierarkis EfficientNet terletak pada strategi dua tahap yang memungkinkan model untuk pertama kali membedakan kondisi normal dari abnormal, kemudian melakukan klasifikasi lebih spesifik antara DM Neuropati dan DM Non Neuropati pada tahap kedua. Konsistensi metrik dengan *precision*, *recall*, dan *F1-score* yang identik menunjukkan keseimbangan klasifikasi yang sangat baik. MCC tertinggi (71,70%) mengkonfirmasi kualitas prediksi yang superior, sementara *confidence level* 79,10% menunjukkan tingkat kepercayaan yang baik.


ResNet-50 menunjukkan performa yang cukup baik dengan akurasi 78,20%, menggunakan konfigurasi yang konsisten dengan *image size* 224×224 , *batch size* 16, *learning rate* 1×10^{-4} dengan *optimizer Adam* selama 100 epoch. Peningkatan yang signifikan dari klasifikasi langsung menunjukkan bahwa arsitektur *deep residual learning* sangat berpotensi ketika diimplementasikan dalam pendekatan hierarkis. Nilai *precision* 78,70%, *recall* 78,20%, dan *F1-score* 78,30% menunjukkan konsistensi yang sangat baik. MCC 67,60% dan *confidence level* tertinggi (87,90%) mengindikasikan tingkat kepercayaan yang baik dalam prediksi hierarkis.

VGG16 mengalami peningkatan performa menjadi 76,20% dengan konfigurasi *image size* 160×160 , *batch size* 8, *learning rate* 5×10^{-5} menggunakan *optimizer SGD* selama 100 epoch. Peningkatan yang signifikan ini mengindikasikan bahwa meskipun VGG16 memiliki arsitektur yang relatif sederhana, pendekatan hierarkis mampu mengoptimalkan kemampuan representasi fiturnya. Nilai *precision* 76,90%, *recall* 76,20%, dan *F1-score* 76,50% menunjukkan keseimbangan yang baik. MCC 64,30% dan *confidence level* 72,30% mengindikasikan peningkatan substansial dalam kualitas dan kepercayaan prediksi.

YOLOv11 juga menunjukkan performa yang cukup baik dengan akurasi 74,00%, menggunakan *image size* 224×224 , *batch size* 16, *learning rate* adaptif

dari 1×10^{-3} hingga 1×10^{-6} dengan *optimizer AdamW* selama 120 *epoch*. Konsistensi metrik dengan *precision* 73,90%, *recall* 74,00%, dan *F1-score* 73,70% menunjukkan keseimbangan yang baik. MCC 61,30% dan *confidence level* 79,20% mengindikasikan adaptasi yang berhasil untuk aplikasi medis hierarkis.

Hasil dari Tabel 4.10 menunjukkan hasil yang cukup baik dalam pendekatan hierarkis pada klasifikasi pembuluh darah kapiler, dimana semua model mencapai akurasi di atas 74%, menunjukkan bahwa strategi pembelajaran bertahap (Normal vs Abnormal, kemudian DM Neuropati vs DM Non Neuropati) sesuai dengan alur diagnostik klinis dan memungkinkan model untuk mengembangkan representasi fitur yang lebih fokus dan relevan. Gap performa antar arsitektur menjadi lebih kecil dalam pendekatan hierarkis, mengindikasikan bahwa strategi ini dapat mengoptimalkan potensi berbagai arsitektur CNN untuk aplikasi klasifikasi citra medis yang kompleks.




Gambar 4. 19 *Confusion Matrix* Klasifikasi EfficientNet Stage 1 untuk 2 Kelas

Stage 1 dalam tahap pertama klasifikasi hierarkis, dimana model bertugas membedakan kondisi Normal dari Abnormal dengan akurasi yang sangat tinggi.

Matriks ini mendemonstrasikan keunggulan pendekatan hierarkis dengan fokus pada tugas *binary classification* yang fundamental. Untuk kelas Abnormal, model berhasil mengklasifikasikan 157 sampel dengan benar dan hanya 6 sampel yang salah diklasifikasikan sebagai Normal, menunjukkan sensitivitas yang sangat baik dalam mendeteksi kondisi patologi pembuluh darah kapiler.

Untuk kelas Normal, model menunjukkan performa yang hampir sempurna dengan mengklasifikasikan 77 sampel dengan benar dan hanya 4 sampel yang salah diklasifikasikan sebagai Abnormal. Tingkat akurasi yang tinggi pada kedua kelas ini mengindikasikan bahwa EfficientNet dengan arsitektur *compound scaling* berhasil menangkap perbedaan fundamental antara karakteristik mikrovaskular normal dan abnormal. Hasil *Stage 1* yang cukup baik ini memberikan pondasi yang kuat untuk *Stage 2*, karena sampel yang masuk ke tahap selanjutnya sudah ter-filter dengan akurasi tinggi, sehingga mengurangi *noise* dan meningkatkan kualitas input untuk diferensiasi yang lebih spesifik.




Gambar 4. 20 Grafik *Training Accuracy* EfficientNet Stage 1 untuk 2 Kelas

Grafik *Training* and *Validation Loss* menunjukkan penurunan yang konsisten, dimana *training loss* turun dari sekitar 0.7 hingga mendekati 0.35,

sementara *validation loss* mengikuti pola serupa tanpa tanda *overfitting*. Pendekatan yang parallel antara *training* dan *validation loss* mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik.

Grafik *Training and Validation Accuracy* memperlihatkan peningkatan yang baik, dimana kedua kurva meningkat secara konsisten hingga mencapai puncak di sekitar 95% untuk *training accuracy* dan 93% untuk *validation accuracy*. Selisih yang minimal antara *training* dan *validation accuracy* menunjukkan bahwa strategi *regularization* yang diterapkan (*dropout* dan *data augmentation*) bekerja dengan optimal.



Gambar 4. 21 *Confusion Matrix* EfficientNet Stage 2 untuk 2 Kelas

Untuk kelas DM Neuropati, model berhasil mengklasifikasikan 59 sampel dengan benar, namun terdapat 23 sampel yang salah diklasifikasikan sebagai DM Non Neuropati. Kesalahan klasifikasi yang relatif tinggi ini mencerminkan kompleksitas yang tinggi dalam membedakan subtype diabetes pada tingkat mikrovaskular, dimana perubahan patologis antara diabetes dengan dan tanpa neuropati memiliki overlap karakteristik yang signifikan. Untuk kelas DM Non Neuropati, model mengklasifikasikan 56 sampel dengan benar, dengan 25 sampel


yang salah diklasifikasikan sebagai DM Neuropati. Pola kesalahan yang relatif simetris menunjukkan bahwa model menghadapi tantangan dalam diferensiasi kedua kondisi, bukan bias sistematis terhadap salah satu kelas.



Gambar 4. 22 Grafik *Training Accuracy* EfficientNet Stage 2 untuk 2 Kelas

Grafik *Training and Validation Loss* memperlihatkan penurunan yang lebih gradual, dimana *training loss* turun dari sekitar 0.8 hingga 0.55, sementara *validation loss* menunjukkan fluktuasi yang lebih stabil, mengindikasikan tingkat kesulitan dari tugas klasifikasi ini. Meskipun demikian, tidak terdapat perbedaan yang signifikan antara *training* dan *validation loss*, menunjukkan bahwa model tetap mempertahankan kemampuan generalisasi yang masuk akal.

Grafik *Training and Validation Accuracy* menampilkan peningkatan yang lebih moderat dibandingkan *Stage 1*, dengan training accuracy mencapai sekitar 75% dan *validation accuracy* stabil di kisaran 70%. Gap yang lebih besar antara *training* dan *validation accuracy* mengindikasikan kompleksitas dalam tugas ini, namun masih dalam *range* yang dapat diterima untuk aplikasi medis.



Gambar 4. 23 Confusion Matrix Model EfficientNet Hierarchical

EfficientNet untuk klasifikasi 3 kelas, mengombinasikan *output* dari *Stage* 1 dan *Stage* 2 untuk menghasilkan prediksi final. Untuk kelas Sehat, model menunjukkan performa yang baik dengan 80 sampel diklasifikasikan dengan benar, tidak ada sampel yang salah diklasifikasikan sebagai DM Neuropati, dan hanya 1 sampel yang salah diklasifikasikan sebagai DM Non Neuropati. Akurasi yang sangat tinggi pada kelas Sehat ini mengkonfirmasi efektivitas *Stage* 1 dalam mengidentifikasi kondisi normal dan menunjukkan bahwa pendekatan hierarkis berhasil mempertahankan akurasi tinggi untuk batasan *clinical condition*.

Untuk kelas DM Neuropati, model mengklasifikasikan 62 sampel dengan benar, namun terdapat 19 sampel yang salah diklasifikasikan sebagai DM Non Neuropati. Sementara untuk kelas DM Non Neuropati, model berhasil mengklasifikasikan 56 sampel dengan benar, dengan 2 sampel salah diklasifikasikan sebagai Sehat dan 24 sampel sebagai DM Neuropati. Pola kesalahan yang terkonsentrasi antara DM Neuropati dan DM Non Neuropati mengkonfirmasi bahwa tantangan utama dalam klasifikasi hierarkis terletak pada diferensiasi subtype diabetes, sementara pengelompokkan kondisi normal dari

abnormal dapat dicapai dengan akurasi yang sangat tinggi. Hasil akhir ini mendemonstrasikan bahwa pendekatan hierarkis EfficientNet berhasil mencapai akurasi overall 81,10%, memberikan peningkatan yang signifikan dibandingkan pendekatan klasifikasi langsung untuk aplikasi diagnostik pembuluh darah kapiler.



UNIVERSITAS
MA CHUNG

Bab V

Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai klasifikasi pembuluh darah kapiler menggunakan teknik *deep learning* dengan empat arsitektur CNN yang berbeda (EfficientNet, ResNet-50, VGG16, dan YOLOv11), dapat ditarik beberapa kesimpulan penting. Penelitian ini berhasil mengevaluasi performa model pada berbagai tingkat kompleksitas klasifikasi, mulai dari klasifikasi biner, klasifikasi 3 kelas, dan klasifikasi 6 kelas, serta mengimplementasikan pendekatan *hierarchical* yang terbukti efektif.

Dalam klasifikasi 2 kelas (Normal dan Abnormal), EfficientNet menunjukkan performa yang baik dengan akurasi tertinggi mencapai 96,80% menggunakan parameter optimal dan 95,70% setelah parameter tuning. YOLOv11 menunjukkan konsistensi yang baik dengan akurasi berkisar antara 93,40% hingga 94,00%, diikuti oleh VGG16 yang memberikan hasil stabil di kisaran 91,50% hingga 93,60%. ResNet-50 mengalami peningkatan yang paling dramatis dari 49,70% menjadi 93,60% setelah optimisasi parameter, menunjukkan pentingnya *hyperparameter tuning* dalam mencapai performa optimal.

Untuk klasifikasi 3 kelas (Sehat, DM Neuropati, DM Non Neuropati), EfficientNet tetap memberikan hasil yang baik dengan akurasi 86,80%, meskipun mengalami penurunan menjadi 75,80% setelah parameter tuning. ResNet-50 menunjukkan peningkatan signifikan menjadi 78,60% setelah optimisasi parameter, sementara YOLOv11 menunjukkan stabilitas dengan akurasi berkisar 76,50% hingga 79,40%. VGG16 mencapai akurasi 65,70% hingga 68,00%, yang menunjukkan bahwa arsitektur sederhana masih dapat memberikan hasil yang *reasonable* untuk tugas klasifikasi yang lebih kompleks.

Pada klasifikasi 6 kelas yang merupakan kombinasi kondisi medis dan status normal/abnormal, kompleksitas tugas yang meningkat berdampak pada penurunan performa semua model. EfficientNet tetap memimpin dengan akurasi 78,10% yang turun menjadi 68,50% setelah tuning parameter. ResNet-50

mencapai akurasi 59,00% hingga 60,10%, sementara YOLOv11 dan VGG16 menunjukkan performa yang terbatas di bawah 55%. Hasil ini mengindikasikan bahwa klasifikasi *fine-grained* dengan enam kategori memerlukan pendekatan yang lebih mendalam dan dataset yang lebih besar.

Pendekatan *hierarchical* yang diimplementasikan untuk klasifikasi 3 kelas terbukti sangat efektif dan memberikan peningkatan performa yang signifikan. EfficientNet mencapai akurasi tertinggi 81,10%, diikuti oleh ResNet-50 dengan 78,20%, VGG16 dengan 76,20%, dan YOLOv11 dengan 74,00%. Pendekatan ini menunjukkan peningkatan akurasi 5-10% dibandingkan klasifikasi langsung dan memiliki alur yang sesuai dengan praktik klinis, yaitu pemisahan kondisi normal versus abnormal terlebih dahulu, kemudian diferensiasi sub tipe diabetes.

Penelitian ini juga membuktikan bahwa parameter tuning memiliki dampak yang sangat krusial terhadap performa model. Contoh paling signifikan adalah ResNet-50 yang mengalami peningkatan akurasi hampir 44% hanya dengan mengoptimasi batch size dari 32 menjadi 16. Hal ini menunjukkan bahwa konfigurasi *hyperparameter* yang tepat dapat mengubah model yang underperforming menjadi lebih baik.

5.2 Saran

Berdasarkan hasil penelitian yang telah diperoleh, terdapat beberapa aspek yang dapat dikembangkan lebih lanjut untuk meningkatkan performa dan aplikabilitas sistem klasifikasi pembuluh darah kapiler. Peningkatan dataset dan preprocessing menjadi aspek utama yang perlu diperhatikan. Dataset perlu diperluas dengan target 5.000-10.000 citra per kelas untuk memastikan representasi yang seimbang. *Enhanced preprocessing* dengan implementasi *noise reduction techniques* khusus untuk *microscopic images*, standarisasi *contrast* dan *normalization* yang konsisten, serta *ROI extraction* yang lebih precise menggunakan *segmentation* dapat meningkatkan kualitas input secara signifikan.

Eksplorasi Parameter Tambahan perlu dilakukan untuk mengoptimalkan performa model lebih lanjut selain parameter *batch size*, *image size*, *learning rate*, dan *epoch* yang telah digunakan. Parameter yang perlu dieksplorasi meliputi

dropout rate dan *weight decay*. Selain itu, eksplorasi *learning rate scheduler* yang berbeda seperti *StepLR*, *ExponentialLR*, dan *CosineAnnealingLR* dapat memberikan konvergensi yang lebih optimal. Parameter data augmentation seperti *rotation angle*, *zoom range*, dan *brightness adjustment* juga perlu disesuaikan untuk karakteristik citra mikroskopis pembuluh darah kapiler.



UNIVERSITAS
MA CHUNG

Daftar Pustaka

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A Textbook*. Springer.
- Agustina, R., Magdalena, R., Pratiwi, N. K. C. (2022). Klasifikasi Kanker Kulit Menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), 444-445.
- Ahmad, J. (2016). The Diabetic Foot. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 10(1), 48-60.
- Al-Mahroos, F., & Al-Roomi, K. (2007). Diabetic neuropathy, foot ulceration, peripheral vascular disease and potential risk factors among patients with diabetes in Bahrain: a nationwide primary care diabetes clinic-based study. *Ann Saudi Med*, 27(1), 24.
- Albert Hendrico, B. S. A., Khoirun Nikmah, Siti Elita Syabaniah, & Ferdianto. (2025). Laporan Kasus dengan Pendekatan Kunjungan Keluarga pada Pasien Diabetes Melitus Tipe 2, Neuropati Diabetik dan Ulkus Diabetik. *Jurnal Ilmiah Indonesia*, 10(2), 1727.
- Alpaydin, E. (2020). *Introduction to Machine Learning*. MIT Press.
- Amrulloh, I. T. A., Sari, B. N., & Padilah, T. N. (2024). Evaluasi augmentasi data pada deteksi penyakit daun tebu dengan YOLOv8. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 7547.
- Anandh, N. S., Bharadwaj, S., Sharma, R. K., & Sharma, R. K. (2023). Nail Fold Capillaroscopic Changes in Patients with Type 2 Diabetes Mellitus: An Observational Study. *European Journal of Cardiovascular Medicine*, 13(2).
- Anggreni, N. K. I. S., Kristianto, B. H., Handayani, D., Yueniwati, Y., Irawan, P. L. T., Rosandi, R., Kapti, R. E., & Purnama, A. D. (2025). Artificial Intelligence for Diabetic Foot Screening Based on Digital Image Analysis: A Systematic Review. *Journal of Diabetes Science and Technology*, 1.
- Asmara, T. S. P., Djojosingito, M. A., & Faizal, S. (2023). Hubungan Antara Indeks Masa Tubuh Dengan Range Of Motion Sendi Panggul Dan Lutut Pada Mahasiswa Fakultas Kedokteran Universitas Islam Bandung Angkatan 2019. *Jurnal Riset Kedokteran*, 19–24.

- Azhar, K. M., Santoso, I., & Soetrisno, Y. A. A. (2021). Implementasi deep learning menggunakan metode convolutional neural network dan algoritma YOLO dalam sistem pendeteksi uang kertas Rupiah bagi penyandang low vision. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(3).
- Bagavathiappan, S., Philip, J., Jayakumar, T., Raj, B., Rao, P. N., Varalakshmi, M., & Mohan, V. (2010). Correlation between plantar foot temperature and diabetic neuropathy: a case study by using an infrared thermal imaging technique. *Journal of diabetes science and technology*, 4(6), 1386-1392.
- Bishop, C.M. (2006). *Pattern Recognition and Machine Learning*. Singapore: Springer Science+Business Media
- Brownlee, J. (2018). *Data Preparation for Machine Learning*. Machine Learning Mastery.
- Chatchawan, U., Eungpinichpong, W., Plandee, P., & Yamauchi, J. (2018). Effects of Thai foot massage on plantar pressure distribution and walking speed in patients with diabetic peripheral neuropathy: a randomized controlled trial. *Journal of Physical Therapy Science*, 30(7), 947-953.
- Chollet, F. (2017). *Deep Learning with Python*. Manning.
- Chollet, F. (2021). *Deep Learning with Python, Second Edition*. Manning Publications.
- Davies, E. R. (2017). *Computer Vision: Principles, Algorithms, Applications, Learning*. Academic Press.
- Davis, J., & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd International Conference on Machine Learning*, 233-240.
- Desiani, A., Erwin, M., Suprihatin, B., Yahdin, S., Putri, A. I., & Husein, F. R. (2021). Bi-path architecture of CNN segmentation and classification method for cervical cancer disorders based on Pap-smear images. *IAENG International Journal of Computer Science*, 48(3), 1–9.
- Dima, A., Berza, I., Popescu, D. N., & Pârvu, M. I. (2021). Nailfold capillaroscopy in systemic diseases: Short overview for internal medicine. *Romanian Journal of Internal Medicine*, 59(3), 201–217.
- Dino-Lite. (n.d.). *CapillaryScope 500 Pro (MEDL4N5 Pro)*. Dino-Lite Europe. <https://www.dino-lite.eu/en/capillaryscope-500-pro-medl4n5-pro> (Accessed 11 Apr 2025)

- Dumoulin, V., & Visin, F. (2018). *A guide to convolution arithmetic for deep learning*. arXiv.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Forsyth, D. A., & Ponce, J. (2011). *Computer Vision: A Modern Approach*. Pearson.
- Ganda, L. H., & Bunyamin, H. (2021). Penggunaan Augmentasi Data pada Klasifikasi Jenis Kanker Payudara dengan Model Resnet-34: *Jurnal Strategi*, 3(1), 187-193.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. Jepang: O'Reilly Media.
- Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 3rd Edition*. O'Reilly Media.
- Girshick, R. B. (2015). Fast R-CNN. *CoRR*, abs/1504.08083.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *"Deep Learning."* MIT Press.
- Gosak, L., Svensen, A., Lorber, M., & Stiglic, G. (2023). Artificial Intelligence Based Prediction of Diabetic Foot Risk in Patients with Diabetes: A Literature Review. *Applied Science*, 13(5).
- Guyton AC, Hall JE. *Textbook of Medical Physiology*, 14th Edition. Elsevier; 2020:169
- Harrison, M. (2020). *Machine Learning Pocket Reference*. O'Reilly Media.
- Hastie, T., Tibshirani, R., & Friedman, J. (2016). *The Elements of Statistical Learning*. Springer.
- Haykin, S. (2008). *Neural Networks and Learning Machines*. Pearson.
- He, K., et al. (2016). *Deep Residual Learning for Image Recognition*. CVPR.
- Herath, S. (2024). EfficientNet. Revolutionizing Deep Learning Architectures for Image Classification. *Data Science and Machine Learning*, Medium.
- Hosking, S. P., Bhatia, R., Crock, P. A., Wright, I., Squance, M. L., & Reeves, G. (2013). Non-invasive detection of microvascular changes in a paediatric and adolescent population with type 1 diabetes: A pilot cross-sectional study. *BMC Endocrine Disorders*, 13, 41.

- Hossin, M., & Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2), 1-11.
- Howard, A. G. (2013). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*. Google Research.
- International Diabetes Federation. (2017). IDF diabetes atlas Eighth edition 2017.
- Ingegnoli, F., Gualtierotti, R., Lubatti, C., Bertolazzi, C., Gutierrez, M., Boracchi, P., et al. (2013). Nailfold capillary patterns in healthy subjects: A real issue in capillaroscopy. *Microvascular Research*, 90, 90–95.
- Ioffe, S., & Szegedy, C. (2015). *Batch Normalization*. ICML.
- Islam, M. M., Talukder, M. A., Uddin, A., Akhter, A., Khalid, M. (2024). *BrainNet: Precision Brain Tumor Classification with Optimized EfficientNet Architecture*. *International Journal of Intelligent Systems*.
- Jahne, B. (2014). *Digital Image Processing*. Springer
- Jain, A. K. (2010). *Fundamentals of Digital Image Processing*. Pearson.
- Japkowicz, N., & Shah, M. (2011). *Evaluating Learning Algorithms: A Classification Perspective*. Cambridge University Press.
- Jensen, T. S., Karlsson, P., Gylfadottir, S. S., Andersen, S. T., Bennett, D. L., Tankisi, H., Finnerup, N. B., Terkelsen, A. J., Khan, K., Themistocleous, A. C., Kristensen, A. G., Itani, M., Sindrup, S. H., Andersen, H., Charles, M., Feldman, E. L., & Callaghan, B. C. (2021). Painful and non-painful diabetic neuropathy, diagnostic challenges and implications for future management. *Brain*, 144, 1633.
- Jocher, G. (2023). Ultralytics YOLOv8 Documentation. Ultralytics.
- Kaehler, A., & Bradski, G. (2016). *Learning OpenCV 3*. O'Reilly.
- Karpathy, A., et al. (2014). *Large-Scale Video Classification with Convolutional Neural Networks*. CVPR.
- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*. ICLR.
- Kurniadi, A., Kusrrini., Sadikin, M.F. “Implementasi Convolutional Neural Network Untuk Klasifikasi Varietas Pada Citra Daun Sawi Menggunakan

Keras,” DoubleClick: Journal of Computer and Information Technology, vol. 4, no. 1, p. 25, 2020

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *ImageNet classification with deep convolutional neural networks*. NeurIPS.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep Learning*. Nature.

Lekakis, J. P., Papaioannou, T. G., Papamichael, C. M., et al. (2020). Nailfold capillaroscopy in type 2 diabetes mellitus: Correlation with glycemic control and microvascular complications. *Diabetes Research and Clinical Practice*, 161, 108059.

Lisco, G., & Triggiani, V. (2023). Computerized nailfold video-capillaroscopy in type 2 diabetes: A cross-sectional study on 102 outpatients. *Journal of Diabetes*, 15, 891.

Londoño-Mora, J. L., Leal-Vargas, D. D., & Quintana-Lopez, G. (2020). Prognostic value of capillaroscopy in organ involvement and identification of subtypes in systemic sclerosis (SS): A systematic literature review. *Revista Colombiana de Reumatología*, 27(S1), 10–25.

Maola, & Imroatul, A. Y. (2018). Perbedaan jumlah lekosit darah vena dan kapiler menggunakan pengenceran dalam tabung. Repository Universitas Muhammadiyah Semarang.

Maldonado G, Paredes C, Roberto G, Ríos C (2017) Nailfold Capillaroscopy a Non-Invasive Tool for Direct Observation of Microvascular Damage in Diabetes Mellitus: Review. *JSM Atheroscler* 2(4): 1037

Marasabessy, N. B., Nasela, S. J., & Abidin, L. S. (2020). Pencegahan Penyakit Diabetes Melitus (DM) Tipe 2.

Melania, E. S. (2021). Perbedaan kadar glukosa darah menggunakan sampel darah vena dan darah kapiler. Repository Institut Teknologi Sains dan Kesehatan Insan Cendekia Medika Jombang.

Nixon, M. S., & Aguado, A. S. (2019). *Feature Extraction and Image Processing*. Academic Press.

Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia. *Algor*, 2(1), 12–21.

Nurqolis, M. (2025). Optimasi Kinerja Single-Stage Object Detection Model pada Deteksi Tumor Otak. *Masters thesis*, UIN SUNAN KALIJAGA YOGYAKARTA.

- Parker, J. R. (2010). *Algorithms for Image Processing and Computer Vision*. Wiley.
- Phadnis, R., Mishra, J., & Bendale, S. (2018). Objects talk - object detection and pattern tracking using TensorFlow. *Proceedings of the International Conference on Inventive Communication and Computational Technologies*, 1216–1219.
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Prince, S. J. (2012). *Computer Vision: Models, Learning, and Inference*. Cambridge University Press
- Putera, A. P., & Primandari, P. N. (2020). Rancang bangun aplikasi absensi online berbasis Android menggunakan metode deep learning pada PT. Pelabuhan Indonesia III (Persero).
- Ramsundar, B., & Zadeh, R. B. (2018). *TensorFlow for Deep Learning: From Linear Regression to Reinforcement Learning*. O'Reilly Media.
- Raschka, S., & Mirjalili, V. (2019). *Python Machine Learning*. Packt Publishing.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779-788.
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149.
- Richards, J. A. (2012). *Remote Sensing Digital Image Analysis*. Springer.
- Rijal, M., Yani, A. M., & Rahman, A. (2024). Deteksi citra daun untuk klasifikasi penyakit padi menggunakan pendekatan deep learning dengan model CNN. *Jurnal Teknologi Terpadu*, 10(1), 56-62.
- Rismayanti, I. D. A., Nursalam, Farida, V. N., Dewi, N. W. S., Utami, R., Aris, A., & Agustini, N. L. P. I. B. (2022). Early detection to prevent foot ulceration among type 2 diabetes mellitus patient: A multi-intervention review. *Journal of Public Health Research*, 11(2). SAGE Publications Ltd.
- Rizki, A. M., & Marina, N. (2020). Klasifikasi kerusakan bangunan sekolah menggunakan metode convolutional neural network dengan pre-trained model VGG-16. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 24(3), 197–206.

- Roboflow. (2024). What is EfficientNet? The Ultimate Guide. Retrieved from <https://blog.roboflow.com/what-is-efficientnet/>
- Rosaline, M. D., Herlina, S., Anggraeni, D. T., Tobing, D. L., Sari, S. L., Lestari, S. E., Mauliya, N., & Oktalia, C. (2025). Manajemen Perawatan Kaki Diabetes Melitus dengan “Happy Foot Care Program” sebagai Pencegahan Komplikasi pada Penderita Diabetes Melitus. *Jurnal Kreativitas Pengabdian Kepada Masyarakat (PKM)*, 8(3), 1374-1375.
- Rosebrock, A. (2022). *Deep Learning for Computer Vision with Python*. PyImageSearch.
- Russel, S.J., Norvig, P. (2010). *Artificial Intelligence A Modern Approach*. Amerika: Pearson Education.
- Ryandra, M. F. D. (2022). Perbandingan arsitektur ResNet-50 dan Inceptionv3 dalam klasifikasi Covid-19 berdasarkan citra X-Ray. *Universitas Medan Area*.
- Salawu, F., Shadrach, L., Adenle, T., Martins, O., Bukbuk, D. (2018). Diabetic peripheral neuropathy and its risk factors in a nigerian population with type 2 diabetes mellitus. *African Journal of Diabetes Medicine*, 26(1), 16-20.
- Santoso, R. (2024). Augmentasi data pada prasasti logam untuk deteksi aksara Kawi. *Jurnal Fasilkom*, 14(1), 234–241.
- Sapkota, R., Ahmed, D., & Karkee, M. (2024). Comparing YOLOv8 and Mask R-CNN for instance segmentation in complex orchard environments. *Artificial Intelligence in Agriculture*
- Sapkota, R., Meng, Z., & Karkee, M. (2024). Synthetic meets authentic: Leveraging LLM generated datasets for YOLO11 and YOLOv10-based apple detection through machine vision sensors. *Smart Agricultural Technology*, 9, 100614.
- Sapkota, R., Qureshi, R., Flores-Calero, M., Badgujar, C., Nepal, U., Poullose, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2025). YOLO11 to its genesis: A decadal and comprehensive review of the You Only Look Once (YOLO) series. *ResearchGate*
- Sarker, I. H. (2021). Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2(6), 1–20.

- Saswono, R. S., Adipranata, R., & Gunadi, K. (2020). Deteksi balon ucapan pada komik Jepang dengan convolutional neural network, Canny edge detection dan Run Length Smooth Algorithm. *Jurnal Infra*, 8(2), 133–137.
- Senet, P., Fichel, F., Baudot, N., Gaitz, J. P., Tribout, L., & Frances, C. (2014). Nail-fold capillaroscopy in dermatology. *Annales de Dermatologie et de Vénéréologie*, 141, 429–437.
- Shapiro, L., & Stockman, G. (2001). *Computer Vision*. Prentice Hall.
- Sonka, M., Hlavac, V., & Boyle, R. (2014). *Image Processing, Analysis, and Machine Vision*. Cengage Learning.
- Srivastava, P., Khunger, N., Duvesh, R. K., Bansal, S., & Srivastava, P. (2024). Nail-fold capillaroscopy as a rapid non-invasive tool for assessment of microvascular complications in diabetes mellitus: A cross-sectional study. *Journal of Onychology and Nail Surgery*, 1(1), 5.
- Suprihanto, S., Awaludin, I., Fadhil, M., & Zulfikor, M. A. Z. (2022). Analisis kinerja ResNet-50 dalam klasifikasi penyakit pada daun kopi robusta. *Jurnal Informatika*, 9(2), 116–122.
- Swapna, G., Vinayakumar, R., & Soman, K. P. (2018). Diabetes detection using deep learning algorithms. *The Korean Institute of Communications and Information Sciences (KICS)*, 244.
- Syaripudin, D., Yayat, E., Jayadi, J., & Raharja, A. R. (2025). Klasifikasi penyakit periodontal pada citra panoramik gigi menggunakan deep learning berbasis ResNet50. *SisInfo: Jurnal Sistem Informasi dan Informatika*, 7(1), Februari.
- Szegedy, C., et al. (2015). *Going deeper with convolutions*. CVPR.
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer.
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications (2nd ed.)*. Springer
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In *Proceedings of the 36th International Conference on Machine Learning* (pp. 6105-6114).
- PMLR. Viso.ai. (2025). EfficientNet: Optimizing Deep Learning Efficiency. Retrieved from <https://viso.ai/deep-learning/efficientnet/>

- Waldman, R., DeWane, M. E., & Lu, J. (2020). Dermatomyositis: Diagnosis and treatment. *Journal of the American Academy of Dermatology*, 82(2), 283–296.
- Wayunah, W., Hikmawati, K., Khoeriyah, L., & Saefulloh, M. (2024). Long Time Suffering Influences The Occurrence of Diabetic Neuropathy. *HealthCare Nursing Journal*, 6(1).
- Yang, H., Sloan, G., Ye, Y., Wang, S., et al. (2020). New Perspective in Diabetic Neuropathy: From the Periphery to the Brain, a Call for Early Detection, and Precision Medicine. *Frontiers in Endocrinology*, 10, Article 929, 1.
- Yilmaz, U., Ayan, A., Uyar, S., Inci, A., Ozer, H., Tuter Yilmaz, F., Demirtas, G., Kok, M., & Tokuc, A. (2022). Capillaroscopic appearance of nailfold vasculature of diabetic nephropathy patients. *Arch Endocrinol Metab.*, 66(3), 295.
- Zhang, Z. (2019). *Computer Vision: Machine Learning and Deep Learning*. Springer.
- Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212-3232.

UNIVERSITAS
MA CHUNG