

**KLASIFIKASI ACUTE LYMPHOBLASTIC LEUKEMIA (ALL)
MENGUNAKAN MULTILAYER PERCEPTRON (MLP)**

SKRIPSI

**Oleh :
NABILA MAHDIYA PUTRI
NIM. 210605110006**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI ACUTE LYMPHOBLASTIC LEUKEMIA (ALL)
MENGUNAKAN MULTILAYER PERCEPTRON (MLP)**

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
NABILA MAHDIYA PUTRI
NIM. 210605110006

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN


KLASIFIKASI *ACUTE LYMPHOBLASTIC LEUKEMIA* (ALL) MENGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

SKRIPSI


Oleh :
NABILA MAHDIYA PUTRI
NIM. 210605110006

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 18 Juni 2025

Pembimbing I,


Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004

Pembimbing II,


Johan Ericka Wahyu P, M.Kom
NIP. 19831213 201903 1 004

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Ir. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

KLASIFIKASI ACUTE LYMPHOBLASTIC LEUKEMIA (ALL) MENGUNAKAN MULTILAYER PERCEPTRON (MLP)

SKRIPSI

Oleh :

NABILA MAHDIYA PUTRI
NIM. 210605110006

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 18 Juni 2025

Susunan Dewan Penguji

Ketua Penguji : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Anggota Penguji I : Dr. Cahyo Crysdian, MCS
NIP. 19740424 200901 1 008

Anggota Penguji II : Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004

Anggota Penguji III : Johan Ericka Wahyu Prakasa, M.Kom
NIP. 19831213 201903 1 004

()

()

()

()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Ir. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Nabila Mahdiya Putri
NIM : 210605110006
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Klasifikasi *Acute Lymphoblastic Leukemia* (ALL)
Menggunakan *Multilyer Perceptron* (MLP)

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 18 Juni 2025

Yang membuat pernyataan,



Nabila Mahdiya Putri
NIM. 210605110006

MOTTO

" Percaya sama Allah, jalani dengan ikhlas, selebihnya serahkan pada-Nya."

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur ke hadirat Allah SWT atas segala rahmat, kemudahan, dan kekuatan-Nya, skripsi ini dapat terselesaikan dengan baik. Karya ini saya persembahkan untuk orang-orang yang selalu menjadi alasan saya terus melangkah, meski tak selalu mudah.

Untuk ibu dan ayah, terima kasih atas setiap doa, kasih sayang, dan pengorbanan yang tak terhitung. Juga untuk mas dan mba yang selalu memberikan dukungan dan semangat dalam bentuk yang tidak selalu terlihat, tapi begitu berarti. Kepada diri saya sendiri, terima kasih telah bertahan sejauh ini dalam segala keterbatasan, dalam lelah dan ketidakpastian, namun tetap memilih untuk menyelesaikan apa yang telah dimulai.

Tak lupa, saya persembahkan karya ini untuk teman-teman Aster Teknik Informatika angkatan 2021, yang telah berjalan bersama dari awal perkuliahan hingga akhir perjuangan ini. Terima kasih atas kebersamaan, perjuangan, dan tawa yang menyertai setiap proses. Semoga segala usaha ini menjadi langkah kecil yang berarti, dan menjadi pengingat bahwa setiap perjuangan layak untuk disyukuri.

KATA PENGANTAR

Assalamu 'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah rabbilalamin, segala puji dan syukur senantiasa penulis panjatkan ke hadirat Allah subhanahu wa ta'ala atas berkat Rahmat, serta hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Klasifikasi *Acute Lymphoblastic Leukemia* (ALL) Menggunakan *Multilayer Perceptron* (MLP)” dengan baik dan lancar. Shalawat serta salam tetap tercurahkan kepada Nabi Muhammad SAW, yang telah membawa kita dari zaman kebodohan menuju zaman kebenaran yakni Islam dan zaman yang penuh dengan ilmu pengetahuan sebagaimana yang di rasakan pada saat ini. Dan semoga kita semua mendapat syafaatnya di hari akhir kelak, Aamiin.

Penulis mengucapkan rasa terima kasih yang begitu besar kepada seluruh pihak yang memberikan dukungan dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini. Ucapan terima kasih ini penulis disampaikan kepada:

1. Prof. Dr. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan, M.MT., IPU., selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. Irwan Budi Santoso, M.Kom, selaku dosen pembimbing I yang dengan penuh kesabaran dan ketulusan hati memberikan bimbingan, memberi

arahan, masukan, serta membantu penulis dalam mengerjakan dan menyelesaikan skripsi ini.

5. Johan Ericka Wahyu Prakasa, M.Kom, selaku dosen pembimbing II penulis yang senantiasa memberikan bimbingan dan masukan untuk penulis dalam mengerjakan dan menyelesaikan skripsi ini.
6. Dr. Zainal Abidin, M.Kom selaku penguji I dan Dr. Cahyo Crysdian, M.Cs selaku penguji II yang telah berkenan menguji, memberikan ilmu, kritik, saran, serta memberikan masukan yang membangun sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
7. Nia Faricha S, Si selaku admin Program Studi Teknik Informatika yang selalu sabar memberikan informasi, membantu, dan memberikan arahan selama perkuliahan dan proses penulisan skripsi ini.
8. Segenap dosen, laboran, dan jajaran staff Program Studi Teknik Informatika yang telah memberikan ilmu, pengetahuan, dan dukungan selama penulis menjalani studi.
9. Kepada kedua orang tua tercinta, sosok yang paling penulis sayangi dan hormati. Terima kasih atas kepercayaan yang diberikan kepada penulis untuk menempuh pendidikan tinggi dan menjalani hidup jauh dari rumah. Terima kasih telah menjadi tempat pulang dari segala keluh kesah, sekaligus mampu memposisikan diri sebagai orang tua, sahabat, dan motivator dalam setiap fase kehidupan. Semoga Allah senantiasa melimpahkan kesehatan, perlindungan, dan kebahagiaan, agar dapat terus menjadi bagian dalam setiap langkah perjalanan hidup penulis.

10. Kepada Mas Iwan, Mbak Meci, dan Mbak Yanti saudara kandung penulis yang selalu hadir dengan dukungan dan kasih sayang yang tulus. Terima kasih atas setiap perhatian, semangat, dan kebaikan yang tak pernah putus, yang telah menjadi penguat dalam setiap langkah perjalanan ini.
11. Kepada teman seperjuangan sekaligus sahabat-sahabat tersayang yaitu Amalia Amriadi, Maulidya Rahmah, Roudlotul Hannah, dan Tina Vidya Mariska, terima kasih telah menjadi bagian penting dalam perjalanan ini. Kehadiran kalian yang senantiasa menemani, menguatkan, dan membantu penulis selama hidup di perantauan, menjadi salah satu alasan penulis mampu melalui berbagai fase dengan lebih kuat dan penuh semangat.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, penulis terbuka terhadap saran dan kritik yang membangun untuk pengembangan lebih lanjut. Penulis percaya bahwa setiap masukan merupakan bagian dari proses pembelajaran yang berkelanjutan. Semoga skripsi ini dapat memberikan manfaat bagi pembaca, peneliti selanjutnya, serta berkontribusi dalam pengembangan ilmu pengetahuan di masa mendatang.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 18 Juni 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xiv
ABSTRAK	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
BAB II STUDI PUSTAKA	6
2.1 Penelitian Terkait	6
2.1.1 <i>Acute Lymphoblastic Leukemia (ALL)</i>	6
2.1.2 <i>Transfer Learning MobileNetV2</i>	10
2.1.3 <i>Multilayer Perceptron (MLP)</i>	13
2.2 <i>Acute Lymphoblastic Leukemia (ALL)</i>	15
2.3 MobileNetV2 dalam Tranfer Learning	22
2.4 <i>Multilayer Perceptron (MLP)</i>	24
BAB III DESAIN DAN IMPLEMENTASI	26
3.1 Alur Penelitian	26
3.2 Pengumpulan Data	26
3.3 Augmentasi Data.....	27
3.3.1 Rotasi.....	28
3.3.2 Flipping.....	28
3.4 Desain Sistem.....	30
3.4.1 Pra-Pemrosesan Data	31
3.4.2 Arsitektur <i>Transfer Learning</i> MobileNetV2	32
3.4.3 Arsitektur <i>Multilayer Perceptron (MLP)</i>	43
3.5 Prosedur Uji Coba Penelitian	53
3.5.1 Skenario Penelitian	53
3.5.2 Persiapan Data	55
3.5.3 Proses Pelatihan dan Pengujian	56
BAB IV HASIL DAN PEMBAHASAN	60
4.1 Skenario Uji Coba.....	60
4.2 Hasil Uji Coba.....	63

4.2.1 Skenario 1: Variasi Jumlah Hidden Layer.....	63
4.2.2 Skenario 2: Variasi Jumlah Neuron pada Hidden Layer	66
4.2.3 Skenario 3: Variasi Rasio Pembagian Data Latih dan Data Uji	69
BAB V KESIMPULAN DAN SARAN	73
5.1 Kesimpulan	73
5.2 Saran	73
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Perbandingan morfologi sel normal dan sel blast A: Kromatin, B: Nukleus, dan C: Sitoplasma dan nukleus	20
Gambar 3.1 Alur Penelitian.....	26
Gambar 3.2 Citra (a) untuk sel normal dan citra (b) untuk sel blast leukemia	27
Gambar 3.3 Desain sistem	30
Gambar 3.4 Skenario Training dan Testing	31
Gambar 3.5 Depthwise Separable Convolutions	38
Gambar 3.6 (a) Residual block dan (b) Inverted residual blocks.....	40
Gambar 3.7 Arsitektur <i>Multilayer Perceptron</i> (MLP).....	44
Gambar 3.8 Grafik Fungsi aktivasi Relu	46
Gambar 3.9 Grafik fungsi aktivasi sigmoid	48
Gambar 3.10 Flowchart Pelatihan Model MLP	53
Gambar 4.1 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Jumlah Hidden Layer.....	66
Gambar 4.2 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Jumlah Neuron.....	68
Gambar 4.3 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Rasio Pembagian Data.....	70

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait <i>Acute Lymphoblastic Leukemia</i> (ALL)	9
Tabel 2.2 Penelitian Terkait <i>Transfer Learning</i> MobileNetV2	12
Tabel 2.3 Penelitian Terkait Klasifikasi dengan <i>Multilayer Perceptron</i> (MLP) ..	14
Tabel 3.1 Arsitektur MobileNetV2	41
Tabel 3.2 Hasil Klasifikasi Berdasarkan Kelas Negatif dan Positif.....	59
Tabel 4.1 Rasio Pembagian Data Untuk Penelitian	60
Tabel 4.2 Jumlah Data Hasil Augmentasi pada Kelas Hem	61

ABSTRAK

Putri, Nabila Mahdiya. 2025. **Klasifikasi *Acute Lymphoblastic Leukemia* (ALL) Menggunakan *Multilayer Perceptron* (MLP)**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Irwan Budi Santoso, M.Kom (II) Johan Ericka Wahyu Prakasa, M.Kom.

Kata Kunci : Klasifikasi citra *Acute Lymphoblastic Leukemia* (ALL), *Transfer Learning MobileNetV2*, *Multilayer Perceptron* (MLP)

Acute Lymphoblastic Leukemia (ALL) merupakan salah satu jenis kanker darah yang ditandai oleh pertumbuhan sel darah putih yang belum matang secara berlebihan dalam sumsum tulang, dan memerlukan penanganan segera untuk mencegah komplikasi. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi citra ALL dan Non-ALL menggunakan kombinasi *MobileNetV2* sebagai ekstraktor fitur dan *Multilayer Perceptron* (MLP) sebagai model klasifikasi. Metode yang digunakan melibatkan *transfer learning* untuk mengekstraksi fitur citra, kemudian dilakukan klasifikasi dengan MLP, serta pengujian terhadap pengaruh rasio pembagian data, jumlah neuron, dan jumlah hidden layer terhadap performa model. Hasil terbaik diperoleh pada konfigurasi tiga hidden layer, rasio data 70:30, dan jumlah neuron sebanyak 128, dengan akurasi sebesar 86,21%, presisi 86,61%, recall 86,21%, dan F1-score 85,50%. Penelitian ini menunjukkan bahwa kombinasi *MobileNetV2* dan MLP mampu menghasilkan model klasifikasi citra ALL yang efektif, ringan secara komputasi, dan memiliki kinerja yang baik dalam mengklasifikasikan penyakit.

ABSTRACT

Putri, Nabila Mahdiya. 2025. **Classification of Acute Lymphoblastic Leukemia (ALL) Using Multilayer Perceptron (MLP)**. Thesis Department of Computer Science, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Supervisors: (I) Dr. Irwan Budi Santoso, M.Kom (II) Johan Ericka Wahyu Prakasa, M.Kom.

Acute Lymphoblastic Leukemia (ALL) is a type of blood cancer characterized by excessive growth of immature white blood cells in the bone marrow, requiring immediate treatment to prevent complications. This study aims to develop an image classification system for ALL and Non-ALL using a combination of MobileNetV2 as a feature extractor and a Multilayer Perceptron (MLP) as a classification model. The method involves transfer learning to extract image features, followed by classification using the MLP, and testing the influence of data splitting ratios, the number of neurons, and the number of hidden layers on model performance. The best results were obtained with a configuration of three hidden layers, a data ratio of 70:30, and 128 neurons, with an accuracy of 86.21%, precision of 86.61%, recall of 86.21%, and an F1-score of 85.50%. This study demonstrates that the combination of MobileNetV2 and MLP can produce an effective, computationally lightweight ALL image classification model with good performance in classifying the disease.

Keywords: Acute Lymphoblastic Leukemia (ALL) image classification, MobileNetV2 transfer learning, Multilayer Perceptron (MLP)

مستخلص البحث

فوتري, نبيلة مهدية. 2025. تصنيف سرطان الدم الليمفاوي الحاد (ALL) باستخدام متعدد الطبقات بيرسيبترون (MLP). أطروحة قسم علوم الكمبيوتر، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرفون: (I) د. إيرون بودي سانتوسو، (II) M.Kom يوهان إيريكاه واهيو براكاسا، M.Kom.

الكلمات المفتاحية: تصنيف صور سرطان الدم الليمفاوي الحاد (ALL)، التعلم النقلي MobileNetV2، متعدد الطبقات Multilayer Perceptron (MLP)

اللوكيميا الليمفاوية الحادة (ALL) هي نوع من أنواع سرطان الدم يتميز بنمو مفرط للخلايا البيضاء غير الناضجة في نخاع العظم، ويتطلب علاجاً فورياً لمنع حدوث مضاعفات. تهدف هذه الدراسة إلى تطوير نظام لتصنيف الصور للوكيميا الليمفاوية الحادة (ALL) وغير الحادة (Non-ALL) باستخدام مزيج من MobileNetV2 كمستخرج للميزات و Multilayer Perceptron (MLP) كنموذج تصنيف. تتضمن الطريقة التعلم النقلي لاستخراج ميزات الصور، يليها التصنيف باستخدام MLP، واختبار تأثير نسب تقسيم البيانات وعدد الخلايا العصبية وعدد الطبقات المخفية على أداء النموذج. تم الحصول على أفضل النتائج باستخدام تكوين من ثلاث طبقات مخفية، ونسبة بيانات 70:30، و 128 خلية عصبية، بدقة 86.21٪، ودقة 86.61٪، واسترجاع 86.21٪، ودرجة F1 85.50٪. تُظهر هذه الدراسة أن الجمع بين MobileNetV2 و MLP يمكن أن ينتج نموذجاً فعالاً وخفيفاً حسابياً لتصنيف صور ALL مع أداء جيد في تصنيف المرض.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Acute Lymphoblastic Leukemia (ALL) adalah salah satu jenis kanker leukemia yang ditandai oleh pertumbuhan berlebihan sel darah putih yang belum matang dalam sumsum tulang (Batool & Byun, 2023). Leukemia ini termasuk dalam kategori penyakit kanker yang berhubungan dengan sel darah putih. Berdasarkan klasifikasi usia, leukemia terbagi menjadi empat jenis utama: *Acute Myeloid Leukemia* (AML), *Acute Lymphoblastic Leukemia* (ALL), *Chronic Myeloid Leukemia* (CML), dan *Chronic Lymphocytic Leukemia* (CLL) (National Institute of Technology (Raipur et al., 2020). Pada leukemia akut, seperti ALL, pertumbuhan sel abnormal yang cepat memerlukan penanganan segera untuk mencegah komplikasi dan gangguan sistem kekebalan tubuh (Puła et al., 2022). Keterlambatan pengobatan dapat menghambat kemampuan darah untuk berfungsi secara normal, serta meningkatkan kerentanan terhadap infeksi (Ullah et al., 2021). Prevalensi ALL cukup tinggi, mencapai sekitar 80% pada anak-anak dan 40% pada orang dewasa. Penyakit ini berpotensi memengaruhi produksi sel darah yang belum matang, yang dapat menyebabkan kelainan pada sistem saraf dan meningkatkan risiko kematian (Batool & Byun, 2023). Oleh karena itu, deteksi dini ALL sangat penting untuk mengurangi angka kematian dan meningkatkan efektivitas pengobatan (Musleh et al., 2022).

Dalam Islam, konsep klasifikasi dan pengelompokan memiliki relevansi dalam memahami dan mengenali sesuatu dengan lebih baik. Hal ini sejalan dengan firman Allah dalam QS. Al-Maidah [5] ayat 100:

قُلْ لَا يَسْتَوِي الْخَبِيثُ وَالطَّيِّبُ وَلَوْ أَعْجَبَكَ كَثْرَةُ الْخَبِيثِ فَاتَّقُوا اللَّهَ يَا أُولِي الْأَلْبَابِ لَعَلَّكُمْ تُفْلِحُونَ

“Katakanlah (Nabi Muhammad), “Tidaklah sama yang buruk dengan yang baik meskipun banyaknya yang buruk itu menarik hatimu. Maka, bertakwalah kepada Allah wahai orang-orang yang berakal sehat agar kamu beruntung.” (QS. Al-Maidah: 100).

Menurut tafsir Kementerian Agama RI, ayat ini menekankan pentingnya kemampuan membedakan sesuatu yang baik dari yang buruk meskipun yang buruk tampak menarik secara lahiriah. Dalam konteks ini, pengelompokan dan klasifikasi merupakan bagian dari proses berpikir yang sehat dan rasional, yang menunjukkan penggunaan akal secara bijaksana. Ayat ini mengandung pesan agar manusia, terutama yang memiliki akal dan ilmu, tidak tertipu oleh jumlah atau tampilan luar, melainkan mampu menilai secara mendalam berdasarkan kebenaran (Kementerian Agama Republik Indonesia, n.d.-a). Prinsip ini selaras dengan urgensi dalam dunia medis, khususnya dalam mendiagnosis penyakit seperti ALL, di mana dibutuhkan ketepatan dalam membedakan antara sel sehat dan sel yang abnormal. Proses klasifikasi dalam penelitian ini pada dasarnya merupakan bentuk aktualisasi dari nilai-nilai yang diajarkan dalam ayat tersebut, yaitu mengenali, memisahkan, dan menentukan secara akurat mana yang berbahaya (sel abnormal) dan mana yang sehat, demi keselamatan dan keberhasilan pengobatan. Maka dari itu, penelitian ini tidak hanya bertujuan memberikan kontribusi teknis dalam bidang teknologi medis,

tetapi juga mencerminkan nilai-nilai Islam tentang pentingnya pemahaman yang jernih dan keputusan yang tepat berdasarkan ilmu dan ketakwaan.

Penelitian-penelitian sebelumnya terkait klasifikasi ALL telah mengusulkan berbagai metode dengan kinerja yang cukup tinggi, namun masih terdapat ruang untuk perbaikan. Sebagai contoh, penelitian yang dilakukan oleh (Ullah et al., 2021) menggunakan arsitektur VGG-16 dengan tambahan modul *Efficient Channel Attention* (ECA) untuk memperbaiki representasi fitur, dan menggunakan *Fully Connected* (FC) sebagai klasifikator. Sementara itu, (Ramaneswaran et al., 2021) menggunakan Inception V3 untuk ekstraksi fitur dan XGBoost sebagai algoritma klasifikasi. Penelitian lain oleh (Batoool & Byun, 2023) mengadopsi EfficientNetB untuk ekstraksi fitur, dengan lapisan dense pada tahap klasifikasi. Meskipun metode-metode tersebut cukup efektif, model yang digunakan umumnya memiliki jumlah parameter besar, yang menyebabkan peningkatan biaya komputasi serta waktu pemrosesan. Selain itu, penggunaan FC layer tunggal untuk klasifikasi sering kali kurang mampu menangani masalah non-linearitas, sedangkan XGBoost meskipun menawarkan akurasi yang tinggi, cenderung lebih kompleks dan membutuhkan sumber daya komputasi yang lebih besar. Hal ini menjadi kendala dalam kasus ALL, yang membutuhkan deteksi dan tindakan yang cepat mengingat sifatnya yang akut dan berpotensi cepat menyebar. Oleh karena itu, diperlukan pendekatan yang lebih ringan dan efisien dalam hal ekstraksi fitur dan klasifikasi, yang tidak hanya mempertahankan akurasi tetapi juga mampu mempercepat proses diagnosis sehingga pasien dapat segera menerima perawatan yang tepat.

Berdasarkan pada kelemahan dan potensi dari penelitian sebelumnya, pada penelitian ini diusulkan ekstraksi fitur menggunakan transfer learning MobileNetV2 dan MLP untuk klasifikasi ALL. MobileNetV2, sebagai bagian dari *Convolutional Neural Network* (CNN), dikenal efektif dalam menangani citra medis karena kemampuannya dalam mempelajari fitur langsung dari gambar dan menghasilkan klasifikasi yang akurat (Ramaneswaran et al., 2021; Rehman et al., 2018). Dalam studi yang dilakukan oleh Dou et al. (2023), MobileNetV2 terbukti unggul dalam proses ekstraksi fitur untuk mendeteksi citrus huanglongbing dibandingkan dengan metode ekstraksi fitur lainnya seperti InceptionV3 dan Xception. Keunggulan ini sangat penting untuk mengatasi kompleksitas citra mikroskopis sel darah putih pada leukemia. Setelah fitur diekstraksi, MLP digunakan sebagai algoritma klasifikasi. MLP dipilih karena efektivitasnya yang telah terbukti dalam berbagai penelitian sebelumnya, seperti penelitian yang dilakukan oleh Nugroho et al. (2023) menunjukkan bahwa kombinasi CNN dan MLP dapat mendeteksi thalassemia minor secara andal. Selain itu, Kusuma et al. (2023) menemukan bahwa MLP memiliki performa tinggi dalam klasifikasi penyakit pada daun jagung. Studi lain yang dilakukan oleh Kusuma et al. (2022), yang membandingkan MLP dan SVM untuk klasifikasi kanker payudara, juga menunjukkan bahwa MLP memberikan nilai akurasi, presisi, dan recall yang lebih baik dibandingkan SVM. Oleh karena itu, kombinasi MobileNetV2 dan MLP diharapkan dapat memberikan solusi yang lebih efisien, ringan, namun tetap akurat untuk klasifikasi ALL, yang pada akhirnya dapat mempercepat proses diagnosis dan membantu penanganan pasien dengan lebih tepat.

1.2 Pernyataan Masalah

1. Sejauh mana pengaruh penggunaan transfer learning MobileNetV2 untuk ekstraksi fitur terhadap performa klasifikasi ALL berdasarkan metrik evaluasi akurasi, presisi, recall, dan F1-score?
2. Sejauh mana performa MLP dalam klasifikasi citra ALL berdasarkan metrik evaluasi, presisi, recall, dan F1-score?

1.3 Batasan Masalah

Penelitian ini dibatasi pada penggunaan dataset citra mikroskopis sel darah putih yang diperoleh dari Kaggle. Dataset ini terdiri dari dua jenis sel, yaitu sel normal dan sel blast leukemia (Gupta & Gupta, 2019). Proses ekstraksi fitur dalam penelitian ini dilakukan menggunakan metode transfer learning dengan arsitektur MobileNetV2, tanpa membandingkan dengan metode ekstraksi fitur lainnya.

1.4 Tujuan Penelitian

1. Menganalisis pengaruh penggunaan transfer learning MobileNetV2 untuk ekstraksi fitur terhadap performa klasifikasi ALL berdasarkan metrik evaluasi akurasi, presisi, recall, dan F1-score.
2. Mengevaluasi performa MLP dalam melakukan klasifikasi ALL berdasarkan metrik evaluasi akurasi, presisi, recall, dan F1-score.

1.5 Manfaat Penelitian

Penelitian ini memberikan manfaat bagi tenaga medis dengan mengembangkan model berbasis citra medis untuk mendukung diagnosis *Acute*

Lymphoblastic Leukemia (ALL). Model ini membantu mempercepat analisis, meningkatkan akurasi klasifikasi, dan mendukung pengambilan keputusan klinis tanpa menggantikan peran utama tenaga medis dalam proses diagnosis.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

2.1.1 *Acute Lymphoblastic Leukemia (ALL)*

Penelitian terkait klasifikasi *Acute Lymphoblastic Leukemia (ALL)* telah menggunakan berbagai metode dan dataset. Beberapa penelitian yang menggunakan dataset yang sama dengan penelitian ini, yaitu C-NMC-2019 berjumlah 15.135 citra mikroskopis yang diekstraksi dari 118 pasien, di antaranya adalah penelitian oleh Pushpalatha et al. (2024) dan Rizki Firdaus Mulya et al. (2023). Dalam penelitian yang dilakukan oleh Pushpalatha et al. (2024), model ResNet50 digunakan sebagai bagian dari pendekatan *ensemble*, dan dilengkapi dengan *Adamax Optimizer* serta *Categorical Cross-Entropy Loss Function* untuk menangani ketidakseimbangan data dan noise pada dataset. Hasilnya menunjukkan bahwa ResNet50 mampu membedakan sel B limfoblastik dari prekursor limfoid B normal dengan akurasi sebesar 98,63%. Penelitian oleh Rizki Firdaus Mulya et al. (2023) juga menggunakan dataset C-NMC-19 untuk klasifikasi *Acute Lymphoblastic Leukemia (ALL)* dengan metode *Convolutional Neural Network (CNN)* dengan arsitektur InceptionV3 digunakan untuk mengklasifikasikan citra mikroskopis sel darah putih. Hasil penelitian ini menunjukkan bahwa model InceptionV3 menghasilkan akurasi yang tinggi, mencapai 98,96% pada data training, dengan nilai kerugian (*loss*) sebesar 0,031. Hal ini menunjukkan keunggulan InceptionV3 dalam mengklasifikasikan citra medis dengan akurasi tinggi.

Selain dua penelitian yang menggunakan dataset sama, beberapa studi lainnya menggunakan pendekatan yang berbeda dalam klasifikasi *Acute Lymphoblastic Leukemia* (ALL), meskipun jenis dan jumlah dataset yang digunakan bervariasi. Batool & Byun (2023) menggunakan dua dataset untuk mengevaluasi kinerja dan generalisasi model *Deep Learning*. Dataset C-NMC-19 digunakan untuk klasifikasi biner dalam membedakan sel kanker *Acute Lymphoblastic Leukemia* (ALL) dan sel normal, sedangkan dataset ALL digunakan untuk klasifikasi multi-kelas. Model yang diusulkan adalah EfficientNetB3, yang dikenal sebagai model *Deep Learning* ringan dengan *depthwise separable convolutions*. Hasil analisis menunjukkan bahwa model ini memiliki kinerja sangat baik dengan tingkat deteksi sebesar 95,62% untuk klasifikasi biner dan 97,27% untuk multi-kelas, serta akurasi mencapai 99,31%.

Penelitian oleh De Oliveira & Dantas (2021) juga menggunakan dataset C-NMC-2019 untuk klasifikasi *Acute Lymphoblastic Leukemia* (ALL), dengan fokus pada modifikasi arsitektur jaringan saraf VGG16, VGG19, dan Xception. Teknik augmentasi data seperti pencerminan, rotasi, pengaburan, dan penambahan *salt and pepper noise* diterapkan untuk menyeimbangkan dataset yang tidak seimbang. Modifikasi pada arsitektur jaringan saraf dilakukan dengan mengganti lapisan fully connected pada model *Convolutional Neural Network* (CNN) menggunakan *global average pooling* (GAP), diikuti oleh dua lapisan fully connected dengan masing-masing 512 neuron yang menggunakan fungsi aktivasi ReLU, serta penerapan dropout sebesar 50% pada kedua lapisan untuk mencegah overfitting. Lapisan prediksi softmax digunakan untuk klasifikasi biner antara sel kanker dan sel sehat.

Model VGG16 yang dimodifikasi ini berhasil mencapai F1-score tertinggi sebesar 92,60%, dengan precision sebesar 91,14%, sensitivitas 94,10%, dan spesifisitas 90,86%.

Sementara itu, penelitian oleh Das et al. (2020) mengusulkan pendekatan dan dataset yang berbeda untuk deteksi dan klasifikasi *Acute Lymphoblastic Leukemia* (ALL). Penelitian ini mengembangkan sistem deteksi otomatis yang mengekstraksi limfosit menggunakan teknik K-Means clustering berbasis warna. Fitur utama yang diekstraksi dari gambar yang telah disegmentasi mencakup bentuk, tekstur, dan warna, yang dianalisis dengan algoritma *Grey Level Co-occurrence Matrix* (GLCM) dan *Grey Level Run Length Matrix* (GLRLM). Untuk mengurangi dimensi data, diterapkan metode *Principal Component Analysis* (PCA). Proses klasifikasi menggunakan algoritma *Support Vector Machine* (SVM), menghasilkan akurasi sebesar 96% dan sensitivitas 92,64%.

Selanjutnya, penelitian lain yang dilakukan oleh Ullah et al. (2021) berfokus pada penggunaan *Convolutional Neural Network* (CNN) yang dipadukan dengan modul perhatian *Efficient Channel Attention* (ECA). Arsitektur VGG16 digunakan sebagai backbone untuk ekstraksi fitur, dengan penambahan modul ECA untuk meningkatkan relevansi fitur. Model ini diuji pada dataset C-NMC 2019, dengan hasil akurasi 91,1%, membuktikan bahwa modul ECA membantu mengatasi kesamaan morfologi antara sel kanker ALL dan sel sehat, meningkatkan performa klasifikasi.

Selain itu, Ramaneswaran et al. (2021) mengusulkan model hibrida yang menggabungkan InceptionV3 sebagai model ekstraksi fitur dan XGBoost sebagai

algoritma klasifikasi untuk mendeteksi *Acute Lymphoblastic Leukemia* (ALL). Model ini memanfaatkan InceptionV3 untuk mengekstraksi fitur dari gambar sel darah putih mikroskopis, yang kemudian diteruskan ke XGBoost sebagai pengklasifikasi akhir. Hasil penelitian menunjukkan bahwa kombinasi ini mampu mencapai F1-score berbobot sebesar 0,986, yang lebih baik dibandingkan penggunaan softmax sebagai kepala klasifikasi. Pendekatan hibrida ini menawarkan akurasi tinggi dalam mendeteksi ALL, sekaligus membuktikan keunggulan XGBoost dalam menangani klasifikasi kompleks berbasis fitur.

Pendekatan lainnya diusulkan oleh Mondal et al. (2021), yang mengembangkan model *ensemble* berbobot menggunakan beberapa arsitektur *Convolutional Neural Network* (CNN) untuk meningkatkan performa klasifikasi ALL. Model ini memanfaatkan teknik augmentasi data guna meningkatkan generalisasi model, dengan hasil F1-score sebesar 89,7%, akurasi seimbang 88,3%, dan AUC 0,948 pada dataset C-NMC 2019. *Ensemble* berbobot ini menggabungkan model-model seperti Xception, VGG16, DenseNet121, MobileNet, dan InceptionResNetV2, dan hasil eksperimen menunjukkan bahwa pendekatan *ensemble* ini lebih unggul dibandingkan model individu, terutama dalam mendeteksi ALL secara efektif dan mendukung keputusan klinis pada tahap awal. Tabel 2.1 merangkum hasil kajian literatur terkait metode klasifikasi *Acute Lymphoblastic Leukemia* (ALL) yang telah digunakan dalam penelitian sebelumnya.

Tabel 2.1 Penelitian Terkait Klasifikasi *Acute Lymphoblastic Leukemia* (ALL)

No.	Penulis	Metode	Dataset	Hasil
1.	Pushpalatha et al. (2024)	Penggunaan model ResNet50 dengan optimasi Adamax dan	C-NMC-2019	Akurasi: 98,63%

No.	Penulis	Metode	Dataset	Hasil
		fungsi <i>loss Categorical Cross-Entropy</i>		
2.	Rizki Firdaus Mulya et al. (2023)	Klasifikasi menggunakan CNN berbasis arsitektur InceptionV3	C-NMC-Leukemia	Akurasi: 98,96%
3.	Batool & Byun (2023)	Klasifikasi menggunakan model EfficientNetB3 pada klasifikasi biner dan multi-kelas	C-NMC-2019	Akurasi: 99,31%
4.	De Oliveira & Dantas (2021)	Modifikasi arsitektur VGG16, VGG19, dan Xception dengan penerapan global average pooling, lapisan <i>fully connected</i> , dan <i>dropout</i>	C-NMC-2019	F1-score: 92,60%
5.	Das et al. (2020)	Deteksi menggunakan teknik segmentasi K-Means, ekstraksi fitur GLCM dan GLRLM, reduksi dimensi dengan PCA, serta klasifikasi dengan SVM	ALL-IDB1	Akurasi: 96,00%, Sensitivitas: 92,64%
6.	Ullah et al. (2021)	Ekstraksi fitur menggunakan CNN berbasis VGG16 yang ditambahkan modul <i>Efficient Channel Attention (ECA)</i>	C-NMC-2019	Akurasi: 91,1%
7.	Ramaneswaran et al. (2021)	Ekstraksi fitur menggunakan InceptionV3 dan klasifikasi menggunakan algoritma XGBoost	ISBI C-NMC-2019	F1-score berbobot: 0,986
8.	Mondal et al. (2021)	Ensemble berbobot dari beberapa model CNN (Xception, VGG16, DenseNet121, MobileNet, dan InceptionResNetV2)	C-NMC-2019	F1-score: 89.7%, Akurasi seimbang: 88.3%, AUC: 0.948

2.1.2 Transfer Learning MobileNetV2

Penelitian oleh Somoal & Dzikrillah (2025) membahas penggunaan MobileNetV2 yang dikombinasikan dengan transfer learning untuk ekstraksi fitur, di mana model telah dilatih pada dataset *ImageNet* dan digunakan sebagai *feature extractor*. Penelitian ini membandingkan empat skenario, dua di antaranya menggunakan transfer learning. Hasilnya, skenario dengan transfer learning MobileNetV2 dan *optimizer Adam* mencapai akurasi tertinggi hingga 98%, precision 98%, recall 97,75%, dan f1-score 97,75%. Studi ini menegaskan bahwa

transfer learning pada MobileNetV2 sangat efektif dalam meningkatkan performa model, mempercepat konvergensi, serta mengatasi keterbatasan data dan masalah overfitting. Penelitian ini diaplikasikan pada deteksi tumor otak dari citra MRI.

Penelitian oleh (Putra et al., 2023) mengkaji pemanfaatan beberapa model transfer learning, termasuk MobileNetV2, dalam mengklasifikasikan kondisi tanaman padi yang meliputi berbagai jenis penyakit, hama, serta tanaman yang sehat. Citra yang digunakan terbagi ke dalam sembilan kelas. MobileNetV2 dimanfaatkan sebagai ekstraktor fitur tanpa menyertakan lapisan output aslinya, kemudian ditambahkan lapisan *Global Average Pooling*, *Dropout*, dan Dense sebagai bagian dari proses klasifikasi. Model ini mampu mencapai akurasi, precision, recall, dan f1-score sebesar 96%, serta specificity sebesar 99%, dengan total parameter sekitar 2,27 juta. Temuan ini memperlihatkan bahwa MobileNetV2 mampu memberikan hasil klasifikasi yang sangat baik sekaligus efisien untuk digunakan pada perangkat dengan keterbatasan sumber daya, seperti di wilayah pedesaan.

Sementara itu, penelitian yang dilakukan oleh Karnadi & Handhayani (2024) menerapkan MobileNetV2 untuk mengklasifikasikan sembilan jenis buah dari dataset yang terdiri atas 288 citra. Seperti pada studi sebelumnya, MobileNetV2 dimanfaatkan sebagai metode transfer learning dalam proses ekstraksi fitur, kemudian dilakukan fine-tuning untuk menghasilkan klasifikasi akhir. Hasil pengujian menunjukkan bahwa model ini mampu mencapai precision sebesar 98%, recall 97%, akurasi 97%, dan f1-score 97%, yang berarti lebih unggul dibandingkan InceptionV3 yang hanya memperoleh nilai evaluasi sebesar 94%

pada seluruh metrik. Temuan ini memperkuat bukti bahwa MobileNetV2 merupakan pilihan yang efisien untuk klasifikasi citra, terutama pada sistem dengan keterbatasan daya komputasi tanpa mengorbankan tingkat akurasi.

Selain itu, penelitian yang dilakukan oleh Dou et al., (2023) memanfaatkan MobileNetV2 sebagai model dasar untuk proses ekstraksi fitur, yang dikombinasikan dengan modul CBAM mampu meningkatkan akurasi dalam mengenali citra daun jeruk yang terinfeksi Huanglongbing, dengan akurasi mencapai 98,75%. Meskipun arsitektur dimodifikasi, MobileNetV2 tetap menjadi ekstraktor fitur utama melalui transfer learning dari ImageNet, dan terbukti lebih unggul dibandingkan model lain seperti InceptionV3 dan Xception. Hal ini menegaskan efektivitas MobileNetV2 dalam ekstraksi fitur citra. Tabel 2.2 menyajikan ringkasan kajian literatur mengenai penerapan dan keefektifan metode *transfer learning* sebagai fitur ekstraksi berdasarkan pada penelitian terdahulu.

Tabel 2.2 Penelitian Terkait *Transfer Learning* MobileNetV2

No	Penulis	Metode	Dataset	Hasil
1.	Somoal & Dzikrillah (2025)	MobileNetV2 sebagai <i>feature extractor</i> dengan transfer learning; klasifikasi menggunakan <i>dense layer</i>	Citra MRI tumor otak	Akurasi 98%, Precision 98%, Recall 97,75%, F1-score 97,75%
2.	Karnadi & Handhayani (2024)	MobileNetV2 dengan transfer learning dan fine-tuning untuk ekstraksi fitur dan klasifikasi	9 jenis buah (288 citra)	Akurasi 97%, Precision 98%, Recall 97%, F1-score 97%
3.	Penelitian oleh (Putra et al., 2023)	MobileNetV2 sebagai <i>feature extractor</i> ; klasifikasi menggunakan <i>Global Average Pooling, Dropout, dan Dense Layer</i>	9 kelas citra padi (penyakit, hama, padi sehat)	Akurasi 97%, Precision 98%, Recall 97%, F1-score 97%
4.	Dou et al., (2023)	CBAM-MobileNetV2 (MobileNetV2 + modul CBAM) untuk ekstraksi fitur berbasis transfer learning dan klasifikasi	Citra daun jeruk Huanglongbing (6008 citra hasil augmentasi)	Akurasi 98,75%

2.1.3 *Multilayer Perceptron (MLP)*

Penelitian mengenai klasifikasi dengan memanfaatkan *Multilayer Perceptron* (MLP) telah diterapkan secara luas di berbagai bidang. Salah satunya dilakukan oleh Wibowo et al., (2021), yang menggunakan MLP untuk membedakan empat jenis kayu, yaitu jati, sengon, mahoni, dan mindi. Tahapan awal dalam proses klasifikasi dilakukan melalui ekstraksi fitur tekstur menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM), yang menghasilkan parameter seperti correlation, contrast, energi, dan homogeneiti. Hasil dari ekstraksi tersebut kemudian dimasukkan ke dalam model MLP sebagai data input, dan dari proses ini diperoleh akurasi validasi tertinggi sebesar 88,75%.

Sementara itu, Azzahra et al., (2022) menggunakan pendekatan *Multilayer Perceptron* (MLP) untuk membedakan citra rontgen toraks antara pasien yang terinfeksi COVID-19 dan SARS. Proses dalam penelitian ini dimulai dengan tahap pra-pemrosesan, dilanjutkan dengan ekstraksi ciri tekstur menggunakan metode histogram dan *Gray Level Co-Occurrence Matrix* (GLCM), kemudian hasil ekstraksi tersebut diklasifikasikan menggunakan MLP. Evaluasi menunjukkan bahwa model berhasil mencapai nilai akurasi, sensitivitas, dan spesifisitas yang sama, yaitu sebesar 91,67%. Temuan ini menunjukkan bahwa MLP mampu mengenali dan membedakan pola tekstur pada citra medis secara efektif.

Penelitian lainnya dilakukan oleh Nugroho et al.,(2023) mengembangkan model klasifikasi untuk mendeteksi sembilan jenis sel eritrosit abnormal dengan memanfaatkan kombinasi antara ekstraksi fitur menggunakan arsitektur CNN VGG16 dan proses klasifikasi melalui *Multilayer Perceptron* (MLP). Penelitian ini

memanfaatkan total 7.245 citra sebagai data latih. Hasil evaluasi menunjukkan bahwa model berhasil mencapai akurasi tertinggi sebesar 96,175%. Selain itu, model tersebut juga diimplementasikan pada perangkat NVIDIA Jetson Nano, memungkinkan penerapannya dalam prediksi medis secara mobile.

Penelitian oleh Kusuma et al.,(2023) melakukan perbandingan performa beberapa algoritma klasifikasi, salah satunya *Multilayer Perceptron* (MLP) yang memanfaatkan fitur yang diekstraksi dari model deep learning VGG16. Berdasarkan hasil pengujian, MLP menunjukkan performa terbaik dengan nilai akurasi, precision, dan recall mencapai 97,4%, melampaui algoritma lain yang diuji. Temuan ini mengindikasikan bahwa MLP memiliki keunggulan dalam tugas klasifikasi citra pada tanaman, khususnya dalam mendeteksi penyakit pada daun jagung.

Penelitian oleh KUSUMA et al.,(2022) membandingkan kinerja Multilayer Perceptron (MLP) dan Support Vector Machine (SVM) dalam mengklasifikasikan kanker payudara. Pada studi ini, MLP menggunakan fungsi aktivasi logistic dan algoritma optimasi Adam, yang menghasilkan akurasi, precision, dan recall sebesar 97,7%, lebih tinggi dibandingkan SVM. Hasil tersebut menunjukkan bahwa MLP mampu memberikan performa yang unggul dalam mendukung proses klasifikasi diagnosis medis berbasis citra. Tabel 2.3 merangkum hasil kajian literatur terkait penggunaan Multilayer Perceptron (MLP) sebagai metode klasifikasi dalam berbagai penelitian sebelumnya.

Tabel 2.3 Penelitian Terkait Klasifikasi dengan *Multilayer Perceptron* (MLP)

No	Penulis	Metode	Dataset	Hasil
1.	Nugroho et al.,(2023)	Ekstraksi fitur CNN VGG16, klasifikasi dengan MLP	7245 citra eritrosit	Akurasi 96,175%

No	Penulis	Metode	Dataset	Hasil
			thalassemia minor	
2.	Kusuma et al.,(2023)	Ekstraksi fitur VGG16, klasifikasi penyakit daun jagung dengan MLP	8200 citra daun jagung (4 kelas)	Akurasi, precision, recall 97,4%
3.	Azzahra et al., (2022)	Ekstraksi ciri tekstur (histogram dan GLCM), klasifikasi dengan MLP	Citra rontgen toraks COVID-19 dan SARS	Akurasi, sensitivitas, dan spesifisitas 91,67%
4.	KUSUMA et al.,(2022)	Klasifikasi kanker payudara menggunakan MLP dengan aktivasi Logistic dan optimisasi Adam	Dataset Wisconsin Breast Cancer (569 data)	Akurasi, precision, recall 97,7%
5.	Wibowo et al., (2021)	Ekstraksi fitur GLCM dan klasifikasi dengan MLP	Citra empat jenis kayu	Akurasi validasi 88,75%

2.2 *Acute Lymphoblastic Leukemia (ALL)*

ALL merupakan jenis kanker darah yang terjadi ketika limfoblas, yaitu sel darah putih yang belum matang, berkembang secara cepat dan tidak terkendali (Jiwani et al., 2023). Kondisi ini disebabkan oleh gangguan dalam proses pembentukan sel darah putih di sumsum tulang. Normalnya, sel darah putih berasal dari pematangan sel punca (*stem cell*), yang akan berubah menjadi limfoblas sebelum akhirnya menjadi limfosit (Jiwani et al., 2023). Namun, pada kasus ALL, proses pematangan ini tidak berjalan sebagaimana mestinya, sehingga limfoblas gagal berkembang menjadi limfosit. Akibatnya, jumlah limfoblas meningkat drastis dan memenuhi sumsum tulang hingga masuk ke peredaran darah. ALL lebih umum ditemukan pada anak-anak dibandingkan dengan orang dewasa (Rahman & Noor, 2023).

Penyebab utama dari ALL adalah adanya mutasi genetik (perubahan struktur DNA) pada sel punca limfoid di sumsum tulang. Sel punca limfoid adalah jenis sel induk yang seharusnya berkembang menjadi limfosit, yaitu salah satu jenis

sel darah putih yang berperan penting dalam sistem kekebalan tubuh untuk melawan infeksi. Namun, akibat mutasi tersebut, sel ini gagal matang secara normal dan justru berubah menjadi limfoblas, yaitu limfosit yang belum matang. Limfoblas ini diproduksi dalam jumlah berlebihan dan bersifat abnormal karena tidak dapat menjalankan fungsi pertahanan tubuh dengan baik. Produksi limfoblas yang tidak terkendali menyebabkan terganggunya proses pembentukan sel darah normal lainnya di sumsum tulang. Beberapa jenis sel darah normal yang produksinya terganggu antara lain:

- a. Eritrosit (sel darah merah): Berfungsi berfungsi membawa oksigen ke seluruh tubuh. Kekurangan eritrosit menyebabkan anemia, yang ditandai dengan rasa lemas, pucat, dan mudah lelah.
- b. Trombosit (keeping darah): Berperan dalam proses pembekuan darah. Jumlah trombosit yang rendah (trombositopenia) membuat penderita mudah mengalami perdarahan, seperti mimisan atau gusi berdarah, serta rentan mengalami memar meski hanya terkena benturan ringan.
- c. Leukosit sehat (sel darah putih matang): Membantu tubuh melawan infeksi. Jika jumlah leukosit sehat berkurang, maka daya tahan tubuh melemah dan penderita lebih mudah mengalami infeksi serta demam tinggi.

Kondisi ketidakseimbangan sel darah tersebut juga menyebabkan berbagai gejala lain yang khas pada ALL, seperti nyeri tulang dan sendi akibat penumpukan sel abnormal di sumsum tulang, sesak napas karena anemia atau infeksi paru, serta pembesaran kelenjar getah bening, hati, atau limpa yang menimbulkan sakit perut atau rasa tidak nyaman. Selain itu, penderita juga dapat mengalami penurunan berat

badan yang drastis tanpa sebab yang jelas, sebagai respons tubuh terhadap penyakit yang menyerang secara sistemik (Pittara, 2022).

Untuk memastikan diagnosis ALL, diperlukan serangkaian pemeriksaan lanjutan yang dilakukan secara bertahap. Tahapan awal dalam proses diagnosis ALL dimulai dari pemeriksaan darah lengkap. Pada tahap ini, darah pasien diambil melalui proses pengambilan darah dari pembuluh vena, kemudian dianalisis di laboratorium untuk mengetahui jumlah dan proporsi dari berbagai jenis sel darah, yaitu eritrosit (sel darah merah), leukosit (sel darah putih), dan trombosit (keping darah). Pemeriksaan ini bertujuan untuk mendeteksi adanya kelainan kuantitatif yang mencurigakan. Jika hasilnya menunjukkan penurunan jumlah eritrosit (yang dapat menyebabkan anemia), trombosit (yang memicu perdarahan), serta jumlah leukosit yang tidak normal (terlalu tinggi atau terlalu rendah), maka dicurigai adanya gangguan hematologis. Kecurigaan terhadap leukemia akan semakin kuat apabila ditemukan limfoblas, yaitu bentuk belum matang dari limfosit di dalam darah tepi, padahal sel ini seharusnya hanya ada di sumsum tulang. Bila temuan ini muncul, maka dokter akan merekomendasikan pemeriksaan lanjutan untuk memastikan apakah sel-sel tersebut benar-benar merupakan sel leukemia.

Berdasarkan indikasi dari tes darah, maka pemeriksaan akan dilanjutkan ke tahap aspirasi dan biopsi sumsum tulang. Prosedur ini biasanya dilakukan pada tulang panggul bagian belakang menggunakan jarum khusus untuk mengambil sampel cairan dan jaringan sumsum tulang. Tujuannya adalah untuk mengamati morfologi (bentuk dan karakteristik) sel darah secara langsung di tempat asal pembentukannya. Jika jumlah limfoblas dalam sumsum tulang ditemukan lebih dari

20% dari total sel, maka diagnosis leukemia limfoblastik akut dapat ditegakkan. Di tahap ini, tidak semua pasien harus melanjutkan ke pemeriksaan berikutnya, kecuali jika ada tanda-tanda klinis yang mengindikasikan kemungkinan penyebaran penyakit, seperti sakit kepala terus-menerus, gangguan penglihatan, kejang, atau kekakuan leher. Gejala-gejala tersebut bisa menjadi tanda bahwa sel leukemik telah menyebar ke sistem saraf pusat.

Jika gejala neurologis muncul atau terdapat dugaan penyebaran ke sistem saraf pusat, maka dokter akan melakukan pungsi lumbal. Dalam prosedur ini, cairan serebrospinal (cairan otak dan tulang belakang) diambil dari ruang subarachnoid melalui sela tulang belakang bagian bawah. Cairan ini kemudian dianalisis untuk mendeteksi keberadaan sel-sel leukemia. Pemeriksaan ini penting untuk menentukan apakah pasien memerlukan kemoterapi intratekal, yakni pemberian obat langsung ke dalam cairan serebrospinal. Pemeriksaan pungsi lumbal tidak selalu dilakukan kepada semua pasien, namun akan menjadi bagian wajib dari penilaian apabila gejala neurologis muncul atau bila subtype ALL yang ditemukan memiliki kecenderungan tinggi menyebar ke sistem saraf pusat.


Setelah diagnosis ditegakkan dan jika diperlukan informasi lebih lanjut mengenai sifat genetik penyakit, maka akan dilakukan pemeriksaan genetik atau sitogenetik. Tes ini bertujuan untuk mengidentifikasi kelainan kromosom atau mutasi genetik spesifik yang berkaitan erat dengan ALL. Misalnya, adanya translokasi antara kromosom 9 dan 22 (Philadelphia chromosome) dapat memperburuk prognosis, sehingga pasien membutuhkan protokol pengobatan yang lebih intensif. Pemeriksaan ini sangat menentukan arah dan pilihan terapi yang akan

diberikan, termasuk intensitas dan jenis kemoterapi, serta kemungkinan indikasi untuk transplantasi sumsum tulang. Pemeriksaan genetik dilakukan hampir pada semua pasien, karena hasilnya sangat penting untuk menentukan perencanaan jangka panjang pengobatan.

Terakhir, jika dokter mencurigai bahwa leukemia telah menyebar ke organ lain di luar sistem darah dan sumsum tulang, maka pasien akan dirujuk untuk menjalani pemeriksaan pencitraan, seperti rontgen, ultrasonografi (USG), atau CT scan. Pemeriksaan ini dilakukan untuk mengevaluasi apakah terjadi pembesaran pada organ-organ seperti hati, limpa, ginjal, atau kelenjar getah bening, serta untuk memeriksa apakah terdapat massa atau infiltrasi leukemik di rongga dada atau otak. Indikasi pemeriksaan ini muncul berdasarkan gejala yang dirasakan pasien, seperti nyeri perut, pembengkakan, atau gejala neurologis berat. Informasi dari hasil pencitraan membantu dokter menentukan stadium penyakit dan memperkirakan sebaran sel kanker secara menyeluruh (Jiwani et al., 2023; Pittara, 2022; Scotti, 2005).

Dalam mengklasifikasikan sel darah, terdapat dua sistem utama yang umum digunakan, yaitu sistem klasifikasi FAB (*French-American-British*) dan sistem klasifikasi WHO (*World Health Organization*). Sistem FAB pertama kali diperkenalkan pada tahun 1976 dan banyak digunakan untuk mengidentifikasi subtype *Acute Lymphoblastic Leukemia* (ALL) berdasarkan karakteristik morfologis sel, seperti bentuk dan ukuran sel, struktur nukleus, serta tingkat keanekaragaman antar sel leukemia. Dalam klasifikasi ini, ALL dibagi menjadi tiga subtype: L1, L2, dan L3, yang masing-masing memiliki ciri khas morfologi

tersendiri (Ladines-Castro et al., 2016; Scotti, 2005). Sementara itu, klasifikasi WHO lebih modern dan bersifat multidimensional. Sistem ini tidak hanya mempertimbangkan ciri morfologi sel, tetapi juga memasukkan aspek genetik, imunofenotipik, serta molekuler dalam proses identifikasi. Beberapa fitur morfologis yang menjadi perhatian dalam sistem WHO meliputi struktur kromatin, jumlah dan bentuk nukleolus, kondisi membran inti, serta karakteristik sitoplasma (Shah et al., 2024).



Gambar 2. 1 Perbandingan morfologi sel normal dan sel blast A: Kromatin, B: Nukleus, dan C: Sitoplasma dan nukleus

Gambar 2.1 memperlihatkan secara rinci perbedaan morfologi antara limfosit normal dan sel blast pada pasien *Acute Lymphoblastic Leukemia* (ALL), yang terbagi dalam tiga bagian utama, yaitu bagian A, B, dan C. Pada bagian A, perbedaan yang ditonjolkan adalah tingkat kematangan kromatin di dalam inti sel. Limfosit normal menunjukkan kromatin yang matang, tampak padat, kasar, dan tersusun rapat. Tampilan ini menyerupai pasir kasar yang menumpuk rapat, menandakan bahwa sel tersebut telah mencapai tahap akhir diferensiasi dan tidak lagi aktif membelah. Sebaliknya, pada limfoblas yang ditemukan pada pasien ALL,

kromatin terlihat homogen, lebih halus, dan belum matang. Bentuk ini menyerupai permukaan lilin lunak yang merata dan mencerminkan bahwa sel masih berada dalam tahap awal perkembangan serta mengalami aktivitas pembelahan yang tinggi. Ciri ini menjadi indikator morfologis awal yang dapat dikenali dalam pemeriksaan mikroskopis.

Perbedaan lain ditunjukkan pada bagian B, yang menyoroti keberadaan nukleolus, yakni struktur kecil dalam inti sel yang berperan dalam sintesis ribosom. Pada limfosit normal, nukleolus biasanya tidak tampak atau sulit dikenali karena ukurannya kecil dan aktivitas sintetik sel yang rendah. Hal ini membuat inti sel tampak homogen tanpa titik terang mencolok. Sementara itu, pada limfoblas, nukleolus tampak lebih dari satu, berukuran besar, dan batasnya tidak jelas. Tampilan ini menyerupai pulau-pulau terang di dalam lautan gelap kromatin, yang menunjukkan bahwa sel sedang dalam fase proliferasi aktif. Keberadaan nukleolus yang menonjol menjadi salah satu penanda penting bahwa sel tersebut abnormal dan sedang mengalami aktivitas pembelahan berlebihan yang khas pada leukemia.

Sementara itu, bagian C menggambarkan perubahan pada struktur sitoplasma dan morfologi nukleus, yang juga menjadi ciri khas pada sel blast. Sitoplasma limfosit normal tampak sebagai pita sempit berwarna biru muda yang merata dan tidak menunjukkan struktur mencolok, menandakan aktivitas metabolik yang rendah. Berbeda dengan itu, sitoplasma pada sel blast terlihat tidak rata, lebih sempit, dan sering kali mengandung vakuola-vakuola kecil yang tampak seperti gelembung. Selain itu, terlihat adanya tonjolan sitoplasma (pseudopod) yang menyerupai lengan sel, suatu fitur yang jarang ditemukan pada limfosit normal.

Perbedaan morfologis juga sangat jelas pada bentuk nukleus. Jika limfosit normal memiliki nukleus yang bulat sempurna dengan permukaan halus, maka limfoblas menunjukkan bentuk nukleus yang tidak beraturan, dengan tepi yang berlekuk (*clefting*) dan terlipat (*konvolusi*), menyerupai balon yang penyok atau tertekan dari dalam. Keberadaan struktur-struktur ini memberikan bukti visual kuat mengenai ketidakteraturan dan sifat ganas dari sel leukemik (Shah et al., 2024).

2.3 MobileNetV2 dalam Tranfer Learning

Transfer learning adalah metode pembelajaran mesin yang memungkinkan penggunaan model yang telah dilatih pada suatu tugas untuk digunakan pada tugas lain yang serupa, tetapi berbeda (Dharmaraj, 2022). Keunggulan *transfer learning* terletak pada kemampuannya untuk mengurangi waktu yang diperlukan dalam melatih model baru dan menurunkan risiko terjadinya kesalahan (*error*) dalam proses pembelajaran, terutama ketika dataset yang digunakan relatif kecil (Roziqin, 2023).

Pada penelitian ini, *transfer learning* diaplikasikan menggunakan model MobileNetV2. MobileNetV2 adalah model yang sudah dilatih untuk klasifikasi gambar, merupakan versi kedua dari model MobileNet. Versi ini memiliki jumlah parameter lebih sedikit, membuatnya lebih cepat dan ringan dalam jaringan saraf dalam (Baran, 2023). Arsitektur ini menggunakan dua komponen utama, yaitu *linear bottleneck* dan *inverted residual*, yang meningkatkan efisiensi dalam menangkap serta mempertahankan fitur penting dari citra input.

Linear bottleneck adalah teknik yang digunakan untuk mengurangi dimensi ruang aktivasi, dengan mempertahankan informasi penting dari input. Hal ini

didasarkan pada asumsi bahwa fitur atau pola dari data dapat disematkan pada subruang berdimensi rendah, sehingga memungkinkan jaringan untuk memproses data secara lebih efisien tanpa kehilangan informasi yang penting. Sedangkan *inverted residuals* adalah desain blok yang mirip dengan blok residual, tetapi urutannya terbalik. Fitur awalnya diekspansi, diterapkan konvolusi *depthwise*, kemudian dimensi dikurangi melalui bottleneck. Pendekatan ini membantu menjaga efisiensi komputasi dan akurasi. Selain itu, arsitektur MobileNetV2 memanfaatkan *depthwise separable convolutions*, yang merupakan teknik konvolusi efisien dengan membagi operasi konvolusi menjadi dua tahap. Tahap pertama, *depthwise convolution*, menerapkan filter secara terpisah pada setiap saluran input, dan tahap kedua, *pointwise convolution* (konvolusi 1x1), menggabungkan hasil *depthwise* secara linier untuk membentuk fitur baru. Teknik ini memungkinkan pengurangan biaya komputasi hingga 8 sampai 9 kali lipat dibandingkan dengan konvolusi standar, tetapi tetap mempertahankan akurasi yang tinggi (Sandler et al., 2018).

MobileNetV2 dalam transfer learning memanfaatkan lapisan-lapisan awal yang sudah dilatih untuk mengenali fitur umum dan melakukan fine-tuning pada lapisan-lapisan akhir untuk menyesuaikan dengan tugas klasifikasi spesifik, seperti mendeteksi *Acute Lymphoblastic Leukemia* (ALL) dari citra mikroskopis sel darah putih. Proses ini dioptimalkan dengan penggunaan *Global Average Pooling* (GAP) untuk mereduksi fitur penting menjadi vektor berdimensi tetap, yang kemudian diproses untuk klasifikasi. Dengan metode ini, MobileNetV2 menawarkan efisiensi komputasi dan akurasi tinggi, terutama dalam konteks dataset yang terbatas.

2.4 Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan salah satu bentuk arsitektur dari *Artificial Neural Network* (ANN) yang paling sederhana. Arsitektur ini didasarkan pada konsep neuron buatan yang dikenal sebagai *Threshold Logic Unit* (TLU) atau *Linear Threshold Unit* (LTU) (Sharma et al., 2022). MLP terdiri dari tiga komponen utama, yaitu: lapisan input, lapisan tersembunyi (*hidden layers*), dan lapisan output. Dalam jaringan ini, setiap lapisan terdiri dari sekumpulan neuron yang saling terhubung melalui bobot dan bias yang menentukan kekuatan pengaruh antar neuron (Chan et al., 2023). Hubungan ini memungkinkan MLP untuk menangani tugas-tugas yang kompleks seperti klasifikasi dan regresi dengan memodelkan hubungan non-linear antar fitur.

MLP berfungsi dengan memproses data dari lapisan input menuju lapisan tersembunyi, di mana setiap neuron melakukan operasi matematika sederhana seperti mengalikan input dengan bobot, menambahkan bias, dan kemudian menerapkan fungsi aktivasi. Fungsi aktivasi ini, seperti sigmoid, bertujuan untuk memperkenalkan non-linearitas pada jaringan agar dapat mempelajari pola-pola yang kompleks. Lapisan tersembunyi berperan penting dalam memproses informasi secara berjenjang sehingga jaringan dapat mengenali pola yang semakin abstrak. Pada akhirnya, lapisan output memberikan prediksi akhir berdasarkan informasi yang diproses oleh lapisan tersembunyi. Pada tugas klasifikasi, prediksi ini seringkali berupa probabilitas yang kemudian dikonversi menjadi kelas tertentu.

Dalam proses pembelajarannya, MLP menggunakan mekanisme penting, yaitu *feedforward* dan *backpropagation*. Pada tahap *feedforward*, data dimasukkan

dari lapisan input dan diteruskan ke lapisan-lapisan berikutnya hingga mencapai lapisan output. Setiap neuron dalam lapisan tersembunyi menggabungkan input dari lapisan sebelumnya, menghitung bobot dan bias, lalu menerapkan fungsi aktivasi untuk menghasilkan output. Proses *feedforward* ini memastikan bahwa data mengalir ke depan melalui jaringan hingga menghasilkan prediksi akhir.

Proses *Backpropagation*, di sisi lain, adalah metode pembaruan bobot yang digunakan saat melatih MLP. Ketika prediksi jaringan dibandingkan dengan nilai target yang sebenarnya, dihitunglah kesalahan atau error. Kesalahan ini kemudian dipropagasi mundur melalui jaringan, dari lapisan output ke lapisan-lapisan sebelumnya, sambil menyesuaikan bobot dan bias neuron. Dengan cara ini, jaringan belajar memperbaiki dirinya sendiri dan meningkatkan akurasi prediksinya seiring waktu.

MLP menawarkan fleksibilitas dalam menyesuaikan jumlah lapisan tersembunyi dan jumlah neuron di setiap lapisan untuk mengatasi berbagai tugas pembelajaran yang kompleks. Namun, model ini juga memerlukan waktu dan sumber daya komputasi yang cukup besar, terutama pada dataset yang besar. Untuk meningkatkan kinerja, digunakan teknik optimasi seperti adam serta metode regularisasi untuk mencegah *overfitting*.


Secara keseluruhan, MLP adalah pendekatan yang efektif dalam pemodelan hubungan non-linear dan digunakan secara luas dalam berbagai aplikasi pembelajaran mesin, termasuk klasifikasi gambar, pengenalan pola, dan prediksi data.

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Alur Penelitian

Alur penelitian ini dirancang untuk mencapai tujuan utama, yaitu melakukan klasifikasi *Acute Lymphoblastic Leukemia* (ALL) menggunakan metode MobileNetV2 dan *Multilayer Perceptron* (MLP). Proses penelitian terdiri dari lima tahapan utama yang saling berkaitan, yaitu pengumpulan data, augmentasi, desain sistem, uji coba, dan hasil uji coba. Setiap tahapan dirancang secara sistematis untuk memastikan bahwa model yang dihasilkan memiliki kinerja yang optimal dalam tugas klasifikasi ALL. Kerangka kerja penelitian ini diilustrasikan pada Gambar 3.1.



Gambar 3.1 Alur Penelitian


3.2 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini bersumber dari data publik di platform Kaggle, yaitu dataset C-NMC-Leukemia (Gupta & Gupta, 2019). Dalam dataset ini, terdapat 15.135 citra mikroskopis sel darah putih yang diekstraksi dari

118 pasien yang didiagnosis dengan ALL. Setiap citra telah diberi label sesuai dengan jenis sel, yaitu sel darah putih normal dan sel blast leukemia, berdasarkan anotasi ahli onkologi untuk memastikan keakuratan data. Setiap citra pada dataset ini disimpan dalam format bitmap (.bmp) dan berukuran 450×450 piksel. Ukuran ini mempertahankan resolusi gambar yang memadai untuk mengidentifikasi fitur penting dari sel darah putih.

Dataset ini telah disusun dalam platform Kaggle ke dalam tiga folder utama, yaitu *training_data*, *validation_data*, dan *testing_data*. Citra sel pada dataset ini merupakan hasil pemisahan dari citra mikroskopis dan mencerminkan kondisi nyata, karena masih mengandung noise akibat pewarnaan serta ketidaksempurnaan pencahayaan. Meskipun demikian, sebagian besar gangguan tersebut telah dikoreksi selama proses pengambilan citra.

Gambar 3.2 menunjukkan contoh citra dari dataset ini, di mana citra (a) menggambarkan sel darah putih normal, sedangkan citra (b) menggambarkan sel blast leukemia.



Gambar 3.2 Citra (a) untuk sel normal dan citra (b) untuk sel blast leukemia

3.3 Augmentasi Data

Augmentasi data adalah teknik dalam pemrosesan citra yang bertujuan untuk meningkatkan variasi dataset tanpa menambah jumlah data asli. Teknik ini

membantu model dalam mengenali pola dengan lebih baik serta meningkatkan kemampuan generalisasi saat proses klasifikasi. Dalam penelitian ini, proses augmentasi menjadi penting karena terdapat ketidakseimbangan jumlah data antara kategori ALL dan Non-ALL, di mana jumlah citra pada kategori ALL lebih banyak dibandingkan dengan kategori Non-ALL. Ketidakseimbangan ini berpotensi menyebabkan model bias terhadap kelas mayoritas, sehingga diperlukan upaya untuk memperkuat representasi dari kelas minoritas. Oleh karena itu, augmentasi dilakukan khususnya pada kelas dengan jumlah data lebih sedikit untuk mencapai distribusi data yang lebih seimbang. Teknik augmentasi yang digunakan meliputi rotasi dan flipping, sebagaimana diterapkan dalam penelitian Ullah et al.,(2021).

3.3.1 Rotasi

Rotasi adalah transformasi geometris yang mengubah orientasi suatu citra dengan memutarnya sebesar sudut tertentu. Pada penelitian ini, citra diputar secara acak dalam rentang 90° berlawanan arah jarum jam untuk membuat model lebih robust terhadap berbagai sudut pengambilan gambar. Rumus transformasi rotasi untuk suatu piksel dalam citra ditunjukkan pada Rumus 2.1 dan 2.2 berikut:

$$x' = x \cdot \cos(\theta) - y \cdot \sin(\theta) \quad (2.1)$$

$$y' = x \cdot \sin(\theta) + y \cdot \cos(\theta) \quad (2.2)$$

Keterangan:

x, y = Koordinat asli piksel

x', y' = Koordinat baru setelah rotasi

θ = Besar sudut rotasi dalam radian

3.3.2 Flipping

Flipping adalah teknik augmentasi yang membalik citra untuk menambah

variasi data. Teknik ini diterapkan dalam dua arah:

- a. Flipping horizontal adalah proses membalik posisi citra terhadap sumbu Y (vertikal), sehingga bagian kiri citra menjadi di kanan dan sebaliknya. Proses flipping horizontal dilakukan menggunakan rumus 2.3:

$$B[x][y] = A[N - x][y] \quad (2.3)$$

Dalam rumus tersebut, A merupakan citra awal atau input, sedangkan B adalah citra hasil setelah dilakukan transformasi. Nilai N menyatakan lebar citra (jumlah kolom piksel), dan koordinat (x, y) merepresentasikan posisi piksel. Transformasi ini bekerja dengan mengganti setiap piksel pada posisi koordinat (x, y) di citra hasil (B) dengan piksel dari posisi $(N - x - 1, y)$ pada citra awal (A), sehingga tampak seperti pencerminan secara horizontal.


- b. Flipping vertikal adalah proses membalik citra terhadap sumbu X (horizontal), yang membuat bagian atas citra menjadi di bawah dan sebaliknya. Proses flipping horizontal dilakukan menggunakan rumus 2.4:

$$B[x][y] = A[x][M - y] \quad (2.4)$$

Dalam hal ini, A tetap merupakan citra input, dan B adalah citra hasil. Nilai M menunjukkan tinggi citra (jumlah baris piksel). Transformasi ini menggantikan piksel di posisi (x, y) pada citra B dengan piksel dari $(x, M - y - 1)$ pada citra A . Dengan demikian, seluruh isi citra seperti diputar secara vertikal.


3.4 Desain Sistem

Desain sistem yang diusulkan dalam penelitian ini terdiri dari empat komponen utama, yaitu augmentasi data, pra-pemrosesan (*preprocessing*), ekstraksi fitur, dan klasifikasi menggunakan model *Multilayer Perceptron* (MLP). Setiap komponen memiliki peran penting dalam menghasilkan model klasifikasi yang optimal. Gambaran menyeluruh mengenai desain sistem yang digunakan dalam penelitian ini ditampilkan pada Gambar 3.3.



Gambar 3. 3 Desain sistem

Selanjutnya, berdasarkan desain sistem tersebut, terdapat dua tahapan utama dalam implementasi sistem, yaitu proses pelatihan (*training*) dan pengujian (*testing*) model. Kedua proses ini bertujuan untuk membangun serta mengevaluasi performa model klasifikasi yang telah dirancang. Rangkaian proses training dan testing ditunjukkan pada Gambar 3.4.



Gambar 3.4 Skenario Training dan Testing

3.4.1 Pra-Pemrosesan Data

Pra-pemrosesan (*preprocessing*) data merupakan langkah penting dalam mempersiapkan dataset sebelum memasuki tahap pelatihan model. Dalam penelitian ini, beberapa langkah pra-pemrosesan diterapkan untuk memastikan bahwa data yang digunakan optimal dan siap untuk digunakan dalam model klasifikasi menggunakan transfer learning MobileNetV2.

Langkah pertama yang dilakukan adalah pengubahan ukuran citra (*resizing*). Setiap citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan dimensi input dari arsitektur model MobileNetV2. Pengubahan ukuran ini dilakukan dengan tetap menjaga aspek rasio asli dari citra, sehingga informasi penting dalam citra tidak hilang selama proses ini. Standarisasi ukuran gambar ini memastikan bahwa semua citra memiliki dimensi yang seragam, yang penting untuk menjaga konsistensi input ke dalam model.

Selanjutnya, dilakukan normalisasi dengan menyesuaikan nilai piksel langsung ke rentang $[-1, 1]$. Normalisasi ini dilakukan agar sesuai dengan format input yang diharapkan oleh model MobileNetV2, yang telah dilatih menggunakan citra dengan rentang nilai piksel $[-1, 1]$. Proses normalisasi dilakukan pada rumus 2.5 berikut:

$$Pixel\ Value = \frac{Pixel\ Value}{127.5} - 1 \quad (2.5)$$

Dengan menggunakan rumus tersebut, setiap pixel citra akan diubah dari rentang $[0, 255]$ menjadi $[-1, 1]$. Hal ini penting untuk memastikan bahwa input citra memiliki distribusi yang konsisten dengan distribusi data pada saat pelatihan awal model, sehingga performa ekstraksi fitur dari MobileNetV2 dapat optimal.

Selain itu, dataset yang digunakan dalam penelitian ini telah dilabeli oleh ahli onkologi. Data telah melalui proses segmentasi dari citra mikroskopis dan sangat representatif terhadap citra di dunia nyata karena mengandung noise pewarnaan dan kesalahan pencahayaan yang mencerminkan tantangan identifikasi dalam kondisi laboratorium klinis yang sebenarnya. Label *ground truth* dari dataset ini telah dianotasi oleh ahli onkologi, sehingga memastikan keakuratan dan validitas data yang digunakan.

3.4.2 Arsitektur *Transfer Learning* MobileNetV2

Pada tahap ini, MobileNetV2 yang telah dilatih sebelumnya pada dataset ImageNet digunakan sebagai alat untuk ekstraksi fitur dari citra input. Dalam konteks *transfer learning*, model MobileNetV2 dimanfaatkan untuk mengambil

fitur umum dari gambar mikroskopis sel darah putih. Tahapan ini dilakukan sebagai berikut:

1. Input Gambar

Dataset citra mikroskopis sel darah putih yang telah diolah dan diubah ukurannya menjadi $224 \times 224 \times 3$ dengan memiliki 3 kanal warna (RGB) dimasukkan ke dalam arsitektur MobileNetV2. Penyesuaian ukuran gambar ini dilakukan untuk memenuhi spesifikasi input MobileNetV2 dan menjaga konsistensi selama proses ekstraksi fitur.

2. Proses Ekstraksi Fitur

Setelah melalui proses pra-pemrosesan, citra diinputkan ke dalam model MobileNetV2 yang telah dilatih sebelumnya (pre-trained) pada dataset ImageNet. Pada tahap ini, citra akan diproses melalui serangkaian lapisan konvolusi, inverted residual blocks, dan batch normalization yang membentuk arsitektur MobileNetV2. Hasil dari proses ini adalah fitur representatif dari gambar, yaitu sekumpulan nilai numerik dalam bentuk vektor atau matriks berdimensi tinggi yang mengandung informasi penting dari gambar masukan. Meskipun paper asli MobileNetV2 (Sandler et al., 2018) tidak secara eksplisit menyebutkan jenis fitur visual yang diekstraksi, desain arsitektur inverted residuals dengan linear bottleneck memungkinkan model untuk mempertahankan kapasitas representasional yang efisien dan informatif. Dalam praktik umum CNN, termasuk MobileNetV2, fitur-fitur yang diekstraksi secara hierarkis mencerminkan karakteristik visual seperti tepi, tekstur, pola warna, dan bentuk objek (Kalathiya, n.d.; Zeiler & Fergus,

2014). Lapisan awal cenderung mengekstraksi tepi dan warna dasar, sedangkan lapisan yang lebih dalam mempelajari pola dan bentuk morfologi yang lebih kompleks. Lapisan awal cenderung mengekstraksi tepi dan warna dasar, sedangkan lapisan yang lebih dalam mempelajari pola dan bentuk morfologi yang lebih kompleks. Dengan demikian, fitur-fitur tersebut digunakan sebagai representasi komputasional dari citra asli yang kaya secara informasi dan penting untuk tugas klasifikasi.

Dalam konteks implementasi transfer learning, bagian klasifikasi akhir dari MobileNetV2 dihapus (atau tidak digunakan), sehingga output yang diambil adalah dari lapisan terakhir sebelum klasifikasi, seperti *Global Average Pooling* atau layer konvolusi terakhir. Vektor fitur inilah yang kemudian digunakan sebagai input ke model klasifikasi selanjutnya (dalam hal ini: MLP).

Adapun proses pembentukan fitur ini melalui beberapa komponen utama MobileNetV2, yaitu:

1. *Convolution Layer* (Conv2D)

Pada tahap awal, citra input akan melalui *Convolution Layer* (Conv2D), di mana lapisan ini bertugas untuk melakukan operasi konvolusi pada citra. Ketika citra melewati lapisan konvolusi, setiap filter yang ada di lapisan ini diaplikasikan secara bertahap ke seluruh bagian citra (input data) untuk menghasilkan *activation map* atau *feature map* dua dimensi (2D). Setiap filter pada *Convolution Layer* memiliki panjang, tinggi (dalam satuan piksel), dan kedalaman yang sesuai dengan jumlah channel pada input.

Filter ini akan bergerak melintasi citra (dengan pengaturan stride dan padding yang ditentukan), dan melakukan operasi perkalian titik (*dot product*) antara piksel pada gambar input dan nilai pada filter. Hasil dari proses konvolusi ini adalah *feature map* yang merepresentasikan fitur-fitur tertentu, seperti tepi horizontal/vertikal, garis diagonal, serta pola-pola tekstur sederhana. Lapisan konvolusi ini dioptimalkan menggunakan beberapa parameter, yaitu:

- a. Depth: Jumlah filter yang menentukan kedalaman output feature map.
- b. Stride: Langkah pergeseran filter saat melintasi gambar.
- c. Padding: Pengaturan padding untuk menyesuaikan ukuran output.

Ukuran feature map yang dihasilkan setelah operasi konvolusi dapat dihitung menggunakan Rumus 2.6 berikut:

$$Output\ Size = \frac{(W - N + 2 \times Padding)}{Stride} + 1 \quad (2.6)$$

Keterangan:

W	= Ukuran dari gambar input.
N	= Ukuran filter (kernel).
$Stride$	= Langkah pergeseran filter.
$Padding$	= jumlah padding yang diterapkan di sekitar gambar input.

2. *Depthwise Separable Convolutions*

Setelah tahap awal Conv2D, MobileNetV2 menggunakan *Depthwise Separable Convolutions* untuk meningkatkan efisiensi komputasi tanpa mengorbankan akurasi. Teknik ini menggantikan konvolusi standar dengan pendekatan yang lebih terfaktorasi, yaitu dengan memisahkan proses konvolusi menjadi dua tahap yang dilakukan oleh dua jenis lapisan

konvolusi yang berbeda yaitu *depthwise convolution* dan *pointwise convolution*. Teknik ini mengurangi jumlah operasi komputasi secara signifikan dibandingkan konvolusi standar.

a. *Depthwise Convolution*

Pada tahap ini, setiap channel pada citra diproses secara terpisah, sehingga fitur yang diekstraksi lebih fokus pada pola-pola spesifik dari masing-masing channel warna. Misalnya, pada gambar RGB, *depthwise convolution* akan mengekstrak fitur seperti perbedaan intensitas warna merah, hijau, dan biru pada struktur sel darah. Berbeda dengan konvolusi standar, yang menggabungkan semua channel dalam satu operasi konvolusi, *depthwise convolution* hanya berfokus pada hubungan spasial di dalam setiap channel, tanpa menggabungkan informasi antar-channel. Operasi ini lebih ringan secara komputasi karena hanya melibatkan konvolusi per channel, bukan seluruh volume input.


b. *Pointwise Convolution* (1×1 Convolution)

Setelah proses *depthwise convolution* selesai, langkah berikutnya dalam *depthwise separable convolution* adalah *pointwise convolution*, yang juga dikenal sebagai konvolusi 1×1 . Pada tahap ini, model menerapkan filter berukuran 1×1 ke setiap posisi piksel dari output *depthwise* untuk menggabungkan informasi antar-channel. Berbeda dengan *depthwise convolution* yang fokus pada hubungan spasial dalam satu channel, *pointwise convolution*

bertugas untuk menyatukan dan mengolah informasi dari seluruh channel yang telah diproses sebelumnya.

Melalui kombinasi linear antar-channel tersebut, model dapat membentuk representasi fitur yang lebih kompleks dan bersifat global. Hal ini memungkinkan jaringan untuk mengenali pola-pola gabungan yang tidak bisa ditangkap hanya dari satu channel saja. Sebagai contoh, fitur-fitur seperti bentuk keseluruhan inti sel, kontur sel yang melengkung, atau distribusi warna dalam struktur sel darah dapat diidentifikasi dengan lebih akurat melalui tahap ini. Dengan demikian, *pointwise convolution* berperan penting dalam menyempurnakan proses ekstraksi fitur, karena membantu model memahami struktur visual yang lebih tinggi dan mendalam dari citra mikroskopis.

Gambar 3.5 di bawah ini menunjukkan proses *depthwise separable convolutions*, di mana *depthwise convolution* (di sebelah kiri) pertama kali menerapkan konvolusi pada setiap channel secara independent, dan kemudian *pointwise convolution* (di sebelah kanan) menggabungkan informasi antar-channel melalui konvolusi 1×1 untuk menghasilkan fitur yang lebih kompleks.



Gambar 3.5 Depthwise Separable Convolutions
(Sumber gambar: www.researchgate.net)

3. *Inverted Residual Block* dengan Bottleneck

Setelah *tahap depthwise separable convolutions*, MobileNetV2 melanjutkan proses ekstraksi fitur dengan menggunakan *Inverted Residuals Blocks* dengan *Bottlenecks*. Desain blok ini merupakan inovasi yang dirancang untuk meningkatkan efisiensi komputasi dan memori tanpa mengorbankan akurasi model, terutama saat menangani gambar mikroskopis yang memerlukan deteksi fitur halus. Setiap *inverted residual block* pada MobileNetV2 terdiri dari beberapa lapisan yang terdiri dari lapisan input, beberapa lapisan *bottleneck*, dan lapisan ekspansi atau projection. Lapisan *bottleneck* bertugas untuk memampatkan data fitur dengan mengurangi jumlah channel, sehingga proses komputasi menjadi lebih ringan. Selanjutnya, lapisan ekspansi memperluas kembali representasi fitur tersebut melalui transformasi nonlinier agar jaringan dapat membentuk fitur-fitur yang lebih kompleks dan mendalam. Proses ini membantu model dalam mengenali pola-pola halus dalam citra biologis,

seperti bentuk dan tekstur sel yang menjadi indikator penting dalam diagnosis.

Selama proses ini, model mengekstraksi berbagai fitur penting yang meliputi hubungan spasial antar bagian sel, seperti keterkaitan antara inti dan sitoplasma; kerapatan serta distribusi warna di dalam inti sel yang dapat mengindikasikan adanya kelainan; dan variasi morfologi antar jenis sel yang mencakup ukuran, bentuk, hingga pola distribusinya dalam citra. Fitur-fitur tersebut menjadi komponen krusial dalam proses klasifikasi karena mencerminkan karakteristik khas dari sel normal maupun sel yang mengindikasikan penyakit seperti leukemia.

Salah satu ciri khas dari blok ini adalah adanya shortcut connection yang langsung menghubungkan input dan output pada bagian bottleneck. Tidak seperti residual block konvensional yang menyambungkan shortcut pada bagian akhir blok, pendekatan ini hanya menghubungkan informasi pada lapisan bottleneck dengan asumsi bahwa informasi penting telah cukup terwakili dalam tahap tersebut. Strategi ini terbukti efektif dalam menjaga aliran informasi ke seluruh jaringan serta membantu proses pelatihan dengan mencegah permasalahan vanishing gradient, khususnya pada jaringan yang lebih dalam.


Secara komputasi, blok ini memang menambahkan sedikit *overhead*, terutama pada lapisan konvolusi 1×1 untuk ekspansi. Untuk blok dengan ukuran $h \times w$, faktor ekspansi t , dan kernel k , dengan d' sebagai jumlah

channel input dan d'' sebagai jumlah channel output, jumlah operasi multiply-add dapat dihitung menggunakan Rumus 2.7 berikut:

$$h \cdot w \cdot d' \cdot t (d' + k^2 + d'') \quad (2.7)$$

Meskipun ada tambahan komputasi karena konvolusi 1×1 , efisiensi keseluruhan tetap terjaga karena ukuran dimensi input dan output yang lebih kecil. Inovasi ini membuat MobileNetV2 lebih hemat sumber daya, menjadikannya pilihan ideal untuk aplikasi dengan keterbatasan daya komputasi, seperti pada perangkat seluler.

Gambar 3.6 dibawah ini menunjukkan visualisasi dari *inverted residual block* dengan *bottleneck*, memperlihatkan alur informasi melalui shortcut connection serta lapisan ekspansi dan proyeksi, yang berperan dalam menjaga efisiensi komputasi.



Gambar 3.6 (a) Residual block dan (b) Inverted residual blocks

Setelah melalui seluruh proses ekstraksi fitur dalam arsitektur MobileNetV2, citra mikroskopis yang telah diproses akan diubah menjadi sebuah vektor fitur berdimensi tetap. Pada tahap akhir dari jaringan, digunakan mekanisme global average pooling untuk mereduksi dimensi spasial dari feature map menjadi

satu nilai rata-rata per channel, sehingga menghasilkan vektor fitur berdimensi 1280. Vektor ini berisi nilai-nilai numerik (real-valued) yang merepresentasikan intensitas berbagai fitur visual yang telah dipelajari oleh model selama proses pelatihan. Fitur-fitur yang termuat dalam vektor ini mencerminkan informasi visual penting dari citra asli, seperti keberadaan dan intensitas tepi atau garis yang menunjukkan batas struktur sel, variasi tekstur yang dapat mengindikasikan perbedaan kepadatan sel, serta bentuk dan ukuran inti sel yang menjadi indikator morfologis penting dalam identifikasi kelainan hematologi. Fitur-fitur ini terbentuk sebagai hasil dari representasi nonlinier yang dikonstruksi oleh jaringan dari berbagai lapisan konvolusi dan blok residual selama proses ekstraksi.

Dalam konteks citra mikroskopis darah, khususnya untuk klasifikasi sel leukemia seperti *Acute Lymphoblastic Leukemia* (ALL), fitur-fitur ini memungkinkan model untuk menangkap perbedaan halus dalam morfologi sel, seperti ukuran dan bentuk inti, rasio inti-sitoplasma, serta distribusi kromatin. Meskipun granula umumnya ditemukan pada jenis sel lain seperti neutrofil atau eosinofil, dalam konteks ALL, fitur seperti granularitas tidak selalu dominan, sehingga fokus utama lebih pada morfologi inti dan kepadatan sel.

Tabel 3.1 menyajikan arsitektur lengkap MobileNetV2, mencakup ukuran input-output, operator, faktor ekspansi, jumlah channel, pengulangan blok, dan stride, untuk memberikan gambaran efisien proses ekstraksi fitur tiap lapisan.

Tabel 3.1 Arsitektur MobileNetV2

Input	Operator	t	c	n	s
$224^2 \times 3$	Conv2d	-	32	1	2
$112^2 \times 32$	Bottleneck	1	16	1	1
$112^2 \times 16$	Bottleneck	6	24	2	2
$56^2 \times 24$	Bottleneck	6	32	3	2
$28^2 \times 32$	Bottleneck	6	64	4	2

Input	Operator	t	c	n	s
$14^2 \times 64$	Bottleneck	6	96	3	1
$14^2 \times 96$	Bottleneck	6	160	3	2
$7^2 \times 160$	Bottleneck	6	320	1	1
$7^2 \times 320$	Conv2d 1×1	-	1280	1	1
$7^2 \times 1280$	GAP (<i>Global Average Pooling</i>)	-	-	-	-
$1 \times 1 \times 1280$	Output Fitur	-	-	-	-

3. Penambahan Top Layer

Setelah fitur diekstraksi melalui MobileNetV2, ditambahkan lapisan atas berupa *Global Average Pooling* (GAP) untuk meratakan fitur spasial menjadi satu nilai per kanal. Dengan pendekatan ini, model mampu menangkap informasi yang merangkum setiap fitur spasial tanpa menambah parameter yang berlebihan. GAP dirancang untuk menyederhanakan output spasial menjadi satu vektor fitur yang lebih ringkas dan efisien, mengurangi kemungkinan overfitting dan mempermudah tahap klasifikasi akhir.

a. *Global Average Pooling* (GAP)

Pada lapisan GAP, setiap kanal dari fitur yang telah diekstraksi oleh MobileNetV2 diratakan dengan cara menghitung nilai rata-rata dari setiap kanal. Proses ini dapat dinyatakan secara matematis melalui rumus 2.8 berikut:

$$g_c(f_j) = \frac{1}{NN} \sum_{i=1}^{NN} f_{ij} \quad (2.8)$$

Keterangan:

$g_c(f_j)$ = Nilai rata-rata untuk kanal fitur j .

NN = Jumlah total elemen dalam kanal fitur (jumlah piksel dalam fitur spasial).

f_{ij} = Nilai fitur pada elemen i dalam kanal fitur f_j .

Rumus ini menghitung rata-rata dari semua nilai elemen dalam satu kanal fitur, menghasilkan satu nilai per kanal. Nilai ini kemudian digunakan sebagai representasi keseluruhan fitur kanal tersebut. Proses GAP ini menghasilkan vektor fitur yang merangkum informasi penting dari seluruh lokasi spasial pada setiap kanal, sehingga mengurangi jumlah parameter dan membantu mencegah *overfitting* pada model. Pendekatan GAP telah digunakan secara luas dalam jaringan saraf konvolusi karena sifatnya yang efisien dan kemampuannya untuk menyederhanakan fitur spasial menjadi representasi yang lebih ringkas (Santoso et al., 2024).

3.4.3 Arsitektur *Multilayer Perceptron* (MLP)


Setelah fitur-fitur penting dari citra mikroskopis sel darah putih diekstraksi menggunakan arsitektur MobileNetV2 dan diringkas melalui lapisan *Global Average Pooling* (GAP), tahap akhir adalah klasifikasi menggunakan *Multilayer Perceptron* (MLP). MLP digunakan untuk memetakan vektor fitur hasil dari GAP menjadi kelas target yang diinginkan, yaitu *Acute Lymphoblastic Leukemia* (ALL) atau Non-ALL.

Model MLP yang digunakan terdiri dari beberapa lapisan, yaitu satu lapisan input, dua lapisan tersembunyi (*hidden layers*), dan satu lapisan output. Proses pelatihan model MLP ini melibatkan dua tahapan utama: *Feedforward propagation* dan *backpropagation*, yang bertujuan untuk meminimalkan error pada prediksi model. Prosesnya dijelaskan sebagai berikut:

1. Arsitektur *Multilayer Perceptron* (MLP)

Arsitektur MLP yang digunakan pada penelitian ini dapat dilihat pada Gambar 3.7, yang terdiri dari beberapa neuron di tiap lapisan:

- Lapisan Input: Menerima input dari vektor fitur.
- Lapisan Tersembunyi (*Hidden Layers*): Berfungsi untuk mempelajari pola non-linear dalam data melalui kombinasi bobot dan bias di tiap neuron.
- Lapisan Output: Menghasilkan nilai prediksi berdasarkan output dari lapisan tersembunyi (*hidden layers*).



Gambar 3. 7 Arsitektur *Multilayer Perceptron* (MLP)

2. Tahapan *Feedforward propagation*

Proses *feedforward propagation* pada jaringan *Multilayer Perceptron* (MLP) dimulai dari lapisan input, di mana setiap neuron menerima nilai fitur dari data masukan. Nilai-nilai ini kemudian dikalikan dengan bobot (w) yang terhubung ke neuron-neuron pada lapisan

tersembunyi (*hidden layer*), lalu ditambahkan dengan nilai bias (b). Hasil dari kombinasi linier ini kemudian diproses menggunakan fungsi aktivasi untuk menghasilkan output dari setiap neuron. Output dari satu lapisan akan menjadi input bagi lapisan berikutnya. Proses ini berlangsung secara berurutan dari lapisan tersembunyi pertama hingga lapisan tersembunyi terakhir, dan akhirnya mencapai lapisan output yang menghasilkan prediksi akhir dari model.

Adapun sebelum proses ini dilakukan, data hasil ekstraksi fitur dari model *transfer learning* MobileNetV2 yang berada pada rentang nilai 0 hingga 5.037258625 terlebih dahulu dinormalisasi. Hal ini penting untuk menyamakan skala antar fitur agar proses pembelajaran model lebih stabil dan efisien. Normalisasi dilakukan menggunakan metode *Min-Max Scaling*, yang secara matematis dirumuskan sebagai berikut:


$$X_{scaled} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) \times (b - a) + a \quad (2.9)$$

Keterangan:

X = Nilai asli fitur
 X_{min} dan X_{max} = Nilai minimum dan maksimum dari fitur
 a dan b = Batas bawah dan atas rentang skala baru (0 dan 1)
 X_{scaled} = Nilai fitur setelah di normalisasi

Fungsi aktivasi memegang peran penting dalam memperkenalkan non-linearitas pada jaringan. Pada lapisan tersembunyi, digunakan fungsi aktivasi *Rectified Linear Unit* (ReLU) yang memiliki keunggulan dalam mempercepat konvergensi proses pelatihan serta mengatasi masalah *vanishing gradient* yang kerap terjadi pada jaringan dengan banyak lapisan (Rizki Firdaus Mulya et al., 2023). Fungsi ReLU bekerja dengan

memberikan keluaran sebesar nol untuk input bernilai negatif, dan mempertahankan input apa adanya untuk nilai positif, sehingga memungkinkan model untuk belajar representasi yang lebih kompleks dan efisien (Youn & Hong, 2024). Meskipun data hasil ekstraksi fitur dari MobileNetV2 tidak mengandung nilai negatif, hasil transformasi linier dari input dan bobot dalam jaringan saraf tetap dapat menghasilkan nilai negatif. Oleh karena itu, ReLU tetap relevan karena berperan sebagai filter yang mengaktifkan hanya neuron dengan sinyal positif, membantu jaringan lebih fokus belajar dari informasi yang dianggap penting. Visualisasi bentuk fungsi aktivasi ReLU ditampilkan pada Gambar 3.8, yang memperlihatkan karakteristik linier untuk nilai positif dan nol untuk nilai negatif, sebagaimana umum digunakan pada lapisan tersembunyi jaringan saraf.



Gambar 3. 8 Grafik Fungsi aktivasi Relu
(Sumber gambar: [geeksforgeeks.org](https://www.geeksforgeeks.org))

Fungsi aktivasi ReLU didefinisikan dalam rumus 2.9 sebagai berikut:

$$ReLU(x) = \max(0, x) \quad (2.10)$$

Keterangan:

$ReLU(x)$ = Fungsi aktivasi RelU untuk input x

$\max(0, x)$ = Memilih nilai maksimum antara 0 dan x

Tahapan feedforward propagation dimulai dari pengolahan sinyal pada lapisan input ke hidden layer 1. Pada tahap ini, setiap nilai input dikalikan dengan bobot yang terhubung ke setiap neuron di hidden layer 1, kemudian dijumlahkan bersama nilai bias, dan hasilnya diproses melalui fungsi aktivasi ReLU. Formulasi proses ini disajikan pada Rumus 2.10 berikut:

$$V_e = Relu \left(\sum_{a=1}^A X_a \cdot W_{a,e} + P_e \right) \quad (2.11)$$

Keterangan:

- X_a = Nilai input dari neuron ke- a
- $W_{a,e}$ = Bobot antara neuron input X_a dan neuron hidden layer 1 V_e
- P_e = Bias pada neuron V_e
- A = Jumlah total neuron pada lapisan input

Selanjutnya, output dari hidden layer 1 menjadi input bagi hidden layer 2. Proses ini dilakukan dengan cara yang serupa: setiap output dari hidden layer 1 dikalikan dengan bobot yang menghubungkannya ke neuron di hidden layer 2, dijumlahkan bersama bias, lalu diproses menggunakan fungsi aktivasi ReLU. Formulasi proses ini disajikan dalam Rumus 2.10 berikut:


$$Z_i = Relu \left(\sum_{e=1}^E V_e \cdot U_{e,i} + Q_i \right) \quad (2.12)$$

Keterangan:

- $U_{e,i}$ = Bobot antara neuron V_e dan neuron hidden layer 2 Z_i
- Q_i = Bias pada neuron Z_i
- V_e = Output dari neuron ke- e pada hidden layer 1
- E = Jumlah total neuron pada hidden layer 1

Pada lapisan output, digunakan fungsi aktivasi sigmoid yang secara

matematis menghasilkan nilai keluaran di antara 0 dan 1. Fungsi ini sangat sesuai untuk tugas klasifikasi biner, seperti pada penelitian ini yang bertujuan mengklasifikasikan pasien ke dalam kategori ALL atau Non-ALL. Fungsi sigmoid memberikan kombinasi karakteristik linier, non-linier (melengkung), dan konstan yang menjadikannya fleksibel terhadap variasi data. Selain itu, fungsi sigmoid mampu mengubah output jaringan menjadi bentuk probabilitas yang dapat diinterpretasikan sebagai tingkat keyakinan model terhadap suatu kelas, misalnya 0.92 berarti 92% yakin terhadap kelas ALL. Hal ini menjadikannya sangat cocok ketika digunakan bersama dengan label one-hot encoding dan fungsi loss seperti cross-entropy, yang banyak diterapkan pada klasifikasi biner. Fungsi sigmoid memberikan kombinasi karakteristik linier, non-linier (melengkung), dan konstan yang menjadikannya fleksibel terhadap variasi data. Grafik dari fungsi aktivasi sigmoid ditunjukkan pada Gambar 3.9.



Gambar 3. 9 Grafik fungsi aktivasi sigmoid
(Sumber gambar: geeksforgeeks.org)

Fungsi aktivasi sigmoid didefinisikan dalam Rumus 2.12 sebagai berikut:

$$\text{sigmoid}(x) = \frac{1}{(1 + e^{-x})} \quad (2.13)$$

Keterangan:

$\text{sigmoid}(x)$ = Fungsi aktivasi sigmoid untuk input x

e = Bilangan Euler (2,71828)

e^{-x} = Eksponensial dari $-x$

Proses feedforward dilanjutkan dari hidden layer 2 ke lapisan output.

Setiap neuron pada hidden layer 2 (Z_i) dikalikan dengan bobot yang terhubung ke neuron output ($O_{i,m}$), kemudian hasil penjumlahan dari semua neuron ditambahkan dengan bias (S_m) dan diproses melalui fungsi aktivasi sigmoid. Rumusnya disajikan dalam Rumus 2.13 sebagai berikut:

$$H_m = \text{Sigmoid} \left(\sum_{i=1}^I Z_i \cdot O_{i,m} + S_m \right) \quad (2.14)$$

Keterangan:

$O_{i,m}$ = Bobot yang menghubungkan neuron Z_i ke neuron output H_m

S_m = Bias pada neuron output H_m

Z_i = Output dari neuron ke- i di hidden Layer 2

H_m = Output dari neuron ke- m pada lapisan output setelah fungsi aktivasi sigmoid diterapkan

I = Jumlah neuron pada hidden layer 2

Nilai H_m yang diperoleh merupakan hasil akhir dari proses feedforward propagation dan menjadi prediksi model untuk masing-masing kelas. Nilai ini selanjutnya akan digunakan dalam tahap backpropagation untuk menghitung error dan memperbarui bobot dalam proses pelatihan jaringan.

3. Tahapan *Backpropagation*

Setelah seluruh proses feedforward propagation selesai dan model menghasilkan output prediksi dalam bentuk nilai probabilitas pada masing-masing neuron output (H_m dan H_n), maka langkah berikutnya adalah

backpropagation. Tahapan ini bertujuan untuk meminimalkan perbedaan (error) antara hasil prediksi model dan target sebenarnya (Y_m dan Y_n).

Backpropagation bekerja dengan menghitung gradien dari fungsi loss terhadap bobot dan bias pada setiap lapisan, kemudian memperbaruinya menggunakan algoritma gradient descent. Perubahan dilakukan dari lapisan output menuju ke lapisan-lapisan sebelumnya (hidden layers).

Karena lapisan output menggunakan fungsi aktivasi sigmoid, maka error pada neuron output H_m dihitung menggunakan turunan dari fungsi sigmoid sebagaimana ditunjukkan dalam Rumus 2.14 berikut:

$$\delta_m = (Y_m - H_m) \cdot H_m \cdot (1 - H_m) \quad (2.15)$$

Keterangan:

δ_m = Nilai error (delta) pada neuron output H_m
 Y_m = Nilai target (label sebenarnya) untuk neuron H_m
 H_m = Nilai output dari neuron H_m setelah aktivasi sigmoid

Setelah δ_m diperoleh, maka bobot $O_{i,m}$ dan bias S_m diperbarui berdasarkan gradien error, sebagaimana ditunjukkan dalam Rumus 2.15 dan 2.16 berikut:

$$\Delta O_{i,m} = \alpha \cdot \delta_m \cdot Z_i \quad (2.16)$$

$$\Delta S_m = \alpha \cdot \delta_m \quad (2.17)$$

Keterangan:

$\Delta O_{i,m}$ = Perubahan bobot antara neuron Z_i (hidden layer 2) dan neuron output H_m
 α = Learning rate
 Z_i = Output dari neuron ke- i pada hidden layer 2
 ΔS_m = Perubahan bias pada neuron output H_m

Setelah dilakukan perhitungan error pada lapisan output, langkah selanjutnya adalah menghitung error pada hidden layer 2 berdasarkan

kontribusinya terhadap error di output layer. Maka, error pada setiap neuron di hidden layer ke-2 dihitung dengan menjumlahkan kontribusi seluruh neuron output, sebagaimana ditunjukkan dalam Rumus 2.17 berikut:

$$\delta_i = \sum_{m=1}^M \delta_m \cdot O_{i,m} \cdot Z'_i \quad (2.18)$$

Keterangan:

- δ_i = Error pada neuron ke- i di hidden layer 2
- Z'_i = Error pada neuron output ke- m
- $O_{i,m}$ = Bobot antara neuron Z_i di hidden layer 2 dan neuron output H_m
- Z'_i = Turunan dari fungsi aktivasi terhadap input Z_i

Perubahan bobot dan bias dari hidden layer 1 ke hidden layer 2 kemudian dihitung menggunakan Rumus 2.18 dan 2.19 berikut:

$$\Delta U_{e,i} = \alpha \cdot \delta_i \cdot V_e \quad (2.19)$$

$$\Delta Q_i = \alpha \cdot \delta_i \quad (2.20)$$

Keterangan:

- $\Delta U_{e,i}$ = Perubahan bobot antara neuron ke- e di hidden layer 1 dan neuron ke- i di hidden layer 2
- ΔQ_i = Perubahan bias pada neuron Z_i di hidden layer 2
- V_e = Output dari neuron ke- e di hidden layer 1

Selanjutnya, error pada hidden layer 1 dihitung berdasarkan propagasi error dari hidden layer 2. Rumusnya 2.20 sebagai berikut:

$$\delta_e = \sum_{i=1}^I \delta_i \cdot U_{e,i} \cdot V'_e \quad (2.21)$$

Keterangan:

- δ_e = Error pada neuron ke- e di hidden layer 1
- V'_e = Turunan fungsi aktivasi ReLU terhadap input V_e
- $U_{e,i}$ = Bobot dari neuron ke- e di hidden layer 1 ke neuron ke- i di hidden layer 2

Bobot dan bias dari input layer ke hidden layer pertama diperbarui menggunakan Rumus 2.21 dan 2.22 berikut:

$$\Delta W_{a,e} = \alpha \cdot \delta_e \cdot X_a \quad (2.22)$$

$$\Delta P_e = \alpha \cdot \delta_e \quad (2.23)$$

Keterangan:

$\Delta W_{a,e}$ = Perubahan bobot dari input neuron X_a ke neuron ke-e di hidden layer 1

ΔP_e = Perubahan bias pada neuron ke-e di hidden layer 1

X_a = Nilai input pada neuron ke-a di input layer

Setelah seluruh nilai error, bobot, dan bias dihitung pada setiap lapisan, langkah selanjutnya adalah melakukan pembaruan parameter. Adapun rumus yang digunakan untuk memperbarui bobot dan bias pada setiap lapisan ditunjukkan dalam Rumus 2.23 dan 2.24 berikut:

$$w_{baru} = w_{lama} + \Delta W \quad (2.24)$$

$$b_{baru} = b_{lama} + \Delta b \quad (2.25)$$

Keterangan:

w_{baru}, b_{baru} = Bobot dan bias setelah pembaruan

w_{lama}, b_{lama} = Bobot sebelum update

$\Delta b, \Delta w$ = Nilai koreksi bobot dan bias yang dihitung dari proses backpropagation

Nilai output dari neuron di lapisan output berada dalam rentang [0, 1] karena menggunakan fungsi aktivasi sigmoid. Dalam konteks klasifikasi biner, keputusan klasifikasi diambil berdasarkan probabilitas tertinggi, sebagaimana ditunjukkan dalam Rumus 2.25 dan 2.26 berikut:

$$Y = \arg \max (H) \quad (2.26)$$

$$\arg \max (H_i) = \begin{cases} 1 & \text{jika } H_m > H_n \\ 0 & \text{jika } H_n \geq H_m \end{cases} \quad (2.27)$$


Keterangan:

Y = Output kelas prediksi (1 atau 0)

H_m = Nilai skor atau probabilitas untuk kelas 1

H_n = Nilai skor atau probabilitas untuk kelas 0

Untuk mempermudah pemahaman terhadap alur proses klasifikasi yang dilakukan pada penelitian ini, Gambar 3.10 menyajikan diagram alir (flowchart) dari keseluruhan tahapan mulai dari pemuatan data fitur hingga proses pelatihan dan penyimpanan model MLP.



Gambar 3. 10 Flowchart Pelatihan Model MLP

3.5 Prosedur Uji Coba Penelitian

3.5.1 Skenario Penelitian

Penelitian ini dilakukan melalui beberapa skenario eksperimental yang dirancang untuk mengevaluasi pengaruh arsitektur MLP dan skema pembagian data terhadap performa klasifikasi citra. Seluruh proses diawali dengan augmentasi dan pra-pemrosesan dataset, dilanjutkan dengan ekstraksi fitur menggunakan MobileNetV2, dan diakhiri dengan klasifikasi menggunakan Multilayer Perceptron (MLP). Adapun skenario yang diterapkan dalam penelitian ini meliputi:

a. Skenario 1: Variasi Jumlah Hidden Layer

Skenario ini bertujuan untuk menganalisis pengaruh jumlah lapisan tersembunyi terhadap akurasi klasifikasi. Tiga konfigurasi yang diuji adalah MLP dengan satu, dua, dan tiga hidden layer. Setiap konfigurasi menggunakan jumlah neuron dan parameter pelatihan yang sama agar hasil perbandingan lebih objektif.

b. Skenario 2: Variasi Jumlah Neuron pada Hidden Layer

Untuk mengevaluasi kapasitas representasi model, dilakukan uji coba dengan jumlah neuron yang berbeda pada setiap hidden layer, yaitu 32, 64, 128, dan 256 neuron. Skenario ini bertujuan untuk mengamati bagaimana perubahan kapasitas neuron memengaruhi performa klasifikasi.

c. Skenario 3: Variasi Rasio Pembagian Data Latih dan Data Uji

Penelitian juga mengkaji pengaruh jumlah data latih terhadap kualitas pembelajaran model. Oleh karena itu, dilakukan uji coba dengan tiga skema pembagian data: 70% data latih dan 30% data uji, 80%:20%, serta 90%:10%. Hasil dari masing-masing skema dibandingkan untuk melihat sejauh mana rasio pembagian data berdampak terhadap performa klasifikasi.

Ketiga skenario tersebut saling mendukung dalam mengeksplorasi konfigurasi terbaik dari kombinasi transfer learning dan jaringan saraf tiruan, sehingga hasil akhir yang diperoleh dapat dijadikan sebagai dasar pemilihan parameter yang optimal dalam tugas klasifikasi citra mikroskopis.

3.5.2 Persiapan Data

Dataset yang digunakan dalam penelitian ini bersumber dari platform *Kaggle*, yang terdiri atas citra mikroskopis sel darah putih. Setiap citra telah dilabeli ke dalam dua kategori, yaitu ALL (Acute Lymphoblastic Leukemia) dan Hem (sel darah sehat). Proses pelabelan dilakukan oleh tenaga medis profesional, sehingga validitas dan akurasi dapat dipercaya.

Sebelum digunakan dalam proses pelatihan dan pengujian model, dataset ini melalui beberapa tahap persiapan sebagai berikut:

1. Augmentasi

Untuk meningkatkan keragaman data dan memperkaya representasi fitur, dilakukan augmentasi pada citra, yang mencakup:

- a. Rotasi citra
- b. Flipping horizontal
- c. Flipping vertical

Augmentasi ini dilakukan guna mengurangi risiko overfitting dan meningkatkan generalisasi model terhadap variasi bentuk dan orientasi citra.

2. Pra-pemrosesan (*Preprocessing*)

Setelah augmentasi, citra-citra tersebut diproses lebih lanjut melalui dua tahapan utama:

- a. Resizing yaitu seluruh citra diubah ukurannya menjadi 224 x 224 piksel agar sesuai dengan dimensi input standar pada arsitektur MobileNetV2.

- b. Normalisasi yaitu nilai piksel setiap citra dinormalisasi ke dalam rentang $[-1, 1]$, menyesuaikan dengan format input yang digunakan MobileNetV2 saat dilatih pada dataset ImageNet.

3. Pembagian Dataset

Sebagai bagian dari eksperimen, dilakukan beberapa skema pembagian dataset untuk mengevaluasi pengaruh jumlah data pelatihan terhadap performa klasifikasi. Skema yang digunakan adalah:

- a. Data pelatihan (70%) – Data pengujian (30%)
- b. Data pelatihan (80%) – Data pengujian (20%)
- c. Data pelatihan (90%) – Data pengujian (10%)

3.5.3 Proses Pelatihan dan Pengujian

Pada tahap ini, dilakukan proses pelatihan dan pengujian model klasifikasi citra sel darah putih untuk mendeteksi Acute Lymphoblastic Leukemia (ALL). Pendekatan yang digunakan adalah transfer learning, di mana MobileNetV2 dimanfaatkan sebagai feature extractor dan Multilayer Perceptron (MLP) digunakan sebagai classifier.

1. Pelatihan Model

Model dilatih menggunakan arsitektur MobileNetV2 yang telah dipra-latih pada dataset ImageNet. Seluruh bobot pada MobileNetV2 dibekukan (freeze) sehingga tidak diperbarui selama proses pelatihan. Model ini hanya digunakan untuk mengekstraksi fitur dari citra input.

Setelah fitur diekstraksi dari citra menggunakan MobileNetV2, dilakukan proses Global Average Pooling (GAP) untuk mereduksi dimensi

output feature map dan menghasilkan representasi fitur dalam bentuk vektor satu dimensi. Vektor hasil GAP inilah yang kemudian menjadi input bagi arsitektur *Multilayer Perceptron* (MLP).

Selanjutnya, MLP mempelajari pola dari vektor fitur tersebut untuk mengklasifikasikan citra ke dalam dua kelas, yaitu ALL dan Non-ALL. Model dilatih selama 100 epoch dengan learning rate sebesar 0.001, yang dipilih berdasarkan hasil terbaik dari penelitian sebelumnya (Pushpalatha et al., 2024; Santoso et al., 2024). Optimizer yang digunakan adalah Adam, yaitu algoritma optimasi dengan laju pembelajaran adaptif yang memanfaatkan gradien fungsi kerugian untuk memperbarui parameter model (Batool & Byun, 2023). Untuk fungsi kerugian, digunakan Binary Cross-Entropy Loss yang efektif mengukur perbedaan antara distribusi probabilitas prediksi dan target, sehingga sangat sesuai untuk tugas klasifikasi dua kelas (De Oliveira & Dantas, 2021; Pushpalatha et al., 2024).

Selama proses pelatihan, model menghasilkan prediksi probabilitas terhadap masing-masing kelas. Fungsi `argmax` digunakan untuk menentukan label akhir berdasarkan nilai probabilitas tertinggi dari output neuron.

2. Pengujian Model

Setelah proses pelatihan selesai, model diuji menggunakan data uji yang telah dipisahkan sebelumnya dari data pelatihan. Pengujian dilakukan dengan memuat parameter bobot dan bias hasil pelatihan, tanpa dilakukan proses pembaruan parameter ulang. Data uji diproses melalui langkah yang

sama: ekstraksi fitur menggunakan MobileNetV2, proses GAP, kemudian klasifikasi dengan MLP.

Hasil prediksi pada data uji dibandingkan dengan label sebenarnya untuk menilai performa model. Evaluasi performa model dilakukan dengan membandingkan hasil prediksi dengan label aktual menggunakan confusion matrix, serta menghitung metrik evaluasi berikut:

1. Akurasi

Akurasi adalah metrik yang menunjukkan persentase prediksi benar dari total data uji, dihitung dengan rumus 2.27 berikut:

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.28)$$

2. Presisi

Presisi adalah metrik yang menunjukkan seberapa banyak prediksi positif yang benar-benar relevan atau tepat. Presisi dihitung dengan rumus 2.28 berikut:

$$\text{Presisi} = \frac{TP}{TP + FP} \quad (2.29)$$

3. Sensitivitas (*Recall*)

Sensitivitas (*Recall*) menunjukkan seberapa baik model mendeteksi kasus positif sebenarnya, dihitung dengan rumus 2.29 berikut:

$$\text{Sensitivitas} = \frac{TP}{TP + FN} \quad (2.30)$$

4. F1-Score

F1-Score adalah metrik yang menggabungkan presisi dan sensitivitas, memberikan gambaran seimbang antara keduanya. Rumusnya ditunjukkan pada Rumus 2.30 berikut:

$$F - 1 \text{ Score} = 2 \times \frac{\text{Presisi} \times \text{Sensitivitas}}{\text{Presisi} + \text{Sensitivitas}} \quad (2.31)$$

Struktur dari confusion matrix yang digunakan dalam penelitian ini dapat dilihat pada Tabel 3.2.

Tabel 3.2 Hasil Klasifikasi Berdasarkan Kelas Negatif dan Positif

<i>Actual Class</i>		<i>Assigned Class</i>	
		<i>Positive</i>	<i>Negative</i>
	<i>Positive</i>	TP	FN
	<i>Negative</i>	FP	TN

Confusion matrix dibangun menggunakan data pengujian setelah model dilatih dan menjadi dasar perhitungan metrik evaluasi seperti akurasi, presisi, sensitivitas, dan F1-Score.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil pengujian dan pembahasan metode klasifikasi citra *Acute Lymphoblastic Leukemia* (ALL) menggunakan *transfer learning* MobileNetV2 sebagai ekstraktor fitur dan *Multilayer Perceptron* (MLP) sebagai klasifikator.

4.1 Skenario Uji Coba

Pada penelitian ini, uji coba dilakukan menggunakan dataset citra mikroskopis sel darah putih yang terdiri dari dua kelas, yaitu sel ALL (*Acute Lymphoblastic Leukemia*) dan sel Hem (sel sehat). Dataset ini diambil dari platform Kaggle dan memiliki total sekitar 12.161 citra. Masing-masing citra telah dilabeli oleh tenaga medis profesional sehingga validitas label dapat diandalkan dalam konteks penelitian klasifikasi medis. Jumlah data dari kedua kelas disusun seimbang untuk menghindari dominasi salah satu kelas yang dapat mengakibatkan bias dalam pembelajaran model. Sebagai bagian dari skenario eksperimen, dataset ini dibagi menjadi data pelatihan dan data pengujian dengan rasio yang bervariasi. Pembagian ini dijelaskan secara rinci pada Tabel 4.1.

Tabel 4.1 Rasio Pembagian Data Untuk Penelitian

Rasio	Jumlah Data	
	Training	Testing
70:30	8.962	3.199
80:20	10.028	2.133
90:10	11.118	1.069

Sebelum dilakukan pelatihan, data melalui serangkaian proses augmentasi dan pra-pemrosesan. Augmentasi dilakukan untuk meningkatkan keragaman data

dan memperkaya pola visual yang tersedia. Beberapa teknik augmentasi yang diterapkan meliputi rotasi, flipping horizontal, dan flipping vertikal. Augmentasi diterapkan secara merata pada citra dari kedua kelas. Hasil dari proses ini memperluas jumlah total data yang digunakan dalam penelitian dan dijabarkan lebih lanjut pada Tabel 4.2.

Tabel 4.2 Jumlah Data Hasil Augmentasi pada Kelas Hem

Rasio	Jumlah Data	
	Sebelum Augmentasi	Setelah Augmentasi
70:30	2.372	3.872
80:20	2.711	4.211
90:10	3.050	4.550

Setelah augmentasi, citra diproses melalui tahap pra-pemrosesan. Seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan standar input pada arsitektur MobileNetV2. Selanjutnya, nilai piksel dinormalisasi ke dalam rentang $[-1, 1]$ untuk menyesuaikan dengan format input MobileNetV2 yang telah dilatih pada dataset *ImageNet*.

Proses ekstraksi fitur dilakukan dengan memanfaatkan arsitektur MobileNetV2 sebagai *feature extractor*. Model ini digunakan dalam kondisi bobot dibekukan (*freeze*), artinya tidak terjadi pembaruan parameter selama pelatihan. MobileNetV2 mengolah citra hingga menghasilkan *feature map* berdimensi 7×7×1280. Untuk mereduksi dimensi dan menghasilkan representasi fitur yang ringkas, digunakan teknik *Global Average Pooling* (GAP) yang menghitung rata-rata nilai pada tiap *channel*. Hasil dari GAP adalah vektor satu dimensi dengan panjang 1280. Vektor ini berisi informasi deskriptif tentang tekstur, bentuk morfologi sel, dan pola-pola visual yang membedakan sel ALL dengan sel Hem.

Vektor hasil GAP inilah yang menjadi input bagi arsitektur *Multilayer Perceptron* (MLP) dalam tahap klasifikasi.

Klasifikasi dilakukan dengan menggunakan MLP yang dirancang untuk mempelajari pola dari vektor fitur tersebut dan memetakan ke dalam dua kelas output. Penelitian ini dirancang dalam beberapa skenario untuk mengevaluasi konfigurasi model terbaik. Terdapat tiga skenario utama: pertama, variasi jumlah *hidden layer*, yaitu satu, dua, dan tiga *layer* tersembunyi. Kedua, variasi jumlah neuron dalam setiap *hidden layer*, yang diuji pada konfigurasi 32, 64, 128, dan 256 neuron. Ketiga, variasi rasio pembagian data pelatihan dan pengujian, yakni 70:30, 80:20, dan 90:10. Setiap skenario dijalankan dengan parameter pelatihan yang konsisten, termasuk penggunaan fungsi aktivasi ReLU pada setiap *hidden layer*. Output layer terdiri dari dua neuron dengan fungsi aktivasi Sigmoid untuk menghasilkan probabilitas klasifikasi pada masing-masing kelas. Prediksi akhir ditentukan dengan menerapkan fungsi *argmax* untuk memilih kelas dengan nilai probabilitas tertinggi.

Selama pelatihan, model dijalankan sebanyak 100 epoch dengan menggunakan learning rate sebesar 0.001 dan optimizer Adam. Fungsi kerugian yang digunakan adalah *Binary Cross-Entropy Loss*, yang sesuai untuk tugas klasifikasi biner. Model mempelajari representasi dari data pelatihan dan menghasilkan parameter berupa bobot dan bias. Setelah pelatihan selesai, bobot dan bias tersebut disimpan dan digunakan untuk menguji data uji tanpa dilakukan pelatihan ulang. Proses pengujian dilakukan dengan alur yang sama seperti

pelatihan, yaitu melalui ekstraksi fitur menggunakan MobileNetV2, GAP, dan klasifikasi oleh MLP.

Kinerja model dievaluasi menggunakan confusion matrix sebagai dasar perhitungan metrik evaluasi, yakni akurasi, presisi, sensitivitas (recall), dan F1-score. Confusion matrix mencerminkan distribusi prediksi model dibandingkan dengan label aktual pada data uji, sementara metrik-metrik tersebut digunakan untuk mengukur seberapa tepat dan akurat model dalam mendeteksi keberadaan sel leukemia. Melalui skenario ini, penelitian berusaha menemukan konfigurasi optimal dari kombinasi arsitektur MLP dan rasio pembagian data, yang dapat digunakan sebagai acuan dalam sistem deteksi leukemia berbasis citra mikroskopis.

4.2 Hasil Uji Coba

Dataset yang telah melalui proses ekstraksi fitur dengan MobileNetV2 selanjutnya diklasifikasikan menggunakan model *Multilayer Perceptron* (MLP) untuk membedakan dua kelas, yaitu *Acute Lymphoblastic Leukemia* (ALL) dan Non-ALL (HEM). Pengujian dilakukan dengan beberapa variasi konfigurasi, seperti jumlah hidden layer, jumlah neuron per layer, serta rasio pembagian data pelatihan dan pengujian. Hasil dari berbagai skenario pengujian disajikan pada bagian berikut.

4.2.1 Skenario 1: Variasi Jumlah Hidden Layer

Pada skenario pertama, pengujian difokuskan untuk memahami pengaruh jumlah hidden layer dalam arsitektur *Multilayer Perceptron* (MLP) terhadap performa klasifikasi citra. *Hidden layer* merupakan lapisan tersembunyi di antara input dan output yang bertugas mempelajari pola kompleks dari data. Dalam

eksperimen ini, digunakan tiga variasi arsitektur MLP, yaitu dengan satu, dua, dan tiga *hidden layer*. Tujuannya adalah untuk mengetahui apakah menambahkan lebih banyak hidden layer dapat meningkatkan akurasi dan kualitas klasifikasi. Agar hasil pengujian lebih adil dan objektif, jumlah neuron pada setiap layer serta rasio pembagian data latih dan uji dibuat tetap sama pada ketiga arsitektur. Dengan begitu, satu-satunya perbedaan terletak pada jumlah hidden layer, sehingga pengaruhnya terhadap performa model dapat diamati secara langsung.


Model dengan satu *hidden layer* menunjukkan performa yang cukup baik dan stabil pada sebagian besar rasio pembagian data. Akurasi tertinggi yang dicapai adalah 86.00% pada rasio 70:30 dengan konfigurasi 256 neuron, sedangkan F1-score tertinggi mencapai 85.23% pada konfigurasi dan rasio yang sama. Hal ini menunjukkan bahwa meskipun arsitekturnya sederhana, model dengan satu *hidden layer* sudah mampu mengenali pola penting dalam data untuk klasifikasi dua kelas ALL dan HEM. Namun, pada beberapa konfigurasi dengan jumlah neuron yang lebih rendah, Model ini memiliki keterbatasan dalam memproses dan memetakan fitur yang kompleks dari hasil ekstraksi MobileNetV2, yang terlihat dari fluktuasi performanya pada beberapa konfigurasi.

Pada arsitektur dengan *dua hidden layer*, model menunjukkan peningkatan performa secara umum. Nilai akurasi tertinggi yang tercatat adalah 86.16% pada rasio 90:10 dengan 256 neuron, sedangkan F1-score tertinggi mencapai 85.66% pada konfigurasi yang sama. Dibandingkan dengan satu *hidden layer*, model ini menunjukkan kemampuan yang lebih baik dalam menangkap pola non-linear dan kompleks, terutama ketika didukung oleh jumlah neuron yang cukup besar.

Performa dua *hidden layer* juga terlihat konsisten di berbagai rasio, menandakan bahwa model ini memiliki stabilitas yang baik untuk klasifikasi citra.

Sementara itu, pada model dengan tiga *hidden layer*, hasilnya bervariasi. Akurasi tertinggi diperoleh sebesar 86.21% pada rasio 70:30 dengan 128 neuron, dan F1-score terbaik sebesar 85.50% pada konfigurasi yang sama. Meskipun terlihat menjanjikan, model dengan tiga *hidden layer* cenderung lebih sensitif terhadap perubahan jumlah neuron dan rasio data. Pada beberapa konfigurasi, terutama dengan jumlah neuron yang terlalu besar, performanya justru menurun. Hal ini mengindikasikan bahwa model mengalami kesulitan dalam konvergensi, terutama ketika data pelatihan tidak cukup besar untuk mendukung kompleksitas arsitektur.

Berdasarkan hasil pengujian tersebut, dapat disimpulkan bahwa model dengan dua *hidden layer* memberikan performa paling optimal dan seimbang dalam hal akurasi dan F1-score. Arsitektur ini mampu mengenali pola secara lebih mendalam dibandingkan satu *hidden layer*, namun tidak terlalu kompleks seperti tiga *hidden layer* yang cenderung menghasilkan performa yang tidak stabil akibat meningkatnya beban komputasi dan kebutuhan data yang lebih besar. Oleh karena itu, dua *hidden layer* dapat dianggap sebagai konfigurasi terbaik untuk model klasifikasi MLP pada penelitian ini. Performa masing-masing arsitektur *hidden layer* dapat dilihat pada Gambar 4.1.



Gambar 4. 1 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Jumlah Hidden Layer

4.2.2 Skenario 2: Variasi Jumlah Neuron pada Hidden Layer

Dalam skenario kedua ini, eksperimen difokuskan pada bagaimana jumlah neuron pada setiap *hidden layer* memengaruhi performa klasifikasi citra leukemia. Jumlah neuron yang diuji adalah 32, 64, 128, dan 256 neuron, yang diterapkan secara konsisten pada setiap *hidden layer* dalam arsitektur MLP. Evaluasi dilakukan dengan mengukur dua metrik utama: akurasi sebagai ukuran keseluruhan prediksi yang benar, dan F1-score sebagai indikator keseimbangan antara presisi dan recall. Hasilnya disajikan dalam bentuk tabel serta divisualisasikan dalam grafik.

Pada konfigurasi 32 neuron, model MLP menunjukkan performa paling rendah dengan akurasi 84,46% dan F1-score 83,47%. Hasil ini mengindikasikan bahwa model belum cukup mampu menangkap keragaman pola dalam data. Jumlah neuron yang terlalu sedikit membatasi kapasitas jaringan dalam mempelajari representasi fitur yang kompleks, sehingga model kesulitan membedakan antara

citra ALL dan Non-ALL secara akurat. Hal ini dapat dianalogikan seperti manusia yang mencoba menghafal pola rumit dengan memori yang terbatas, hasilnya tentu tidak optimal.


Ketika jumlah neuron ditingkatkan menjadi 64 neuron, performa model mengalami peningkatan yang signifikan. Akurasi melonjak ke angka 85,93%, dan F1-score turut naik menjadi 85,12%. Peningkatan ini menunjukkan bahwa model mulai memiliki kapasitas yang cukup untuk merepresentasikan fitur penting dari hasil ekstraksi MobileNetV2. Dengan jumlah neuron yang lebih besar, jaringan mampu membangun hubungan yang lebih kompleks antar fitur, sehingga menghasilkan prediksi yang lebih tepat dan seimbang.

Konfigurasi 128 neuron menjadi titik di mana model mencapai performa terbaik dari sisi akurasi, yakni 86,21%, dengan F1-score sebesar 85,50%. Ini menandakan bahwa model telah berada dalam kapasitas optimal untuk mengenali pola yang relevan tanpa berlebihan. Jumlah neuron ini memberikan keseimbangan antara kompleksitas dan efisiensi, menjadikannya sangat cocok untuk dataset ini. Pada titik ini, model sudah sangat mahir dalam mengidentifikasi karakteristik dari masing-masing kelas dengan akurasi yang tinggi dan distribusi prediksi yang cukup seimbang.

Menariknya, saat jumlah neuron ditambah menjadi 256 neuron, nilai akurasi sedikit turun menjadi 86,16%, namun F1-score justru meningkat menjadi 85,66%, yang merupakan nilai tertinggi pada metrik ini. Hal ini menunjukkan bahwa meskipun model tidak lebih akurat dalam hal jumlah prediksi benar secara keseluruhan, ia menjadi lebih baik dalam menjaga keseimbangan antara prediksi

kelas positif dan negatif. Ini sangat penting dalam konteks medis, di mana prediksi yang seimbang antar kelas lebih krusial daripada akurasi semata, agar tidak terjadi bias terhadap satu jenis diagnosis.

Berdasarkan analisis terhadap seluruh hasil, dapat disimpulkan bahwa konfigurasi dengan 128 neuron adalah yang paling optimal, karena mampu memberikan akurasi tertinggi dengan F1-score yang juga sangat tinggi dan stabil. Sementara konfigurasi dengan 256 neuron juga menunjukkan performa sangat baik dalam hal F1-score, namun tidak memberikan peningkatan berarti pada akurasi. Oleh karena itu, dalam konteks efisiensi dan efektivitas model, jumlah neuron sebanyak 128 dapat direkomendasikan sebagai pilihan terbaik untuk arsitektur MLP dalam penelitian ini. Visualisasi perbandingan performa terhadap jumlah neuron dapat dilihat pada Gambar 4.2.



Gambar 4. 2 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Jumlah Neuron

4.2.3 Skenario 3: Variasi Rasio Pembagian Data Latih dan Data Uji

Skenario ketiga mengkaji pengaruh rasio pembagian data latih dan data uji terhadap performa klasifikasi model MLP. Rasio ini menjadi aspek penting karena berkaitan langsung dengan seberapa banyak data yang digunakan untuk melatih model dan seberapa banyak data yang digunakan untuk mengujinya. Tiga konfigurasi rasio yang diuji adalah 70:30, 80:20, dan 90:10, yang masing-masing merepresentasikan persentase data pelatihan dan pengujian dari keseluruhan dataset.


Pada rasio 70:30, model memperoleh akurasi tertinggi yaitu 86,21% dan F1-score sebesar 85,50%. Ini menunjukkan bahwa porsi data uji sebesar 30% sudah cukup memberikan gambaran generalisasi model yang baik. Di sisi lain, data latih yang cukup besar (70%) tetap mampu membekali model dengan pola-pola penting dalam data. Rasio ini menjadi pilihan yang seimbang, baik dalam aspek pelatihan maupun evaluasi, sehingga performa yang dihasilkan tergolong stabil dan andal.

Rasio 80:20 justru menunjukkan penurunan performa yang cukup signifikan dibandingkan dua rasio lainnya. Akurasi hanya mencapai 84,25%, dan F1-score juga turun menjadi 83,24%. Penurunan ini menunjukkan bahwa meskipun data latih lebih banyak, berkurangnya variasi data uji membuat proses evaluasi menjadi kurang optimal. Hal ini memperlihatkan bahwa menambah porsi data latih tidak selalu menjamin peningkatan kinerja jika tidak diimbangi dengan data uji yang cukup untuk mengevaluasi secara menyeluruh.

Sementara itu, Rasio 90:10 menghasilkan F1-score tertinggi yaitu 85,66%, dengan akurasi yang juga tinggi yaitu 86,16%. Hasil ini menunjukkan bahwa model

dapat mengenali kedua kelas dengan cukup seimbang. Namun, porsi data uji yang hanya 10% dapat menjadi terlalu sempit untuk mengukur performa secara umum, karena risiko ketidakwakilan data menjadi lebih besar. Oleh karena itu, meskipun nilai metrik tinggi, keandalan evaluasi pada rasio ini perlu diperhatikan dengan hati-hati.

Dari ketiga rasio yang diuji, dapat disimpulkan bahwa rasio 70:30 merupakan konfigurasi terbaik. Rasio ini tidak hanya menghasilkan akurasi tertinggi, tetapi juga memberikan keseimbangan yang baik antara proses pembelajaran dan pengujian model. Dengan data uji yang lebih luas, hasil evaluasi menjadi lebih representatif, menjadikan model lebih stabil dan terpercaya untuk diterapkan pada data nyata. Visualisasi perbandingan performa model berdasarkan rasio pembagian data ini dapat dilihat pada Gambar 4.3, yang menggambarkan perbedaan akurasi dan F1-score secara jelas untuk masing-masing konfigurasi.



Gambar 4. 3 Grafik Perbandingan Akurasi dan F1-Score Berdasarkan Rasio Pembagian Data

Dari grafik tersebut, terlihat bahwa rasio 70:30 menghasilkan akurasi dan F1-score yang paling seimbang, sedangkan rasio 90:10 memang menunjukkan metrik yang tinggi, namun harus dipertimbangkan dengan hati-hati karena jumlah data uji yang terlalu sedikit dapat mengurangi keandalan evaluasi secara keseluruhan.

Lebih dari sekadar membahas angka dan performa model, penelitian ini juga memuat nilai-nilai moral dan spiritual yang relevan dengan semangat keilmuan dalam Islam. Dalam konteks klasifikasi Acute Lymphoblastic Leukemia (ALL), penelitian ini tidak hanya dilakukan sebagai bentuk pengembangan teknologi dan capaian akademik, tetapi juga dilandasi semangat untuk memberi manfaat nyata bagi umat manusia. Upaya ini mencerminkan pentingnya ilmu pengetahuan sebagai sarana untuk saling membantu dalam kebaikan, khususnya dalam dunia kesehatan yang sangat erat kaitannya dengan kualitas hidup manusia.

Ajaran Islam sangat menekankan pentingnya kolaborasi dan tolong-menolong dalam hal-hal yang membawa manfaat. Hal ini tercermin dalam firman Allah SWT:

وَتَعَاوُنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوُنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ

“Dan tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan pelanggaran.” (QS. Al-Ma'idah: 2).

Menurut *Tafsir Tahlili*, ayat ini mengajarkan agar umat Islam senantiasa bekerja sama dalam melakukan perbuatan baik dan menghindari tolong-menolong dalam perbuatan dosa. Pesan moral dari ayat ini adalah Ayat ini memberikan pesan mendalam bahwa kolaborasi yang dibangun atas dasar kebaikan dan ketakwaan

adalah bagian dari nilai-nilai mulia dalam Islam. Sebaliknya, kolaborasi yang dilakukan tanpa mempertimbangkan etika dan dampaknya terhadap orang lain perlu dihindari. Dalam penelitian ini, kolaborasi ditunjukkan melalui sinergi antara peneliti, tenaga medis, dan masyarakat dalam mengembangkan sistem klasifikasi yang lebih akurat, efisien, dan dapat membantu proses diagnosis penyakit secara lebih cepat (Kementerian Agama Republik Indonesia, n.d.-b).

Teknologi yang digunakan dalam penelitian ini, seperti MobileNetV2 sebagai ekstraktor fitur dan Multilayer Perceptron (MLP) sebagai klasifikator, bukan ditujukan untuk menggantikan tenaga medis, tetapi untuk mendukung mereka dalam pengambilan keputusan. Model ini berperan sebagai alat bantu yang dapat mempercepat dan meningkatkan akurasi dalam proses klasifikasi, khususnya pada kasus leukemia yang membutuhkan diagnosis cepat dan tepat. Ini merupakan salah satu bentuk nyata implementasi tolong-menolong dalam kebajikan melalui pengembangan teknologi yang aplikatif dan berlandaskan integritas ilmiah.

Dengan demikian, penelitian ini tidak hanya berkontribusi pada aspek akademik, tetapi juga menjadi bentuk nyata dari pengamalan nilai-nilai Islam dalam pemanfaatan ilmu pengetahuan. Prinsip kolaborasi dalam kebaikan tercermin melalui proses pengumpulan data, pengolahan, analisis, hingga penyampaian hasil yang tidak hanya informatif, tetapi juga bertujuan untuk membawa kemaslahatan bersama. Harapannya, hasil dari penelitian ini dapat menjadi bagian dari ikhtiar kolektif dalam memperbaiki layanan kesehatan dan menolong sesama, sesuai dengan nilai-nilai Islam yang menempatkan ilmu sebagai cahaya dan amal sebagai bentuk nyata dari kebermanfaatan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini menunjukkan bahwa penerapan transfer learning menggunakan MobileNetV2 sebagai metode ekstraksi fitur dan *Multilayer Perceptron* (MLP) sebagai model klasifikasi memberikan performa yang cukup efektif dalam mendeteksi penyakit *Acute Lymphoblastic Leukemia* (ALL). Pengujian dilakukan dengan mengevaluasi pengaruh rasio pembagian data latih dan uji, jumlah neuron, serta jumlah *hidden layer* terhadap performa klasifikasi. Hasil terbaik diperoleh pada konfigurasi tiga *hidden layer*, rasio data 70:30, dan jumlah neuron sebanyak 128, dengan capaian akurasi sebesar 86,21%, presisi 86,61%, recall 86,21%, dan F1-score 85,50%. Hasil tersebut mengindikasikan bahwa kombinasi MobileNetV2 dan MLP mampu membentuk model klasifikasi citra yang andal dengan beban komputasi yang relatif ringan. Selain itu, variasi jumlah neuron, hidden layer, dan rasio data terbukti berpengaruh terhadap kualitas performa klasifikasi.

5.2 Saran

Dalam pengembangan sistem klasifikasi *Acute Lymphoblastic Leukemia* (ALL) dan Non-ALL, terdapat beberapa aspek yang dapat diperbaiki dan dikembangkan lebih lanjut untuk meningkatkan akurasi serta kinerja deteksi. Berdasarkan hasil penelitian ini, penulis memberikan beberapa saran sebagai berikut:

1. Pada tahap pra-pemrosesan, disarankan untuk menambahkan variasi augmentasi data, seperti perubahan ukuran yang beragam dan augmentasi warna. Langkah ini bertujuan untuk meningkatkan keragaman data latih sehingga model memiliki kemampuan generalisasi yang lebih baik terhadap variasi citra.
2. Pengujian sistem pada perangkat dengan spesifikasi rendah perlu dilakukan, mengingat model ini memiliki beban komputasi yang ringan dan berpotensi untuk diimplementasikan pada perangkat medis dengan keterbatasan sumber daya.

DAFTAR PUSTAKA

- Azzahra, J. F., Sumarti, H., & Kusuma, H. H. (2022). Klasifikasi Kasus COVID-19 dan SARS Berbasis Ciri Tekstur Menggunakan Metode Multi-Layer Perceptron. *Jurnal Fisika*, 12(1), 16–27. <https://doi.org/10.15294/jf.v12i1.35685>
- Baran, K. (2023). *Smartphone thermal imaging for stressed people classification using CNN+MobileNetV2*. <https://doi.org/https://doi.org/10.1016/j.procs.2023.10.242>
- Batool, A., & Byun, Y. C. (2023). Lightweight EfficientNetB3 Model Based on Depthwise Separable Convolutions for Enhancing Classification of Leukemia White Blood Cell Images. *IEEE Access*, 11(April), 37203–37215. <https://doi.org/10.1109/ACCESS.2023.3266511>
- Chan, K. Y., Abu-Salih, B., Qaddoura, R., Al-Zoubi, A. M., Palade, V., Pham, D., Ser, J. Del, & Muhammad, K. (2023). *Deep neural networks in the cloud: Review, applications, challenges and research directions*. <https://doi.org/https://doi.org/10.1016/j.neucom.2023.126327>
- Das, P. K., Jadoun, P., & Meher, S. (2020). Detection and Classification of Acute Lymphocytic Leukemia. *Proceedings of 2020 IEEE-HYDCON International Conference on Engineering in the 4th Industrial Revolution, HYDCON 2020*. <https://doi.org/10.1109/HYDCON48903.2020.9242745>
- De Oliveira, J. E. M., & Dantas, D. O. (2021). Classification of normal versus leukemic cells with data augmentation and convolutional neural networks. *VISIGRAPP 2021 - Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 4(Visigrapp), 685–692. <https://doi.org/10.5220/0010257406850692>
- Dharmaraj. (2022). *Image classification and prediction using transfer learning*. <https://medium.com/@draj0718/image-classification-and-prediction-using-transfer-learning-3cf2c736589d>
- Dou, S., Wang, L., Fan, D., Miao, L., Yan, J., & He, H. (2023). Classification of Citrus Huanglongbing Degree Based on CBAM-MobileNetV2 and Transfer Learning. *Sensors*, 23(12), 1–18. <https://doi.org/10.3390/s23125587>
- Gupta, A., & Gupta, R. (2019). *ALL Challenge dataset of ISBI 2019 [Data set]*. The Cancer Imaging Archive. <https://www.kaggle.com/datasets/andrewmvd/leukemia-classification?resource=download-directory>
- Jiwani, N., Gupta, K., Pau, G., & Alibakhshikenari, M. (2023). Pattern Recognition of Acute Lymphoblastic Leukemia (ALL) Using Computational Deep Learning. *IEEE Access*, 11(February), 29541–29553. <https://doi.org/10.1109/ACCESS.2023.3260065>
- Kalathiya, M. (n.d.). *Feature extraction using pre-trained models for image classification*. Medium.
- Karnadi, B., & Handhayani, T. (2024). *Klasifikasi Jenis Buah dengan Menggunakan Metode*. 35–42. <https://doi.org/10.30864/eksplora.v14i1.1067>
- Kementerian Agama Republik Indonesia. (n.d.-a). *Tafsir Surah Al-Maidah Ayat*

100. Kementerian Agama RI. Retrieved March 20, 2025, from <https://quran.kemenag.go.id/quran/per-ayat/surah/49?from=1&to=18>
- Kementerian Agama Republik Indonesia. (n.d.-b). *Tafsir Surah Al-Maidah Ayat 2*. Retrieved May 14, 2025, from <https://quran.kemenag.go.id/quran/per-ayat/surah/5?from=2&to=120>
- KUSUMA, J., HAYADI, B. H., WANAYUMINI, W., & ROSNELLY, R. (2022). Komparasi Metode Multi Layer Perceptron (MLP) dan Support Vector Machine (SVM) untuk Klasifikasi Kanker Payudara. *MIND Journal*, 7(1), 51–60. <https://doi.org/10.26760/mindjournal.v7i1.51-60>
- Kusuma, J., Rubianto, Rosnelly, R., Hartono, & Hayadi, B. H. (2023). Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron. *Journal of Applied Computer Science and Technology*, 4(1), 1–6. <https://doi.org/10.52158/jacost.v4i1.484>
- Ladines-Castro, W., Barragán-Ibañez, G., Luna-Pérez, M. A., Santoyo-Sánchez, A., Collazo-Jaloma, J., Mendoza-García, E., & Ramos-Peñafiel, C. O. (2016). Morphology of leukaemias. *Revista Médica Del Hospital General de México*, 79(2), 107–113. <https://doi.org/10.1016/j.hgmx.2015.06.007>
- Mondal, C., Hasan, M. K., Ahmad, M., Awal, M. A., Jawad, M. T., Dutta, A., Islam, M. R., & Moni, M. A. (2021). Ensemble of Convolutional Neural Networks to diagnose Acute Lymphoblastic Leukemia from microscopic images. *Informatics in Medicine Unlocked*, 27, 100794. <https://doi.org/10.1016/j.imu.2021.100794>
- Musleh, S., Islam, M. T., Alam, M. T., Househ, M., Shah, Z., & Alam, T. (2022). ALLD: Acute Lymphoblastic Leukemia Detector. *Studies in Health Technology and Informatics*, 289, 77–80. <https://doi.org/10.3233/SHTI210863>
- National Institute of Technology (Raipur, I. D. of E. E., Institute of Electrical and Electronics Engineers. Bombay Section, National Institute of Technology (Raipur, I. I. S. B., & Institute of Electrical and Electronics Engineers. (2020). *Ratley, Minj, Patre*. 161–165.
- Nugroho, Z. N., Harjoko, A., & Auzan, M. (2023). Klasifikasi Eritrosit Pada Thalasemia Minor Menggunakan Fitur Konvolusi dan Multi-Layer Perceptron. *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 13(1), 91–100. <https://doi.org/10.22146/ijeis.83473>
- Pittara, D. (2022). *Leukemia Limfoblastik Akut*. Alodokter.Com. <https://www.alodokter.com/leukemia-limfoblastik-akut#:~:text=Acute lymphoblastic leukemia terjadi akibat,berubah menjadi limfoblas terlebih dahulu.>
- Puła, A., Zdunek, M., Michalczyk, K., Cichosz, M., & Młynarski, W. (2022). Chemotherapy delays in children with acute lymphoblastic leukemia might influence the outcome of treatment. *Acta Haematologica Polonica*, 53(2), 141–148. <https://doi.org/10.5603/AHP.A2022.0007>
- Pushpalatha, M. P., Jahnavi, B. S., Monika, N. S., Nikhitha, B. R., & Anusha, K. (2024). Detection and Classification of Acute Lymphoblastic Leukemia using CNN. *International Journal of Advanced Research in Computer Science*,

- 15(4), 35–43. <https://doi.org/10.26483/ijarcs.v15i4.7114>
- Putra, O. V., Mustaqim, M. Z., & Muriatmoko, D. (2023). Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2. *Techno.Com*, 22(3), 562–575. <https://doi.org/10.33633/tc.v22i3.8516>
- Rahman, M., & Noor, R. (2023). A Study on Demographic Status in Children with ALL. *Scholars Journal of Applied Medical Sciences*, 11(05), 971–975. <https://doi.org/10.36347/sjams.2023.v11i05.028>
- Ramaneswaran, S., Srinivasan, K., Vincent, P. M. D. R., & Chang, C. Y. (2021). Hybrid Inception v3 XGBoost Model for Acute Lymphoblastic Leukemia Classification. *Computational and Mathematical Methods in Medicine*, 2021. <https://doi.org/10.1155/2021/2577375>
- Rehman, A., Abbas, N., Saba, T., Rahman, S. I. ur, Mehmood, Z., & Kolivand, H. (2018). Classification of acute lymphoblastic leukemia using deep learning. *Microscopy Research and Technique*, 81(11), 1310–1317. <https://doi.org/10.1002/jemt.23139>
- Rizki Firdaus Mulya, Ema Utami, & Dhani Ariatmanto. (2023). Classification of Acute Lymphoblastic Leukemia based on White Blood Cell Images using InceptionV3 Model. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(4), 947–952. <https://doi.org/10.29207/resti.v7i4.5182>
- Roziqin, A. (2023). IMPLEMENTASI METODE TRANSFER LEARNING DAN ALGORITMA RANDOM FOREST IMPLEMENTASI METODE TRANSFER LEARNING. 19.
- Sandler, M., Zhu, M., Zhmoginov, A., & Mar, C. V. (2018). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*.
- Santoso, I. B., Supriyono, & Utama, S. N. (2024). Multi-Model of Convolutional Neural Networks for Brain Tumor Classification in Magnetic Resonance Imaging Images. *International Journal of Intelligent Engineering and Systems*, 17(5), 741–758. <https://doi.org/10.22266/ijies2024.1031.56>
- Scotti, F. (2005). *CIMSA 2005-IEEE International Conference on Computational Intelligence for Measurement Systems and Applications Automatic Morphological Analysis for Acute Leukemia Identification in Peripheral Blood Microscope Images*. July, 20–22. http://piurilabs.di.unimi.it/Papers/cimsa_2005.pdf
- Shah, W. H., Baloch, A., Jaimes-Reátegui, R., Iqbal, S., Fatima, S. R., & Pisarchik, A. N. (2024). Acute lymphoblastic leukemia classification using persistent homology. *European Physical Journal: Special Topics*, 123. <https://doi.org/10.1140/epjs/s11734-024-01301-4>
- Sharma, R., Kim, M., & Gupta, A. (2022). Motor imagery classification in brain-machine interface with machine learning algorithms: Classical approach to multi-layer perceptron model. *Biomedical Signal Processing and Control*, 71(PA), 103101. <https://doi.org/10.1016/j.bspc.2021.103101>
- Somoal, M. G., & Dzikrillah, A. R. (2025). KOMPARASI MOBILENETV2 DENGAN KUSTOMISASI TRANSFER LEARNING DAN HYPERPARAMETER UNTUK IDENTIFIKASI TUMOR OTAK COMPARISON OF MOBILENETV2 WITH CUSTOMISED TRANSFER LEARNING AND HYPERPARAMETER FOR BRAIN TUMOUR

IDENTIFICATION. 12(1), 229–240.

<https://doi.org/10.25126/jtiik.2025129582>

Ullah, M. Z., Zheng, Y., Song, J., Aslam, S., Xu, C., Kiazolu, G. D., & Wang, L. (2021). An attention-based convolutional neural network for acute lymphoblastic leukemia classification. *Applied Sciences (Switzerland)*, 11(22). <https://doi.org/10.3390/app112210662>

Wibowo, D. W., Erwanto, D., & Kusumastutie, D. A. W. (2021). Klasifikasi Jenis Kayu Menggunakan Esktrasi Fitur Gray Level Co-Occurence Matrix dan Multilayer Perceptron. *Jurnal Nasional Teknik Elektro*, 10(1), 1. <https://doi.org/10.25077/jnte.v10n1.788.2021>

Youn, Y. R., & Hong, J. (2024). *Optimization of Model based on Relu Activation Function in MLP Neural Network Model*. 13(2), 80–87.

Zeiler, M. D., & Fergus, R. (2014). Visualizing and understanding convolutional networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8689 LNCS(PART 1), 818–833. https://doi.org/10.1007/978-3-319-10590-1_53