## SISTEM KLASIFIKASI LEUKEMIA BERDASARKAN CITRA PERIPHERAL BLOOD MICROSCOPIC MENGGUNAKAN EXTREME LEARNING MACHINE

#### **SKRIPSI**



Disusun Oleh
WAHYU TRI PUSPITASARI
H72216071

PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA

#### PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama

: WAHYU TRI PUSPITASARI

NIM

: H72216071

Program Studi : Matematika

Angkatan

: 2016

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul " SISTEM KLASIFIKASI LEUKEMIA BERDASARKAN CITRA PERIPHERAL BLOOD MICROSCOPIC MENGGUNAKAN EXTREME LEARNING MACHINE". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, Desember 2019

Yang menyatakan,

NIM. H72216071

U TRI PUSPITASARI

## LEMBAR PERSETUJUAN PEMBIMBING

### Skripsi oleh

Nama

: WAHYU TRI PUSPITASARI

NIM

: H72216071

Judul Skripsi : SISTEM KLASIFIKASI LEUKEMIA BERDASARKAN

CITRA

PERIPHERAL

BLOOD

**MICROSCOPIC** 

MENGGUNAKAN EXTREME LEARNING MACHINE

telah diperiksa dan disetujui untuk diujikan.

Surabaya,

Desember 2019

Pembimbing

Dian Candra Rim Novitasari, M.Kom

NIP. 198511242014032001

#### PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama

WAHYU TRI PUSPITASARI

NIM

H72216071

Judul Skripsi

: SISTEM KLASIFIKASI LEUKEMIA BERDASARKAN BLOOD PERIPHERAL **MICROSCOPIC CITRA** 

MENGGUNAKAN EXTREME LEARNING MACHINE

Telah dipertahankan di depan Tim Penguji pada tanggal Desember 2019

> Mengesahkan, Tim Penguji

Penguji I

Dian Candra Rini Novitasari, M.Kom

NIP. 198511242014032001

Penguji II

Fanani, M.Kom

NIP. 198701272014031002

Penguji III

Nurissaidan Ulinnuha, M.Kom

NIP. 199011022014032004

Penguji IV

Putroue Keumala Intan, M.Si

NIP. 198805282018012001

Mengetahui,

Dekan Fakultas Sains dan Teknologi

UIN Sunan Ampel Surabaya

CERIAN

Purwati, M.Ag 221/1990022001



## KEMENTERIAN AGAMA UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300 E-Mail: perpus@uinsby.ac.id

#### LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama	: WAHYU TRI PUSPITASARI
NIM	: H72216071
Fakultas/Jurusan	: SAIN DAN TEKNOLOGI/SAINS
E-mail address	: WAHYUPIPIT64@GMAIL.COM
UIN Sunan Ampe  ☑ Skripsi ☐ yang berjudul: SISTEM KLASIF	gan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan l Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah:  Tesis Desertasi Lain-lain ()  IKASI LEUKEMIA BERDASARKAN CITRA PERIPHERAL BLOOD  MENGGUNAKAN EXTREME LEARNING
Perpustakaan UIN mengelolanya da menampilkan/men akademis tanpa p	yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Ekslusif ini N Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, alam bentuk pangkalan data (database), mendistribusikannya, dan mpublikasikannya di Internet atau media lain secara <i>fulltext</i> untuk kepentingan erlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 31 Desember 2019

Penulis

(Wahyu Tri Puspitasari) nama terang dan tanda tangan

#### **ABSTRAK**

# SISTEM KLASIFIKASI LEUKEMIA BERDASARKAN CITRA PERIPHERAL BLOOD MICROSCOPIC MENGGUNAKAN EXTREME LEARNING MACHINE

Leukemia merupakan salah satu kanker yang mematikan yang menyerang manusia di segala usia. Sebuah database SEER Incidence Database menyebutkan bahwa pada tahun 2019 teedapat kasus baru leukemia sebanyak 61.780 kasus dan 22.840 jiwa meninggal dunia akibat leukemia. Leukemia dikatakan sangat berbahaya karena penyakit ini merupakan jenis tumor cair sehingga bentuknya tidak dapat dilihat secara fisik. Namun perkembangan penyakit leukemia dapat diketahui dengan menghitung jumlah sel-sel darah yang terdapat dalam tubuh melalui tes mikroskopik. Hasil tes mikroskopik dapat diproses menggunakan bantuan machine learning untuk melakukan sistem klasifikasi. Metode klasifikasi yang sering digunakan dalam beberapa tahun terakhir adalah extreme learning machine(ELM). Extreme Learning Machine (ELM) memiliki istilah lain yang disebut dengan Single Hidden Layer Feedforward Neural Network (SLFNs), yaitu jaringan saraf tiruan feedforward dengan satu hidden layer. ELM mampu mengatasi permasalahan yang sering terjadi pada backpropagation. Dalam proses pembelajarannya, ELM memanfaatkan teori invers matriks Moore Penrose Pseudoinverse yang memiliki hasil generalisasi terbaik dengan waktu komputasi yang cepat. Pada penelitain ini, dilakukan klasifikasi leukemia berdasarkan citra peripheral blood microscopicmenggunakan Extreme Learning Machine (ELM). Tahapan-tahapan klasifikasi terdiri dari preprocessing mmenggunakan histogram equalization dan median filter bertujuan untuk perbaikan kualitas citra, ekstraksi fitur menggunakan gray level run length matrix digunakan untuk mengambil ciri statistik yang terdapat dalam citra dan klasifikasi citra leukemia menggunakan extreme learning machine. Hasil klasifikasi leukemia berdasarkan beberapa orientasi arah dengan tiga belas percobaan jumlah node pada hidden laver diperoleh hasil terbaik yaitu akurasi sebesar 100%, presisi sebesar 100% dan recall sebesar 100% pada orientasi  $0^0$  dengan 10 node *hidden layer*, orientasi  $45^0$  dengan 12 node hidden layer, orientasi 900 dengan 14 node hidden layer, dan orientasi 135<sup>0</sup> dengan 10 node *hidden layer*.

Kata kunci: leukemia, ekstraksi fitur, klasifikasi, GLRLM, ELM

#### **ABSTRACT**

# LEUKEMIA CLASSIFICATION SYSTEM BASED ON PERIPHERAL BLOOD MICROSCOPIC IMAGE USING EXTREME LEARNING MACHINE

Leukemia is one of the deadliest cancers that can attack humans at any age.A SEER Incidence Database says that in 2019 there were 61,780 new cases of leukemia and 22,840 people died of leukemia. Leukemia is very dangerous because this disease is a type of liquid tumor so that its shape cannot be seen physically. But the development of leukemia can be known by counting the number of blood cells found in the body through microscopic tests. Microscopic test results can be processed using machine learning aid to the classification system. The classification method that is often used in recent years is extreme learning machine (ELM). Extreme Learning Machine (ELM) has another term called Single Hidden Layer Feedforward Neural Network (SLFNs), which is a feedforward artificial neural network with one hidden layer. ELM can solve problems that often occur in backpropagation. In the learning process, ELM utilizes Moore Penrose Pseudoinverse inverse matrix theory which has the best generalization results with fast computing time. In this research, leukemia classification is done based on peripheral blood microscopic images using Extreme Learning Machine (ELM). Classification stages, namely preprocessing using histogram equalization and median filter aim to improve image quality, feature extraction using gray level run length matrix is used to retrieve statistical features contained in the image and classification of leukemia images using extreme learning machines. The results of leukemia classification are based on several orientation directions with thirteen experiments the number of nodes on textit hidden layer obtained the best results, namely accuracy of 100 %, precision of 100 % and recall of 100 % on orientation  $0^0$  with 10 nodes textit hidden layer, orientation 450 with 12 nodes textit hidden layer, orientation 900 with 14 nodes textit hidden layer, and orientation 1350 with 10 nodes textit hidden layer.

**Keywords**: leukemia, feature extraction, classification, GLRLM, ELM

## **DAFTAR ISI**

H	ALAN	AN JUDUL	i
LF	EMBA	R PERSETUJUAN PEMBIMBING i	ii
ΡF	ENGE	SAHAN TIM PENGUJI SKRIPSIii	ii
HA	ALAN	AN PERNYATAAN KEASLIAN i	V
M	OTTO		V
HA	ALAN	AN PERSEMBAHAN v	/ <b>i</b>
KA	ATA F	ENGANTAR vi	ii
DA	AFTA	RISI i	X
<b>D</b> A	AFTA	R TABEL	κi
DA	AFTA	R TABEL	ii
DA	AFTA	R LAMBANG <mark></mark>	V
ΑI	BSTR	AK	V
ΑI	BSTR	ACT	/i
I	PEN	DAHULUAN	1
	1.1.	Latar Belakang Masalah	1
	1.2.	Rumusan Masalah	8
	1.3.	Tujuan Penelitian	8
	1.4.	Manfaat Penelitian	9
	1.5.	Batasan Masalah	9
	1.6.	Sistematika Penulisan	0
II	TIN,	AUAN PUSTAKA 1	2
	2.1.	Darah	2
	2.2.	Leukimia	3
	2.3.	Citra Digital	8
		2.3.1. Citra biner	0
		2.3.2. Citra Red Green Blue (RGB)	0
		2.3.3. Citra <i>Grayscale</i>	1

	2.4.	Pengol	ahan Citra Digital	22
		2.4.1.	Preprocessing pada citra	22
		2.4.2.	Analisis Citra	25
	2.5.	Gray L	Level run Lengrh Matrix (GLRLM)	25
		2.5.1.	Short Runs Emphasis (SRE)	27
		2.5.2.	Long Runs Emphasis (LRE)	27
		2.5.3.	Gray Level Non-uniformity (GLN)	28
		2.5.4.	Run Length Non-uniformity (RLN)	28
		2.5.5.	Run Precentage (RP)	28
	2.6.	Machin	ne Learning	28
	2.7.	Jaringa	nn Saraf Tiruan	29
	2.8.		ne Learninng Machine (ELM)	
	2.9.	Moore-	-Penrose Gene <mark>ra</mark> liz <mark>ed I</mark> nvers <mark>e</mark>	33
	2.10.		si Kinerja K <mark>las</mark> ifikator	
Ш	MET	ODE P	PENELITIAN	36
	3.1.	Jenis P	Penelitian	36
	3.2.	Data P	enelitian	36
	3.3.		ngan Penelitian	
IV	HAS	IL DAN	N PEMBAHASAN	41
	4.1.	Prepro	cessing Citra	41
		4.1.1.		
		4.1.2.	Histogram Equalization	45
		4.1.3.	Median Filter	48
	4.2.	Ekstral	ksi Fitur	49
	4.3.	Klasifi	kasi Menggunakan Extreme Learning Machine	55
$\mathbf{V}$	PEN	UTUP		66
	5.1.		lan	
	5.2.			
DA			ГАКА	
A				

## **DAFTAR TABEL**

2.1	Matrix Run length dengan orientasi arah 0	26
2.2	Matrix Run length dengan orientasi arah 45	26
2.3		27
2.4	Matrix Run length dengan orientasi arah 135	27
4.1	Proses Perhitungan Kemunculan Tingkat Keabuan Dalam Sebuah Citra	46
4.2	Proses Perhitungan Peluang	46
4.3	Proses Histogram Equalization	
4.4	Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah $0^0$	52
4.5	Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah 45°	53
4.6	Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah 90°	54
4.7	Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah $135^0$	55
4.8	Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah $0^0$ Menggunakan ELM	60
4.9	Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah $45^0$ Menggunakan ELM	62
4.10	Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah 90 <sup>o</sup> Menggunakan ELM	63
4.11		64

## DAFTAR GAMBAR

2.1	Komponen Darah dalam Tubuh Manusia	12
2.2	Normal	14
2.3	Acute Myelogenous Leukemia (AML)	14
2.4	Acute Lymphoblastic Leukemia (ALL)	14
2.5	Chronic Myelogenous Leukemia (CML)	15
2.6	Chronic Lymphoblastic Leukemia (CLL)	15
2.7	Sistem koordinat yang dipergunakan untuk mewakili citra	19
2.8	Contoh Matrik dari Citra Biner	20
2.9	Contoh Matriks dari Citra RGB	21
2.10	Contoh Matrik dari Citra Grayscale	22
2.11	Transformasi Histogram Citra Sebelum dan Sesudah Pemerataan .	24
2.12	Orientasi Arah dar <mark>i Gray Level Run</mark> Length Matrix	25
2.13	Matriks yang berisi nilai piksel dari sebuah citra	26
2.14	Struktur Umum ELM	30
2.15	Confusion Matrix Klasifikasi Dua Kelas	34
2.1	Diagram Alia Bancana Balaksan an Banalitian	37
3.1	Diagram Alir Rencana Pelaksanaan Penelitian	
3.2	Diagram Alir GLRLM	38
3.3	Diagram Alir Proses Klasifikasi	39
4.1	Sampel Citra Peripheral Blood Microscopic Darah Normal	41
4.2	Sampel Citra Peripheral Blood Microscopic Darah ALL	42
4.3	Sampel Citra Peripheral Blood Microscopic Darah CLL	42
4.4	komponen R, komponen G, dan komponen B dari sampel citra normal	43
4.5	Sampel Citra Setelah Proses Grayscale	44
4.6	Sampel Citra Setelah Proses Histogram equalization	47
4.7	Perhitungan Manual Median Filter	48
4.8	Sampel Citra Setelah Proses <i>Median Filter</i>	49

4.9	Pembentukan Matriks Run Length										50
	O										



## DAFTAR LAMBANG

 $x \in A$ : x anggota A

:himpunan semua bilangan real

 $\sum_{i=1}^n a_i$  : penjumlahan  $a_1+a_2+\cdots+a_n$   $\prod_{i=1}^n a_i$  : perkalian  $a_1\cdot a_2\cdot\cdots\cdot a_n$ 

#### **BABI**

#### **PENDAHULUAN**

#### 1.1. Latar Belakang Masalah

Leukemia merupakan salah satu jenis kanker yang mematikan. Leukemia dikatakan sangat berbahaya karena penyakit ini merupakan jenis tumor cair sehingga bentuknya tidak dapat dilihat secara fisik. Selain itu, penyebab pasti leukemia belum diketahui sampai sekarang. Beberapa database seperti World Health Organizations (WHO, 2018), SEER Incidence Database (SEER Incidence Database, 2019), Leukemia and Lymphoma Society (Society, Leukemia and Lymphoma, 2019) menyebutkan bahwa leukemia menjadi salah satu penyakit mematikan bagi semua kalangan usia. SEER Incidence Database (Surveillace, Epidemiology and End Result Program) mencatat adanya kasus baru leukemia pada tahun 2019 sekitar 61.780 kasus dan 22.840 jiwa meninggal dunia akibat leukemia di Amerika Serikat (SEER Incidence Database, 2019). Sedangkan World Health Organzation (WHO) mengatakan bahwa jumlah penderita leukemia dengan jenis Acute Lymphocytic Leukemia di Indonesia sebanyak kurang lebih 150.000 jiwa setiap tahun dengan tingkat kematian yang cukup tinggi (WHO, 2018; Ball, Seorang dokter yang merupakan Kepala Instalasi Anak Rumah Sakit 2013). Kanker Dharmais mengatakan bahwa leukemia merupakan kasus kanker nomer satu. Beliau mengatakan bahwa pada seluruh rumah sakit yang memiliki fasilitas pengobatan kanker terdapat kurang lebih 70% anak menderita leukemia (Kemkes, 2016). Angka tersebut menunjukkan bahwa penyakit leukemia sangat berbahaya

bagi anak-anak. dalam Al-Quran surat Ar-Ra'ad ayat 11 disebutkan bahwa manusia berkewajiban untuk menjaga kesehatan diri masing-masing. karena sesungguhnya Allah tidak mengubah keadaan suatu kaum. Oleh karena itu, sangat diperlukan deteksi dini dalam rangka menjaga kesehatan diri masing-masing dengan harapan mampu mengurangi angka penderita leukemia. Leukemia merupakan kelainan yang terjadi pada darah manusia (Praida, A. R, 2008).

Darah merupakan cairan tubuh yang sangat vital bagi kehidupan manusia mengingat perannya yang sangat penting bagi tubuh manusia. Darah mengandung beberapa komponen antara lain komponen padat berupa sel-sel darah dan komponen cair yang berupa plasma darah. Masing-masing komponen memiliki peran yang sangat penting bagi tubuh manusia (Firani, 2018). Seperti sel darah putih (*leukosit*) yang memiliki peran sebagai pelindung tubuh terhadap berbagai ancaman penyakit dan benda-benda asing maupun mikroorganisme yang masuk kedalam tubuh (Gul, S, 2007). Sel darah putih diproduksi di dalam sumsum tulang. Apabila sumsum tulang memproduksi sel darah putih secara berlebihan atau tidak normal dapat mengganggu fungsi dari sel darah putih dalam melindungi tubuh. Perkembangan sel darah putih yang semakin banyak bahkan sampai mengalami penumpukan yang berlebih pada sumsum tulang hingga pada organ lain seperti limfa, paru-paru maupun ginjal mampu menganggu bahkan merusak kinerja organ tersebut (Kantarjian, H. M, 2016)(Society, Leukemia and Lymphoma, 2019). Hal ini dapat dikatakan sebagai leukemia.

Leukemia adalah kelainan darah yang menyerang sel-sel pembentuk darah muda di sumsum tulang (Morrison & Hesdorffer, 2012). Jenis leukemia dibagi menjadi dua yaitu leukemia akut dan leukemia kronis. Leukemia akut dibedakan menjadi dua yaitu *Acute Myeloblastic leukemia* (AML) dan *Acute lymphoblastic* 

Leukemia (ALL) (Harmon, 2012). Sedangkan leukemia kronis dibedakan menjadi dua antara lain Chronic Myeloblastic Leukemia (CML) dan Chronic Lymphoblastic Leukemia (CLL) (Gul, S, 2007). Kata akut dan kronis menunjukkan bahwa leukemia dapat berkembang dengan sangat cepat sehingga mampu membahayakan bahkan hingga berakibat fatal bagi penderita apabila tidak dilakukan terapi sejak dini. Leukemia dapat disebabkan oleh beberapa faktor yaitu faktor keturunan dan faktor lingkungan. Faktor lingkungan yang dimaksud adalah kontak langsung dengan radiasi. Radiasi menjadi salah satu faktor lingkungan yang menyebabkan leukemia. Radiasi yang paling banyak menyebabkan leukemia berasal dari radiasi pengion. Radiasi nonpengion termasuk radiasi elektromagnetik SUTET (Anies, 2009). Selain itu, leukemia juga dapat disebabkan oleh zat kimia seperti benzena, arsen, kloramfenikol, fenil butason dan lain-lain (Tambayong, 1999) (Anies, 2009). Leukemia mempunyai tingkat kesembuhan yang tinggi apabila ditangani sejak dini. Namun, deteksi dini tergolong sulit dilakukan karena gejala umum leukemia yang tidak terlihat (Ball, 2013).

Gejala umum penderita leukemia biasanya mengalami pusing kepala yang berkelanjutan, mudah merasa lelah, terlihat pucat, tulang-tulang dan persendian terasa nyeri, sering mengalami pendarahan biasanya berupa pendarahan gusi dan mimisan. Gejala tersebut juga merupakan gejala dari penyakit selain leukemia sehingga sangat sulit membedakannya. Pada penderita leukemia akut, berat badan turun secara drastis. Pada leher atau ketiak penderita leukemia juga mengalami pembengkakan kelenjar getah bening (Gul, S, 2007)(Firani, 2018). Pada umumnya, seorang penderita mengetahui dirinya terkena leukemia setelah melakukan tes darah dengan tepat. Seseorang akan melakukan tes darah pada saat ada masalah lain yang memerlukan tes darah (Scotti, 2005). Terdapat berbagai

cara untuk diagnosis leukemia seperti menghitung jumlah sel-sel darah dalam darah, tes mikroskopik yang bertujuan untuk melihat apakah sel-sel tersebut memiliki tampilan yang normal atau abnormal. Dari hasil tes-tes tersebut dokter melakukan diagnosis leukemia apakah termasuk kedalam leukemia akut atau kronis. Jenis leukemia dapat diketahui dengan melihat hasil mikroskopik. Pada hasil tersebut terlihat jenis sel yang terlibat dalam darah. Berdasarkan jumlah sel darah yang terlihat pada saat diagnosis ditetapkan stadium leukemia (Klinis, D. O, 2017). Kesalahan diagnosis dapat membahayakan penderita karena pemberian penanganan yang dilakukan tidak sesuai dengan tingkat keparahan penyakitnya. Oleh karena itu, deteksi leukemia merupakan hal yang sangat penting dilakukan sejak dini (Rangole, 2019).

Fabio Scotti telah melakukan penelitian mengenai deteksi dini leukemia. Dalam penelitian ini dilakukan analisis morfologi pada gambar mikroskopik darah yang akan diklasifikasi (Scotti, 2005). Hal ini menunjukkan efektivitas metode morfologi otomatis yang mampu mengidentifikasi leukemia dengan baik. Alternatif deteksi menggunakan mikroskopik leukemia dapat diproses menggunakan sistem komputasi (Putzu, Caocci, & Di, C, 2014). Terdapat dua sistem komputasi utama yang dapat dikembangkan untuk membantu ahli onkologi dalam melakukan deteksi dini leukemia, yaitu Computer Aided Detection (CAD) dan Computer Aided Diagnosis (CADx). Sistem CAD bertujuan untuk mendeteksi lesi melalui citra medis, seperti menandai struktur bagian yang mencolok (Madero Orozco, et all, 2014). Sementara sistem CADx memiliki tujuan untuk menentukan karakterisasi lesi seperti menentukan keganasan dan stadium kanker. Penelitian ini menggunakan sistem CADx untuk membantu ahli onkologi dalam diagnosis sebagai pembanding untuk klasifikasi jenis leukemia dan untuk mengurangi waktu evaluasi mikroskopik. Tahapan dari sistem CADx yang dilakukan untuk klasifikasi kanker terdiri dari *preprocessing*, ekstraksi fitur, dan klasifikasi (Andono,T.& Muljono, 2017).

Proses preprocessing bertujuan untuk memperbaiki kualitas citra. Kualitas citra medik yang diperoleh berbeda-beda tergantung pada proses pengambilan citra (Ortiz-Ramón et al, 2019). Perbedaan kualitas citra dinilai dari seberapa banyak noise dalam citra, tingkat kecerahan, dan lain-lain. Noise yang terdapat dalam citra dapat dihilangkan melalui proses filtering (Yang, C, 2009). Salah satu metode filtering yang sering digunakan adalah median filter (Tang, Ni, Zhao, & Li, 2018) (Zhu & Huang, 2012). Dalam paper yang berjudul "An Improved Median Filtering Algorithm for Image Noise Reduction" yang ditulis oleh Youlian Zhu dan Cheng Huang menunjukkan bahwa median filter mampu mengurangi noise secara efektif (Zhu & Huang, 2012). Citra dengan kualitas yang baik akan diekstraksi fitur. Ekstraksi fitur dilakukan untuk mengambil ciri-ciri statistik yang terdapat dalam citra tersebut. Ciri tersebut akan menjadi bahan pembeda dari objek-objek lainnya. Gray Level Co-occurrence Matrix (GLCM) merupakan metode ekstraksi fitur orde dua yang terkenal (Punitha, Amuthan, & Joseph, 2018). GLCM telah digunakan dalam beberapa penelitian seperti klasifikasi batik (R. E. Putra, Suciati, & Wijaya, 2011), deteksi tumor otak (Harshavardhan, Babu, & Venugopal, 2017), deteksi kanker paru-paru (Tun, K. & Khaing, A. S, 2014) dan lain-lain karena memiliki kinerja yang baik untuk ekstraksi fitur. Beberapa waktu terakhir, terdapat metode lain yang memiliki performa lebih baik daripada GLCM yaitu Gray Level Run Length Matrix (GLRLM) (Sabu & Ponraj, 2012). Dalam suatu penelitian yang dilakukan oleh Sendren menunjukkan bahwa klasifikasi penyakit liver menggunakan SVM berdasarkan ektraksi fitur menggunakan GLCM dan GLRLM menunjukkan bahwa performa GLRLM lebih tinggi daripada dengan GLCM. Pada penelitian tersebut yang mulanya menggunakan 44 fitur dari GLRLM kemudian dilakukan reduksi fitur menjadi 5 sehingga memperoleh hasil yang lebih baik. Hal ini ditunjukkan dengan tingkat akurasi yang diperoleh dari GLRLM lebih tinggi yaitu 88.13%, sedangkan GLCM sebesar 78%. Perbedaan antara GLCM dengan GLRLM terletak pada matriks yang dibangun. Pada GLCM terdapat matriks kookurensi yang digunakan untuk mengambil ciri statistik dari citra seperti kontras, energi, entropy, homogenitas, korelasi (Filipczuk et all, 2012), sedangkan pada GLRLM ciri statistik diambil dari matriks *run length*. Ciri statistik tersebut menjadi fitur yang akan digunakan sebagai inputan dalam proses klasifikasi (Sohail, Bhattacharya, Mudur, & Krishnamurthy, 2011).

Saat ini, permasalahan klasifikasi dapat diselesaikan menggunakan Artificial Intelligence atau biasa dikenal dengan kecerdasan buatan (Devi, Ravi, Vaishnavi, & Punitha, 2016). Salah satu langkah besar dalam sejarah kecerdasan buatan adalah penemuan jaringan saraf tiruan. Jaringan saraf tiruan telah bekerja dengan baik selama bertahun-tahun (Prasetya, 2014). Berbagai macam pengembangan telah dilakukan salah satunya penemuan metode Extreme Learning Machine (ELM). ELM merupakan jaringan syaraf tiruan umpan maju (feedforward) dengan layar tersembunyi yang berjumlah satu atau dapat disebut single hidden layer feedforward neural networks (SLFNs) (Subbulakshmi,C. Deepa,S.& Malathi, N, 2012). ELM mampu melengkapi kekurangan dari jaringan syaraf tiruan terutama dalam hal kecepatan pembelajaran. Keunggulan lain dari ELM adalah tidak memerlukan kriteria pemberhentian seperti maksimal iterasi namun tetap memiliki kinerja yang lebih baik. ELM telah digunakan dalam beberapa penelitian sebelumnya karena kinerjanya yang sangat baik (Nawi,

2018)(Saporetti, Duarte, Fonseca, & Pereira, 2018).

Para ahli telah melakukan beberapa penelitian mengenai deteksi dini leukemia. Salah satunya adalah Rangole melakukan deteksi leukemia pada citra mikroskopik menggunakan pengolahan citra digital dengan melakukan ekstraksi fitur menunjukkan hasil yang baik untuk proses klasifikasi (Rangole, 2019). Peneliti lain melakukan deteksi leukemia menggunakan jaringan syaraf tiruan sehingga memperoleh akurasi sebesar 83.33% (Praida, A. R, 2008). Penerapan metode lain dalam deteksi leukemia juga dilakukan oleh Bhima Caraka dan timnya. Dalam penelitiannya, klasifikasi sel darah putih dilakukan menggunakan metode *Support Vector Machine* (SVM) menunjukkan hasil terbaiknya dengan akurasi sebesar 82,20% menggunakan kernel *Radial Basis Fuction* (RBF).

SVM juga digunakan oleh Gowthaman untuk deteksi diabetic retinopathy. Gowthaman membandingkan kinerja SVM dan ELM untuk klasifikasi mikroanarism dalam deteksi diabetic retinopathy. Dari beberapa percobaan yang dilakukan, diperoleh kesimpulan bahwa ELM lebih baik dibandingkan SVM dengan perhitungan yang cepat dan hasil yang lebih baik. Harmon Zulfa Afiq Fikriya dan teman-temannya menunjukkan bahwa ELM mampu melakukan pengenalan objek citra digital (Fikriya, Z. A et all, 2017). Penelitian lain yang juga menggunakan metode ELM seperti peramalan laju inflasi di Indonesia (Alfiyatin et al, 2019), detection of dengue disease (Nawi, 2018), diagnosis kanker payudara (Nemissi, Salah, & Seridi, 1945) dan lain-lain menunjukkan hasil dengan tingkat akurasi rata-rata di atas 90%. Berdasarkan latar belakang yang telah dijelaskan di atas, maka peneliti melakukan penelitian dengan judul "Sistem Klasifikasi Leukemia Berdasarkan Citra Peripheral Blood Microscope menggunakan Extreme Learning Machine". Penelitian ini diharapkan mampu membentuk sistem yang

dapat mengklasifikasi leukemia sehingga hasil dari sistem dapat digunakan untuk diagnosi penyakit leukemia.

#### 1.2. Rumusan Masalah

Berdasarkan latar belakang di atas, terdapat beberapa permasalahan yang muncul antara lain

- 1. Bagaimana hasil perbaikan kualitas citra *Peripheral Blood Microscopic* menggunakan *histogram equalization* dan *median filter*?
- 2. Bagaimana hasil ekstraksi fitur citra *peripheral blood microscopic* menggunakan GLRLM?
- 3. Bagaimana hasil klasifikasi leukemia berdasarkan citra *peripheral blood microscopic* menggunakan *extreme learning machine* untuk klasifikasi tiga kategori yaitu normal, akut dan kronis?

#### 1.3. Tujuan Penelitian

- Dapat memperbaiki perataan tingkat keabuan pada citra Peripheral Blood Microscopic menggunakan histogram equalization dan median filter
- 2. Dapat mengekstraksi fitur citra *Peripheral Blood Microscopic* menggunakan GLRLM.
- 3. Dapat mengklasifikasi citra proses klasifikasi leukemia berdasarkan citra peripheral blood Microscopic menggunakan extreme learning machine untuk klasifikasi tiga kelas yaitu normal, leukemia akut dan leukemia kronis.

#### 1.4. Manfaat Penelitian

#### 1. Manfaat Teoritis

Secara teoritis, manfaat penelitian ini bagi bidang kesehatan dan ilmu matematika kajian ini mampu menambah pengetahuan tentang metode GLRLM dan kemampuan ELM dalam melakukan klasifikasi leukemia.

#### 2. Manfaat Praktis

Bagi Dokter dan ahli onkologi, penelitian ini memberikan kemudahan untuk melakukan deteksi leukemia dengan cepat. Bagi Universitas Islam Negeri Sunan Ampel Surabaya, penelitian ini menambahkan daftar koleksi bahan pustaka yang bermanfaat bagi Universitas Islam Negeri Sunan Ampel Surabaya dan menjadi sumbangsih pemikiran yang menjadi bukti nyata terhadap Fakultas Sains dan Teknologi.

#### 1.5. Batasan Masalah

- Data yang digunakan pada penelitian ini menggunakan data citra Peripheral Blood Microscopic.
- Deteksi leukemia dibagi kedalam tiga kelas yaitu normal, leukemia akut dan leukemia kronis.
- Hasil dari sistem ini adalah berupa informasi hasil klasifikasi leukemia berdasarkan tingkat keparahannya.
- Validasi dilakukan dengan membandingkan hasil klasifikasi dengan data yang sudah ada.

10

1.6. Sistematika Penulisan

Sistematika penyusunan yang digunakan pada penulisan skripsi ini terdiri

dari lima bagian, yaitu sebagai berikut :

1. BAB I : PENDAHULUAN

Bab ini menjelaskan yang menjadi latar belakang penulis dalam melakukan

penelitian. Selain itu bab ini juga menjelaskan bagaimana rumusan masalah dan

tujuan dari penelitian ini. Penyelesaian yang diharapkan oleh seorang peneliti

dapat memberi manfaat yang akan dijelaskan pada bagian manfaat penelitian.

2. BAB II : DASAR TEORI

Pada bab ini berisikan tentang teori-teori yang mendukung penelitian sehingga

dapat memahami permasalahan dalam penelitian antara lain mengenai leukemia,

Pengelolahan citra berupa histogram equalization, median filter, GLRLM, dan

ELM.

3. BAB III: METODE PENELITIAN

Bab ini menjelaskan pedekatan yang digunakan pada penelitian, jenis penelitian,

waktu penelitian, metode pengumpulan data, analisis data, dan pengujian serta

evaluasi.

4. BAB IV: HASIL DAN PEMBAHASAN

Bab ini menjelaskan hasil penelitian yang telah dilakukan peneliti. Selain itu

pembahasan hasil penelitian dijabarkan untuk menjelaskan proses yang terjadi

pada setiap tahapanya juga dilakukan analisis dari hasil yang diperoleh.

5. BAB V : PENUTUP

Bab ini berisi rangkuman dari keseluruhan hasil yang sudah diuraikan. Selain itu bab ini juga berisi saran yang ditujukan kepada peneliti selanjutnya yang ingin mengembangkan penelitian ini.

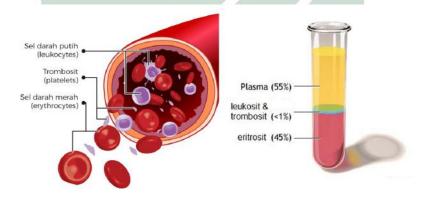


#### **BAB II**

#### TINJAUAN PUSTAKA

#### 2.1. Darah

Darah merupakan cairan yang terdapat dalam tubuh manusia dengan peran yang sangat penting. Darah berfungsi sebagai kendaraan bagi oksigen dan nutrisi untuk bergerak ke seluruh sel dalam tubuh serta mengangkut produk-produk metabolisme sel (Firani, 2018). Volume darah secara keseluruhan kira-kira setara dengan satu per duabelas berat badan atau kira-kira 3,6 liter pada wanita dan 4,5 liter pada pria. Sekitar 55% darah merupakan komponen cairan atau plasma, sisanya sebesar 45 merupakan komponen sel-sel darah. Terdapat tiga komponen sel-sel darah dalam tubuh antara lain sel darah merah (eritrosit), sel darah putih (leukosit), dan keping darah (trombosit).



Gambar 2.1 Komponen Darah dalam Tubuh Manusia

(Firani, 2018)

Plasma darah adalah cairan yang bertugas membawa oksigen, karbon dioksida, hormon, enzim dan antigen dalam tubuh. Plasma darah mengandung

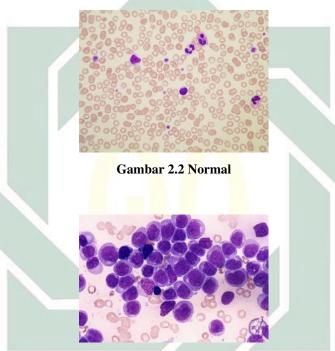
kurang lebih 90% air dan 10% sisanya mengandung zat-zat lain yang didistribusikan ke seluruh tubuh. Sel-sel yang terdapat dalam darah memiliki peran masing-masing. Eritrosit berfungsi sebagai alat transportasi oksigen dan karbon Trombosit memiliki peran dalam proses pembekuan darah (Firani, dioksida. 2018). Sedangkan leukosit berperan mempertahankan tubuh terhadap benda sing maupun mikroorganisme. Leukosit terdiri atas neutrifil, eosinophil, basophil, Jumlah leukosit cenderung lebih sedikit dibandingkan limfosit, dan monisit. dengan eritrosit. Semua jenis sel darah diproduksi oleh Sel Induk Hematopoitik (SIH). Proses pembentukan sel-sel darah berawal dari satu sel induk yang masih primitif, kemudian berakhir pada pembentukan sel-sel darah yang sudah matang. Proses pembentukan sel-sel darah terjadi pada sumsum tulang. Pada tahapan pembentukan sel-sel darah terjadi proses proliferasi (penggandaan atau perbanyak sel), diferensiasi (perkembangan sel), dan maturasi (sel-sel mengalami perubahan fungsional)(Klinis, D. O, 2017). Penumpukan atau kekurangan dari salah satu komponen sel-sel darah mampu menyebabkan kelainan atau penyakit (Ball, 2013). Salah satunya adalah penyakit leukemia yang ditandai adanya penumpukan jumlah leukosit yang tidak normal.

#### 2.2. Leukimia

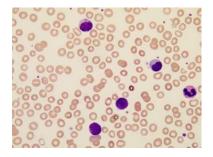
Istilah leukemia diambil dari Bahasa Yunani yang berarti darah putih. Leukemia adalah penyakit yang disebabkan oleh pertumbuhan abnormal dari leukosit yang ditandai dengan pembelahan abnormal dari sel-sel hematopoitik. Jenis leukemia berdasarkan lama waktu terjadinya penyakit dibedakan menjadi dua yaitu leukemia akut dan leukemia kronis.

#### 1. Leukemia Akut

Leukemia akut terjadi dalam proses yang singkat. Perkembangan leukemia akut dapat terhitung dalam hitungan hari atau bulan. Hal ini yang mampu membahayakan pasien apabila tidak diobati sejak dini. Leukemia akut terbagi lagi dua yaitu *Acute Myelogenous Leukemia* (AML) dan *Acute Lymphoblastic Leukemia* (ALL) (Kantarjian, H. M, 2016).



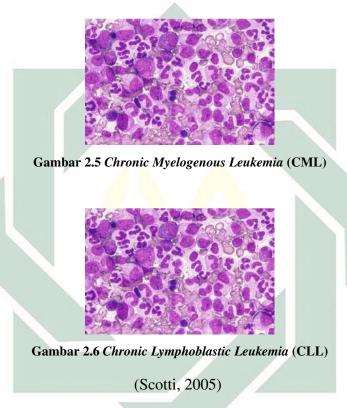
Gambar 2.3 Acute Myelogenous Leukemia (AML)



Gambar 2.4 Acute Lymphoblastic Leukemia (ALL)
(Scotti, 2005)

#### 2. Leukemia Kronis

Leukemia kronis yaitu leukemia yang terjadi dengan proses waktu yang lama berkisar tahunan. Leukemia kronis juga terbagi menjadi dua yaitu *Chronic Myelogenous Leukemia* (CML) dan *Chronic Lymphoblastic Leukemia* (CLL) (Kantarjian, H. M, 2016).



Gejala leukemia terjadi jika terdapat gangguan dalam proses pematangan sistem sel menjadi sel darah putih kemudian berubah menjadi ganas. Biasanya gejala-gejala umum pada penderita leukemia yang muncul adalah nyeri, demam, dyspnea, mual, muntah, konstipasi, depresi (Ball, 2013). Selain itu, terdapat gejala yang biasanya terjadi pada leukemia akut setelah beberapa minggu yang dibedakan menjadi tiga tipe, yaitu:

1. Gejala tipikal: sering kelelahan, sesak napas (akibah anemia), infeksi bakteri (akibat leukopenia), pendarahan (akibat trombositopenia), kulit pucat, beberapa

memar, demam, dan limfadenopati

- Gejala sistemik: malaise, penurunan berat badan, berkeringat, dan anoreksia cukup sering terjadi.
- 3. Gejala lokal: infiltrasi leukemia di kulit, gusi, atau sistem saraf pusat.

Penyebab penyakit leukemia masih belum diketahui secara pasti. Orang-orang dengan faktor risiko tertentu lebih meningkatkan resiko timbulnya penyakit leukemia seperti umur, faktor genetik, virus, dinar radioaktif, zat kimia. Biasanya penderita AML berusia antara 15-39 tahun. Penyakit leukemia lebih sering menyerang laki-laki dibanding perempuan. Kemungkinan orang dewasa lebih sering terkena leukemia sebesar 10 kali daripada anak-anak (Morrison & Hesdorffer, 2012). Faktor genetik juga mampu menyebabkan terkena leukemia. Biasanya anak-anak penderita *sindrom down* 20 kali lebih besar berisiko terkena leukemia. Kejadian leukemia akut juga meningkat pada penderita kelainan *congential* (Klinis, D. O, 2017). Penurunan gen dari penderita leukemia juga dapat meyebabkan keturunannya terkena leukemia. Sinar radioaktif menjadi faktor eksternal penyebab leukemia.

Penggunaan sinar radioaktif dapat menyebabkan meningkatnya angka kejadian leukemia akut. Selain sinar radioaktif, faktor eksternal penyebab leukemia adalah penggunaan zat kimia dan juga faktor lingkungan pekerjaan (Kantarjian, H. M, 2016). Zat kimia yang diduga meningkatkan risiko terdampak leukemia, misalnya benzena, arsen, pestisida, kloramfenikol, dan fenilbutazon. Benzena telah terkenal menyebabkan leukemia karena merupakan zat leukomogenik yag berperan sebagai karsinogen. Sifat karsinogen tersebut yang menyebabkan leukemia. Jika terkena paparan benzene dengan takaran tinggi, tidak hanya menyebabkan timbulnya penyakit leukemia, tetapi juga dapat menyebabkan

aplasia sumsum tulang dan kerusakan kromosom(Kantarjian, H. M, 2016). Hal itulah yang menyebabkan faktor lingkungan pekerjaan juga menjadi faktor eksternal penyebab leukemia, khususnya para petanidan peternak.

Pemeriksaan penyakit leukemia dapat dilakukan berdasarkan gejala yang terjadi pada penderita leukemia. Dalam hal ini, pemeriksaan leukemia dibagi menjadi dua, yaitu:

#### 1. Pemeriksaan Fisik

Pemeriksaan fisik dilakukan dengan cara disesuaikan dengan gejala yang dikeluhkan. Biasanya gejala yang sering dikeluhkan antara lain: gejala pendarahan, anemia, infeksi, dan gejala-gejala akibat infiltrasi dari sel-sel leukemia tersebut ke jaringan atau organ lain. Pemeriksaan fisik berdasarkan gejala pendarahan disebabkan oleh dua penyebab utama, yaitu trombositopenia (menurunnya produksi trombosit dan meningkatnya konsumsi trombosit akibat infeksi, dll) dan adanya pembekuan darah yang meliputi hipofibrinogenemia, kelainan faktor V dan VII, meningkatnya *Fibrin Degradation Product* (FDP) dan anti koagulan di dalam sirkulasi(Harmon, 2012).

#### 2. Pemeriksaan Laboratorium

Pemeriksan laboratorium dilakukan karena pemeriksaan fisik telah dilalui dan diperlukan pemeriksaan lebih lanjut yang tidak bisa dilihat secara langsung. Pemeriksaan ini dilakukan dengan cara mengambil sampel darah untuk diperiksa lebih lanjut (Klinis, D. O, 2017). Kelainan yang paling menyolok pada hasil pemeriksaan darah penderita leukemia adalah terdapatnya anemia, trombositopenia dan terdapatnya sel-sel muda (*blast*) pada pemeriksaan hapusan darah tepi atau pada sediaan hapusan sumsum tulang. Pada umumnya, saat diagnosis sediaan sumsum tulang didapatkan gambar hipersekuler yang

mengandung 30-100% sel-sel *blast*. Terkadang hasil yang didapatkan dari aspirasi sumsum tulang adalah "*dry lap*", hal ini dapat terjadi pada keadaan:

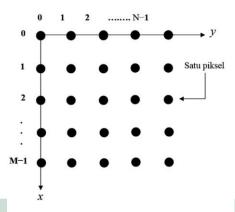
- a. Sumsum tulang terlalu padat dengan sel-sel leukemia
- b. Terjadi reticulum fibrosis
- c. Nekrosis dari sumsum tulang.

Jika pada pemeriksaan darah ditemukan ketidaknormalan, maka akan dilanjutkan dengan biopsy sumsum tulang. Pemeriksaan ini memungkinkan seorang dokter melihat sel-sel yang ada di dalam sumsum tulang. Kunci utama informasi tentang leukemia ada di pemeriksaan tersebut, termasuk jenis pengobatan yang diperlukan (Wirawan, I. M. C., 2013). Selain itu, hasil pemeriksaan laboratorium leukemia lainnya yang sering dijumpai adalah komplikasi asam urat yang disertai dengan pengendapan kristal urat pada saluran kemih (Klinis, D. O, 2017).

#### 2.3. Citra Digital

Citra adalah sesuatu yang merepresentasikan kemiripan dari suatu objek. Citra analog tidak bisa direpresentasikan dalam komputer, sehingga perlu dikonversi terlebih dahulu menjadi citra digital (Irwan & Sianipar, 2018). Citra digital adalah representasi numerik dari citra dua dimensi yang dapat diproses oleh komputer. Nilai numerik yang direpresentasikan umumnya adalah nilai biner 8 bit. Nilai ini disimpan pada elemen citra yang sering disebut sebagai pixel (D. Putra, 2010). Sebuah citra digital direpresentasikan dengan matriks yang terdiri dari M baris dan N kolom, dimana perpotongan antara baris dan kolom tersebut disebut piksel. Piksel memiliki dua parameter koordinat dan intensitas atau warna (Irwan & Sianipar, 2018). Nilai yang terdapat pada koordinat (x,y) adalah f(x,y), yaitu

nilai intersitas atau warna dari piksel di titik itu.



Gambar 2.7 Sistem koordinat yang dipergunakan untuk mewakili citra

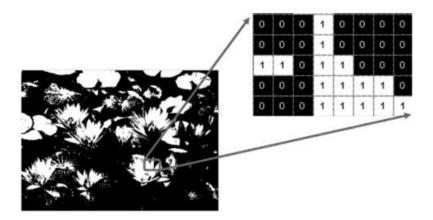
(Andono, T.& Muljono, 2017)

Dari gambar tersebut menunjukkan bahwa sebuah citra digital dapat ditulis dalam bentuk matriks berikut (Munir, 2004)

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & f(1,1) & \dots & f(1,M-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{bmatrix}$$

f(x,y) merupakan fungsi intensitas, dimana x baris dan y kolom merupakan koordinat posisi dan f(x,y) adalah nilai fungsi pada setiap titik (x,y) yang menyatakan besar intensitas citra atau tingkat keabuan atau warna dari pixel di titik tersebut. Terdapat beberapa jenis citra yang sering digunakan, diantaranya adalah (Sutoyo & Mulyanto, 2009)

#### 2.3.1. Citra biner



Gambar 2.8 Contoh Matrik dari Citra Biner

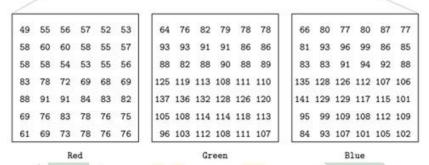
(Andono, T.& Muljono, 2017)

Citra biner hanya memiliki dua warna saja yaitu hitam dan putih. Citra biner berwarna hitam apabila bernilai 0 dan berwarna putih jika bernilai 1. Terkadang citra biner juga direpresentasikan dengan nilai 0 dan 255 (Munir, 2004).

#### 2.3.2. Citra Red Green Blue (RGB)

Citra RGB adalah citra yang setiap pikselnya memiliki 3 komponen warna. Komponen pertama menyimpan warna merah/Red (R), komponen kedua menyimpan warna hijau/Green (G) dan komponen terakhir menyimpan warna biru//Blue (B). Warna lain diluar dari warna RGB merupakan campuran dari ketiga warna tersebut (Munir, 2004).





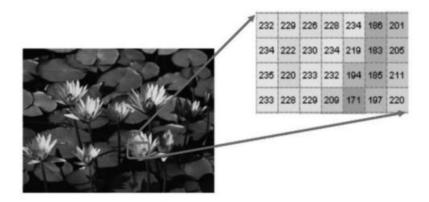
Gambar 2.9 Contoh Matriks dari Citra RGB

(Andono, T.& Muljono, 2017)

#### 2.3.3. Citra Grayscale

Citra *grayscale* merupakan matriks berisi nilai-nilai yang merepresentasikan intensitas dari setiap piksel berkisar antara 0 sampai dengan 255. Warna hitram diwakilkan dengan nilai piksel 0, putih diwakilkan dengan nilai 255. Diantara keduanya mewakilkan tingkat keabuan. Semakin besar nilai yang terdapat pada piksel tersebut menunjukkan tingkat keabuan yang semakin terang atau mendekati putih (Munir, 2004). Rumus untuk mengubah citra RBG menjadi citra *grayscale* ditunjukkan dalam persamaan 4.5

$$Gray(1,1) = 0.299 \times R + 0.587 \times G + 0.114 \times B$$
 (2.1)



Gambar 2.10 Contoh Matrik dari Citra Grayscale
(Andono, T.& Muljono, 2017)

#### 2.4. Pengolahan Citra Digital

Dalam sistem klasifikasi citra medik diperlukan teknik-teknik pengolahan citra digital yang terdiri dari tiga tahap yaitu *preprocessing*, ekstraksi fitur dan klasifikasi(Andono,T.& Muljono, 2017). Berikut penjelasan mengenai teknik-teknik pengolahan citra digital untuk pengklasifikasian (Andono,T.& Muljono, 2017).

#### 2.4.1. Preprocessing pada citra

Preprocessing merupakan tahap pemroses data citra dengan tujuan memperbaiki kualitas dari data tersebut sebelum digunakan untuk proses selanjutnya. Masing-masing citra memiliki kualitas yang berbeda-beda seperti terdapat noise, citra yang terlalu gelap, citra yang cenderung kabur dan lain-lain (Ahmad, U, 2005). Pada penelitian, apabila terjadi perbedaan kualitas citra yang sangat signifikan mampu mempengaruhi hasil dari penelitian tersebut. Untuk menghindari risiko perolehan hasil yang kurang baik, maka diperlukan perbaikan kualitas citra. Perbaikan kualitas citra (image enhancement) merupakan bagian

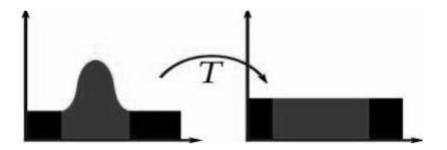
dari tahap *preprocessing*. Perbaikan kualitas citra bertujuan meningkatkan kualitas citra untuk pandangan manusia atau mengkonversi suatu citra agar memiliki format yang lebih baik sehingga citra tersebut menjadi lebih mudah diolah dengan komputer. Perbaikan suatu citra dapat dilakukan dengan operasi titik, operasi spasial, operasi geomatrik, dan operasi aritmatika (Munir, 2004). Penggunaan masing-masing metode bergantung pada kebutuhan dari sebuah penelitian. Beberapa metode *image enhancement* yang sering digunakan adalah *intensity adjustment*, *filtering*, dan sebagainya.

#### a. Histogram Equalization

Histogram Equalization merupakan suatu teknik untuk meningkatkan kualitas citra, di mana pendistribusian pikselnya tidak merata (rentang nilai antara satu dan yang lain terlalu jauh) (Kaur, Garg, & Kaur, 2012). Teknik ini menghasilkan keluaran berupa citra dengan intensitas piksel pada rentang dinamis dan tersebar secara merata (Pandey, 2016). Nilai histogram pada citra direpresentasikan dalam bentuk grafik 2D dengan sumbu x menunjukkan nilai intensitas piksel dan sumbu y menjelaskan jumlah frekuensi dari setiap intensitas piksel (Sutoyo & Mulyanto, 2009). Histogram Equalization dapat dinyatakan dalam fungsi transformasi yang ditampilkan pada persamaan 2.2

$$T(x) = \sum_{i=0}^{x} n_i \frac{MaximumIntensity}{N}$$
 (2.2)

Dengan N merupakan nilai total piksel pada citra dan  $n_i$  merupakan nilai piksel pada intensitas i (D. Putra, 2010).



Gambar 2.11 Transformasi Histogram Citra Sebelum dan Sesudah Pemerataan

## b. Median Filter

Median filter merupakan salah satu dari metode filter spasial. Filter spasial bekerja dengan membentuk spatial window yang bertugas mengevaluasi setiap nilai piksel yang terdapat pada sebuah citra (Tang, Ni, Zhao, & Li, 2018). Spatial window yang dibentuk biasanya berukuran  $3 \times 3$ ,  $5 \times 5$ , dan  $7 \times 7$  dan seterusnya dimana ukuran dari filter spasial merupakan matriks yang berukuran ganjil agar dapat memperoleh titik pusat piksel yang berada di tengah (centered). Titik pusat dari filter spatial dievaluasi terhadapat tetangganya. Proses evaluasi dilakukan menggunakan berbagai perhitungan seperti rata-rata (mean), nilai tengah (median), nilai yang sering muncul (modus), gauss dan lain-lain. Median filter menjadi salah satu metode filtering yang sering digunakan dalam permasalahan filtering (, Sembiring(2015).

Median filter bekerja dengan menggantikan nilai piksel yang berada di tengah (centered) dari spatial window dengan nilai median dari gray level pada piksel-piksel yang terdapat pada spatial window. Persamaan 2.3 digunakan untuk menghitung nilai median.

$$f(x,y) = median\{g(x,y)\}\tag{2.3}$$

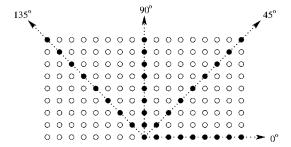
x,y adalah ukuran dari *window*, g(x,y) merepresentasikan nilai piksel dalam *window*. *Median filter* sering digunakan karena mampu mengurangi *noise* pada beberapa tipe derau acak (medfil).

#### 2.4.2. Analisis Citra

Citra yang telah diperbaiki akan dianalisis. Analisis citra merupakan teknik morfologi deteksi tepi, segmentasi garis, dan analisis bentuk, dan ekstraksi fitur pada citra. Terdapat beberapa metode ektraksi fitur salah satunya adalah *Gray Level Run Length Matrix*.

## 2.5. Gray Level run Lengrh Matrix (GLRLM)

Gray Level Run Length Matrix (GLRLM) merupakan salah satu metode yang digunakan untuk mengekstraksi fitur yang terdapat pada citra sehingga diperoleh ciri statistik atau fitur yang terdapat dalam citra dengan estimasi piksel-piksel yang memiliki derajat keabuan yang sama. Jika diketahui matriks run length dengan elemen matrik  $p(i,j|\theta)$  memberikan jumlah total kemunculan run yang memiliki panjang j dari tingkat keabuan i dalam sebuah orientasi arah yang diberikan  $\theta$  (Sohail, Bhattacharya, Mudur, & Krishnamurthy, 2011). Orientasi arah dibentuk dengan empat arah pergeseran yaitu  $0^{\circ},45^{\circ}$ ,  $90^{\circ}$  dan  $135^{\circ}$  ditunjukkan dalam Gambar 2.12.



Gambar 2.12 Orientasi Arah dari Gray Level Run Length Matrix

0	1	2	3
0	2	3	3
2	1	1	1
3	0	3	0

Gambar 2.13 Matriks yang berisi nilai piksel dari sebuah citra

Perhatikan Gambar 2.13, matriks  $run\ length$  dihitung dengan memperhatikan jumlah total kemunculan nilai piksel yang memiliki panjang j dari tingkat keabuan i dalam sebuah orientasi arah yang diberikan  $\theta$ . Jumlah total kemunculan nilai piksel sama dengan 0 dengan run = 1 dengan orientasi arah  $90^\circ$  sebesar 4. Kemudian masukkan nilai tersebut pada matriks  $run\ length$  pada baris tingkat keabuan 0 dan kolom panjang  $run\ length$  1. Perhitungan ini dilakukan hingga mencapai tingkat keabuan terbesar yang terdapat pada citra tesebut. Berikut matriks-matriks  $run\ length$  yang diperoleh dari Gambar 2.5 ditunjukkan dalam Tabel 2.1. - 2.4.

Tabel 2.1 Matrix Run length dengan orientasi arah 0

0	1	2	3	4
0	4	0	0	0
1	1	0	1,	0
2	3	0	0	0
3	3	1	0	0

Tabel 2.2 Matrix Run length dengan orientasi arah 45

0	1	2	3	4
0	4	0	0	0
1	4	0	0	0
2	0	0	1	0
3	3	1	0	0

Tabel 2.3 Matrix Run length dengan orientasi arah 90

0	1	2	3	4
0	2	1	0	0
1	4	0	0	0
2	3	0	0	0
3	3	1	0	0

Tabel 2.4 Matrix Run length dengan orientasi arah 135

	0	1	2	3	4
	0	2	1	0	0
1	1	4	0	0	0
	2	3	0	0	0
	3	3	1	0	0

Galloway mengatakan bahwa terdapat beberapa jenis ciri statistik yang dapat diekstraksi dari matriks *run length* diantaranya:

# 2.5.1. Short Runs Emphasis (SRE)

SRE sangat bergantung pada jumlah short run. SRE bernilai kecil apabila citra memiliki tekstur halus dan bernilai besar pada tekstur kasar (Preetha & Jayanthi, 2018).

$$SRE = \frac{\sum_{i=1}^{G} \sum_{j=1}^{R} \frac{p(i,j|\theta)}{j^2}}{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i,j|\theta)}$$
(2.4)

# 2.5.2. Long Runs Emphasis (LRE)

LRE sangat bergantung pada jumlah *long run*. LRE bernilai besar apabila tekstur halus dan bernilai kecil apabila tekstur kasar.

$$LRE = \frac{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i, j | \theta) j^{2}}{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i, j | \theta)}$$
(2.5)

## 2.5.3. Gray Level Non-uniformity (GLN)

GLN mengukur persamaan nilai tingkat keabuan diseluruh citra. GLN bernilai kecil apabila nilai tingkat keabuan sama dengan seluruh citra (Preetha & Jayanthi, 2018).

$$GLN = \frac{\sum_{i=1}^{G} \left(\sum_{j=1}^{R} p(i,j|\theta)\right)^{2}}{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i,j|\theta)}$$
(2.6)

# 2.5.4. Run Length Non-uniformity (RLN)

RLN mengukur persamaan *run length* diseluruh citra. RLN bernilai kecil apabila panjang *run* sama pada seluruh citra.

$$RLN = \frac{\sum_{i=1}^{R} \left(\sum_{j=1}^{G} p(i,j|\theta)\right)^{2}}{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i,j|\theta)}$$
(2.7)

## 2.5.5. Run Precentage (RP)

RP mengukur keserbasamaan dan distribusi *run* dari sebuah citra pada arah tertentu. RP bernilai besar apabila panjang *run* adalah 1 untuk semua tingkat keabuan pada arah tertentu.

$$RP = \frac{\sum_{i=1}^{G} \sum_{j=1}^{R} p(i, j | \theta)}{N}$$
 (2.8)

# 2.6. Machine Learning

Machine learning merupakan cabang ilmu Artificial Intelligence yang terfokuskan pada pembentukan dan studi sebuah sistem agar dapat melakukan pembelajaran dari data-data yang diperoleh. Machine learning dapat diaplikasikan apabila terdapat data. Data yang digunakan biasanya dibagi menjadi dua yaitu data

training dan data testing. Data training digunakan untuk proses pembelajaran sedangkan data testing digunakan untuk mengetahui kinerja algoritma yang telah dilatih sebelumnya (Fikriya, Z. A et all, 2017).

## 2.7. Jaringan Saraf Tiruan

Jaringan saraf tiruan (JST) merupakan sebuah model yang menerapkan cara kerja neuron secara biologi dengan fokus pada cara kerja saraf otak. JST sering digunakan untuk aplikasi komersial seperti *voice recognition*, *handwriting recognition* dan lain-lain. Jaringan saraf tiruan terdiri dari kumpulan *layer* (lapisan). Terdapat tiga lapisan yaitu lapisan *input*, lapisan tersembunyi, dan lapisan keluaran. Setiap relasi menghubungkan dua buah lapisan dengan bobot tertentu dan terdapat arah yang menunjukkan aliran data dalam proses.

Lapisan *input* merepresentasikan sebuah *input* parameter seperti umur, jenis kelamin, dan sebagainya. Lapisan tersembunyi merupakan lapisan yang terdapat di tengah. Lapisan tersembunyi menerima masukan dari lapisan *input* atau dari lapisan tersembunyi sebelumnya. Lapisan tersembunyi bertugas mengkombinasi semua masukan berdasarkan bobot dari relasi yang terhubung, melakukan perhitungan, dan memberikan keluaran untuk lapisan berikutnya. Lapisan keluaran merepresentasikan keluaran dari jaringan yang dibuat.

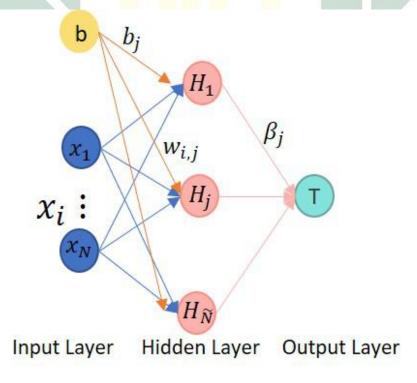
## 2.8. Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) memiliki istilah lain yang disebut denganI hidden Layer Feedforward Neural Network (SLFNs), yaitu jaringan saraf tiruan feedforward dengan satu hidden layer (Humaini, 2015). ELM ini berjenis supervised learning dengan keunggulan dapat mengatasi permasalahan yang sering terjadi pada metode-metode Feedforward Neural Network lain, yaitu permasalahan

learning speed rendah (Pandiangan, 2017). Permasalahan tersebut terjadi karena:

- 1. Proses training menggunakan Slow Gradient Based Learning Algorithm.
- 2. Semua parameter pada jaringan ditentukan secara iterative.

Proses pembelajaran pada metode *backpropagation* berjalan lambat karena semua parameter seperti bobot *input* dan bias *hidden* dimasukkan secara manual. Selain itu, parameter-parameter tersebut saling terhubung pada setiap *layer*nya, sehingga memerlukan *learning speed* yang lama dan sering terjadi kejadian terjebak lokal minima (Zhu & Huang, 2012). Sedangkan pada ELM, parameter-parameter yaitu *input weigth* dan *hidden* bias dipilih secara acak sehingga menghasilkan *learning speed* yang cepat dan memiliki hasil yang baik. Gambar 2.14 merupakan struktur umum ELM



Gambar 2.14 Struktur Umum ELM

Dalam proses pembelajarannya, ELM memanfaatkan teori invers matriks

Moore Penrose Pseudoinverse yang memiliki hasil generalisasi terbaik dengan waktu komputasi yang cepat. Berdasarkan Gambar 2.1, struktur jaringan ELM terdiri atas, input layer, hidden layer, dan output layer(Humaini, 2015). ELM memiliki model matematis yang berbeda dari backpropagation dengan model sederhana dan efektif. Pada ELM, jika terdapat N sampel  $(x_i, t_i)$  dengan  $x_i = [x_{i1}, x_{i2}, \cdots, x_{in}]^T \in \mathbb{R}_n$  dan  $t_i = [t_i, t_i, \cdots, t_i]^T \in \mathbb{R}_n$  n = jumlah parameter, kemudian standar SLFN dengan N hidden neurons dan fungsi aktivasi g(x) dapat dimodelkan secara matematis sebagai berikut (Zhu & Huang, 2012).

$$\sum_{j=1}^{m} \beta g(x_{i,:}.w_{:,j} + b_j) = O_j, \qquad i = 1, \dots, N$$
 (2.9)

Dimana  $w_{:,j} = [w_{11}, w_{22}, \cdots, w_{nm}]^T$  merupakan vektor bobot yang menghubungkan node pada *hidden layer* ke-m dengan *node* dari *input layer*.  $\beta_j = [\beta_1, \beta_2, \cdots, \beta_m]^T$  merupakan vektor bobot yang menjadi penghubung antara *hidden neuron* ke-i dengan *ouput neuron* (Mishra, Majhi, Sa, & Siddiqui, 2018). Tanda "." pada  $w_i.x_j$  menunjukkan perkalian titik dari  $x_i$  dan  $w_j$ . Sedangkan  $b_j$  merupakan index bias dari *hidden neuron* ke-j. SLFN diasumsikan mampu memperkirakan N sampel data memiliki tingkat error yang rendah yaitu sebesar 0 yang ditunjukkan dalam persamaan 2.10 (Zhu & Huang, 2012).

$$\sum_{i=1}^{N} ||O_i - t_i|| = 0 (2.10)$$

Sehingga model matematis sebelumnya dapat dituliskan seperti yang ditunjukkan dalam persamaan 2.11

$$\sum_{j=1}^{m} \beta g(x_{i,:}.w_{:,j} + b_j) = t_j, \qquad i = 1, 2, \dots N$$
 (2.11)

Persamaan matematis diatas dapat diubah ke dalam bentuk matriks

$$H\beta = T \tag{2.12}$$

$$H(a_{i,:}, w_{:,j}, b_{j}) = \begin{bmatrix} g(x_{1,:}.w_{1,1} + b_{1}) & \cdots & g(x_{1,:}.w_{1,m} + b_{m}) \\ \vdots & \ddots & \vdots \\ g(x_{N,:}.w_{N,1} + b_{1}) & \cdots & g(x_{N,:}.w_{N,m} + b_{m}) \end{bmatrix}$$
(2.13)

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}$$
 (2.14)

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}$$
 (2.15)

Matriks H merupakan matriks output hidden layer dari jaringan syaraf  $g(x_{i,:}.w_{:,j}+b_j)$ .  $\beta$  adalah matriks berisi bobot output dan T merupakan matriks target jaringan. Jika jumlah node pada hidden layer sama dengan jumlah sampel yang berbeda dari data latih, maka H akan berupa matriks simetris sehingga memiliki invers. Namun pada berbagai kasus memiliki permasalahan yaitu jumlah hidden node jauh lebih kecil daripada jumlah sampel data latih dimana H menjadi matriks asimetris. Permasalahan tersebut dapat diselesaikan dengan menggunakan teori Moore-Penrose generalized invers yang ditunjukkan pada persamaan berikut (Filipczuk, Fevans et all, 2019) Dimana H adalah teori Moore-Penrose generalized

*invers* dari matriks H.

$$\beta = H^{\dagger}T \tag{2.16}$$

#### 2.9. Moore-Penrose Generalized Inverse

Moore-Penrose Generalized Inverse merupakan solusi dari sistem persamaan linier Ax = y, dimana A memiliki kemungkinan berisi matriks singular atau tidak persegi berordo  $m \times n$  yang tidak memiliki invers. Konsep dari moore-penrose yaitu membuat matriks yang seolah-olah menjadi invers dari matriks singular atau yang biasa dikenal dengan sebutan pseudoinvers. Moore-Penrose ditemukan oleh E.H. Moore dan seorang temannya yang bernama Roger Penrose. Definisi dari Moore-Penrose generalized inverse ditunjukkan sebagai berikut

## **Definisi 2.9.1** (*Ding, Zhao, Zhang, Xu, & Nie, 2015*)

Jika  $A \in M(n,m)$ , , maka terdapat  $A^{\dagger} \in M(n,m)$  memenuhi empat kondisi Penrose yang ditunjukkan dalam persamaan berikut

$$AA^{\dagger}A = A \tag{2.17}$$

$$A^{\dagger}AA^{\dagger} = A^{\dagger} \tag{2.18}$$

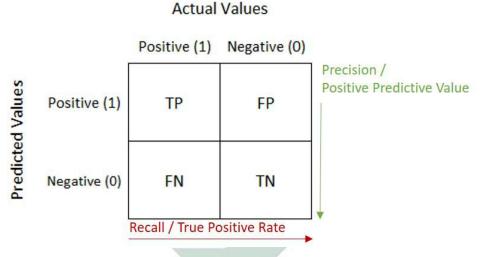
$$A^{\dagger}A = (A^{\dagger}A)^* \tag{2.19}$$

$$AA^{\dagger} = (AA^{\dagger})^* \tag{2.20}$$

Dimana  $A^*$  menyatakan konjugat transpose dari matriks A

# 2.10. Evaluasi Kinerja Klasifikator

Dalam membangun model klasifikasi diperlukan evaluasi untuk mengetahui seberapa jauh kinerja dari model tersebut. Berbagai cara dilakukan untuk melakukan evaluasi, salah satunya dengan memanfaatkan *confusion matrix*. Menurut Han dan Kamber, *confusion matrix* adalah suatu metode yang berfungsi untuk melakukan analisis apakah model klasifikasi tersebut sudah baik dalam mengenali kelas yang berbeda. Beberapa metode evaluasi yang dapat dilakukan menggunakan *confusion matrix* seperti akurasi, presisi dan *recall*.



Gambar 2.15 Confusion Matrix Klasifikasi Dua Kelas

True Positive (TP): hasil prediksi sesuai dengan nilai yang sebenarmya yaitu sama-sama benar.

True Negative (TN): hasil sebenarnya negatif dan nilai prediksi negatif.

False Positive (FP): hasil sebenarnya positif dan hasil prediksi negatif.

False Negative (FN): hasil sebenarnya positif dan hasil prediksi negatif.

Akurasi merupakan tingkat kebenaran program dalam melakukan sistem klasfikasi

$$akurasi = \frac{TP + TN}{TP + FP + FN + TN}$$
 (2.21)

Presisi merupakan perbandingan antara jumlah data yang terklasifikasi dengan benar oleh sistem terhadap data benar yang diklasifiasikan oleh sistem

$$presisi = \frac{TP}{TP + FP}$$
 (2.22)

Recall merupakan perbandingan antara jumlah data yang terklasifikasikan benar oleh sistem terhadap jumlah data aktual yang benar

$$recall = \frac{TP}{TP + FN} \tag{2.23}$$

#### **BAB III**

#### METODE PENELITIAN

## 3.1. Jenis Penelitian

Penelitian tentang ekstraksi fitur citra leukemia menggunakan metode extreme learning machine termasuk dalam jenis penelitian terapan yang dilihat dari aspek fungsinya. Hasil klasifikasi ini bertujuan sebagai alternatif deteksi yang tepat dan mempercepat pemeriksaan leukemia. Penelitian terapan juga dapat diartikan sebagai suatu tindakan aplikatif untuk pemecahan masalah tertentu.

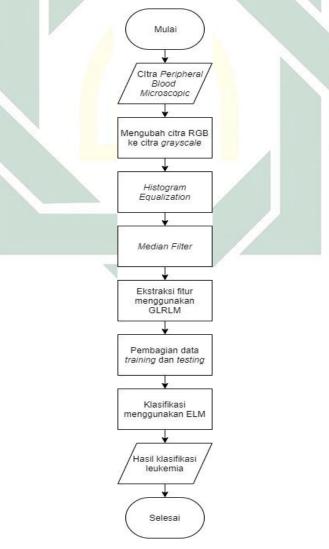
## 3.2. Data Penelitian

Data yang digunakan dalam penelitian ini adalah data citra sel darah peripheral blood microscopic. Jumlah data citra paru-paru sebanyak 161 data dengan 59 data normal, 49 data acute lymphoblastic leukemia dan 53 data chronic lymphoblastic leukemia. Citra peripheral blood microscopic diambil dari database Acute Lymphoblastic Leukemia Image Database for Image Processing pada tahun 2019. Data tersebut diperoleh dari Rumah Sakit S. Gerardo di Monza, Italia.. (Scotti, F., Piuri, V., & Labati, R. D., 2019)

## 3.3. Rancangan Penelitian

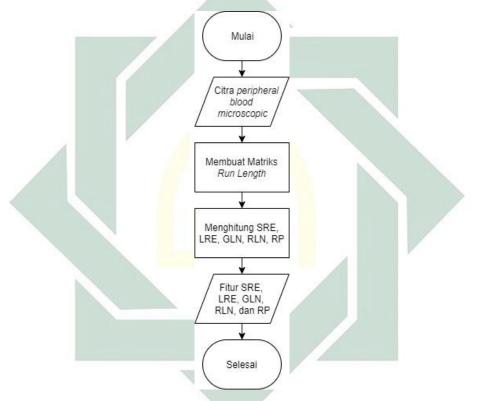
Rancangan penelitian ini ditunjukkan dalam diagram alir pada Gambar 3.1. Penelitian dilakukan melalui 3 tahapan yaitu *preprocessing*, ekstraksi fitur dan klasifikasi. Pertama, data citra *peripheral blood microscopic*. Data citra ini merupakan citra RGB. Penelitian ini menggunakan data citra *peripheral blood* 

microscopic yang berisikan keping darah. Proses selanjutnya memasuki tahapan preprocessing. Citra peripheral blood microscopic memiliki kualitas citra yang berbeda-beda sehingga perlu dilakukan proses preprocessing dengan tujuan untuk memperbaiki kualitas citra. Citra RGB diubah kedalam citra grayscale. Langkah selanjutnya perataan intensitas citra menggunakan histogram equalization. Proses ini dilakukan karena citra peripheral blood microscopic memiliki penyebaran intesitas piksel yang berbeda-beda. Selanjutnya dilakukan proses filtering menggunakan median filter Persamaan 2.3. Filtering dilakukan dengan tujuan mampu menghilangkan noise yang terdapat pada citra.



Gambar 3.1 Diagram Alir Rencana Pelaksanaan Penelitian

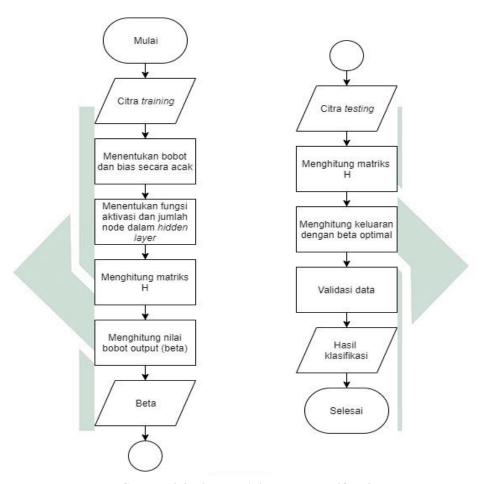
Setelah citra diperbaiki, dilakukan ekstraksi fitur menggunakan *gray level run length* (GLRLM) untuk mendapatkan fitur-fitur yang terdapat pada citra. Pada penelitian ini menggunakan orientasi arah  $0^0$ ,  $45^0$ ,  $90^0$  dan  $135^0$  untuk pembentukan matriks *run length*. Fitur diperoleh melalui Persamaan 2.4 - 2.8. Fitur-fitur ini digunakan sebagai *inputan* dalam proses klasifikasi. Langkah-langkah ekstraksi fitur GLRLM ditampilkan dalam *flowchart* yang ditunjukkan pada Gambar 3.2



Gambar 3.2 Diagram Alir GLRLM

Tahapan ekstraksi fitur menggunakan GLRLM dilakukan sengan membentuk matriks  $run\ length$  menggunakan  $p(i,j|\theta)$  dengan i adalah tingkat keabuan, j adalah jumlah kemunculan  $run\ length$  dan  $\theta$  adalah arah orientasi arah. Dari matriks tersebut diambil ciri-ciri statistik yang diperoleh menggunakan Persamaan 2.4 - 2.8. Fitur-fitur ini yang digunakan sebagai masukkan untuk proses klasifikasi. Proses selanjutnya adalah pembagian data menjadi dua yaitu data training dan data testing. Data yang digunakan dalam proses

training/pembelajaran adalah data training, sedangkan data testing digunakan pada proses testing. Pembagian data dilakukan menggunakan k-fold cross validation. Data training ditujukan untuk proses pembelajaran sistem klasifikasi. Data testing ditujukan untuk pengujian hasil klasifikasi.



Gambar 3.3 Diagram Alir Proses Klasifikasi

Proses pembelajaran dilakukan menggunakan merode *Extreme Learning Machine* (ELM). Matriks *inputan* pada ELM diproses dengan bobot dan bias yang telah diinisialisasi terlebih dahulu untuk memperoleh keluaran dari *hidden layer*. Fungsi aktifasi digunakan untuk memperoleh keluaran dari *hidden layer*. Keluaran *hidden layer* berupa matriks *H* yang diperoleh dari Persamaan 2.13. Kemudian, mencari *pseudo inverse* dari matriks tersebut. Matriks *pseudo inverse* tersebut

digunakan untuk menghitung nilai bobot beta  $(\beta)$  menggunakan persamaan 2.14. Setelah diperoleh  $\beta$ , proses selanjutnya adalah pelatihan. Pelatihan dilakukan menggunakan data *testing* dengan nilai bobot dan bias yang sama seperti proses pembelajaran. Kemudian menghitung matriks H dari data *testing* tersebut. Matriks H tersebut dikalian dengan  $\beta$  sehingga diperoleh hasil klasifikasi. Langkah-langkah proses klasifikasi disajikan pada Gambar 3.3

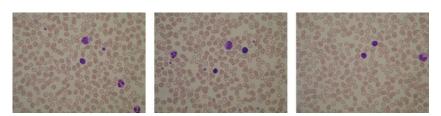


## **BAB IV**

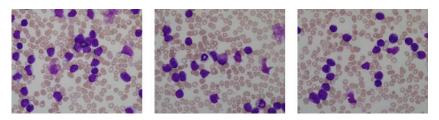
## HASIL DAN PEMBAHASAN

## 4.1. Preprocessing Citra

Pada penelitian ini, sistem klasifikasi leukemia dirancang menggunakan Extreme Learning Machine berdasarkan citra peripheral blood microscopic. Citra peripheral blood microscopic diperoleh dari Acute Lymphoblastic Leukemia Image Database for Image Processing (ALL-IDB). Dataset ini terdiri dari 161 citra peripheral blood microscopic dengan 49 data citra darah Acute Lymphoblastic Leukemia, 53 data citra chronic lymphoblastic leukemia dan 59 data citra darah normal. Data tersebut dikumpulkan sejak September 2005. Data ini berisi sekitar 39000 elemen darah, dimana masing-masing sel limfosit telah diberi label oleh ahli onkologi. Pengambilan citra peripheral blood microscopic dilakukan dengan pembesaran mikroskop yang berbeda mulai dari 300 hingga 500 kali. Semua citra tersebut dalam format JPG dengan resolusi 2592 × 1944. Berikut sampel data dari berbagai tingkatan lymphoblastic leukemia ditunjukkan dalam Gambar 4.1



Gambar 4.1 Sampel Citra Peripheral Blood Microscopic Darah Normal



Gambar 4.2 Sampel Citra Peripheral Blood Microscopic Darah ALL



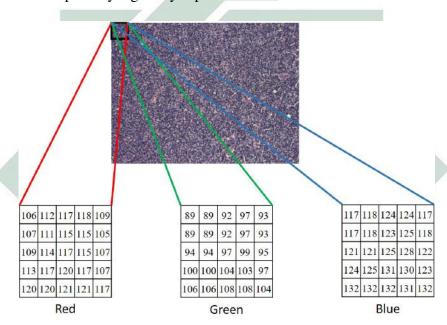
Gambar 4.3 Sampel Citra Peripheral Blood Microscopic Darah CLL

Citra peripheral blood microscopic digunakan sebagai inputan dalam sistem klasifikasi leukemia menggunakan Extreme Learning Machine. Tahapan yang dilakukan yaitu preprocessing, ektraksi fitur dan klasifikasi. Tahapan pertama adalah preprocessing. Citra peripheral blood microscopic yang telah diperoleh tidak dapat diolah secara langsung karena kualitas masing-masing citra tersebut belum memenuhi standar pengolahan. Citra yang diperoleh memiliki intensitas yang bervariasi sehingga mengakibatkan pencahayaan yang tidak merata dan kontras yang lemah. Selain itu, terdapat noise pada citra yang dapat mengganggu dalam proses pengolahan. Oleh karena itu, perlu dilakukan proses preprocessing untuk memperbaiki kualitas citra. Tahapan-tahapan yang dilakukan dalam preprocessing berupa proses grayscale, histogram equalization. Penjelasan lebih rinci mengenai masing-masing tahapan dalam preprocessing:

## 4.1.1. Grayscale

*Grayscale* merupakan proses perubahan citra RGB menjadi citra *grayscale*. Proses *grayscale* bertujuan untuk mengambil gambar berskala abu-abu sehingga

dapat memudahkan dalam proses pengoalahan. Pengubahan RGB menjadi grayscale dilakukan menggunakan persamaan 4.5. Maka, contoh perhitungan RGB ke grayscale dengan satu sampel data disajikan dibawah ini. Gambar 4.4 menunjukkan pengambilan nilai red (R), green (G), blue (B). R adalah matriks yang berisi komponen yang menyimpan warna merah dari citra tersebut, G adalah matriks yang berisi komponen yang menyimpan warna hijau dan B adalah matriks yang berisi komponen yang menyimpan warna biru.



Gambar 4.4 komponen R, komponen G, dan komponen B dari sampel citra normal

Sehingga untuk citra pada piksel (1,1) dapat dihitung sebagai berikut:

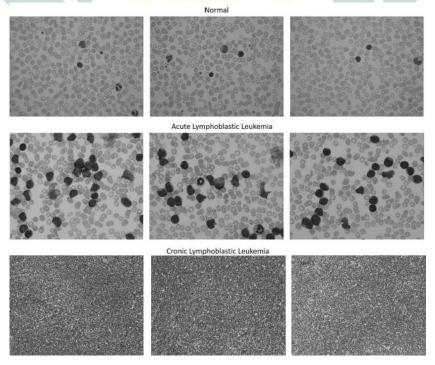
$$Gray(1,1) = 0.299 \times 106 + 0.587 \times 89 + 0.114 \times 117 = 97$$
  
 $Gray(1,2) = 0.299 \times 112 + 0.587 \times 89 + 0.114 \times 118 = 99$   
 $Gray(1,3) = 0.299 \times 117 + 0.587 \times 92 + 0.114 \times 124 = 103$   
 $Gray(1,4) = 0.299 \times 118 + 0.587 \times 97 + 0.114 \times 124 = 106$   
 $Gray(1,5) = 0.299 \times 109 + 0.587 \times 93 + 0.114 \times 117 = 101$ 

Proses di atas dilakukan pada setiap baris dan kolom sehingga membentuk matriks

gray seperti dibawah ini.

$$gray = \begin{bmatrix} 97 & 99 & 103 & \dots & 104 & 105 & 143 \\ 98 & 99 & 102 & \dots & 105 & 105 & 142 \\ 102 & 103 & 106 & \dots & 105 & 105 & 144 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 141 & 139 & 136 & \dots & 90 & 91 & 83 \\ 130 & 128 & 127 & \dots & 85 & 87 & 84 \\ 121 & 118 & 119 & \dots & 78 & 84 & 80 \end{bmatrix}$$

Matriks gray berukuran  $1040 \times 1388$ . Terdapat 161 matriks gray karena pada penelitian ini menggunakan 161 data citra  $peripheral\ blood\ microscopic$ . Setelah diperoleh matriks gray, langkah selanjutnya adalah  $histogram\ equalization$ .



Gambar 4.5 Sampel Citra Setelah Proses Grayscale

## 4.1.2. Histogram Equalization

Selanjutnya dilakukan proses histogram equalitation. Tujuan dilakukan histogram equalitation yaitu untuk meratakan intensitas cahaya pada citra. Histogram equalitation diperlukan karena data yang diolah memiliki intensitas cahaya yang beragam. Tahap-tahap yang dilakukan dalam histogram equalitation. Selain untuk meratakan cahaya, histogram equalitation juga dapat membuat citra menjadi lebih tajam sehingga mempermudah proses identifikasi fitur. Tahapan histogram equalitation dijelaskan sebagai berikut.

Langkah pertama yaitu menghitung kemunculan dari masing-masing tingkat keabuan pada sebuah citra. Pada proses ini dilakukan pencarian jumlah kemunculan tingkat keabuan pada sebuah citra. Sebagai contoh pada citra berukuran  $5 \times 5$  yang berisi tingkat keabuan seperti yang ditunjukkan pada matriks I.

$$I = \begin{bmatrix} 97 & 99 & 103 & 106 & 101 \\ 98 & 99 & 102 & 106 & 99 \\ 102 & 103 & 106 & 107 & 102 \\ 107 & 108 & 112 & 110 & 103 \\ 113 & 113 & 115 & 115 & 111 \end{bmatrix}$$

Berdasarkan pada matriks *I*, terlihat bahwa jumlah tingkat keabuan yang bernilai 99 sebanyak 3 kemunculan. Tingkat keabuan sama dengan 100 muncul sebanyak 0, dan tingkat keabuan bernilai 101 sebanyak 1 kemunculan. Perhitungan serupa dilakukan pada setiap matriks *gray*. Perhitungan pada salah satu matrik *gray* ditunjukkan pada tabel 4.3

Tabel 4.1 Proses Perhitungan Kemunculan Tingkat Keabuan Dalam Sebuah Citra

Gray	0	1	 34	35	 244	245
n	0	0	 10	17	 3	1

Proses selanjutnya adalah menghitung peluang suatu tingkat keabuan terhadap banyaknya elemen pada matriks *gray*. Proses perhitungan peluang dilakukan dengan membagi jumlah kemunculan pada masing masing tingkat keabuan dengan jumlah elemen pada matriks *gray* yang dituliskan dalam Persamaan 4.1

$$s = \sum_{i=0}^{k} \frac{n}{N} \tag{4.1}$$

dengan n = jumlah kemunculan tingkat keabuan dan N adalah banyaknya elemen dalam array. Untuk hasil selengkapnya dapat dilihat pada Tabel 4.3

Tabel 4.2 Proses Perhitungan Peluang

Gray	0	1	1	34	35	,/	244	245
n	0	0		10	17		3	1
S	0	0		0.0000069	0.0000118	/*	0.0000021	0.0000007

Selanjutnya, peluang dikalikan dengan maksimal tingkat keabuan yang terdapat pada citra *gray* sebesar 245. Sehingga perhitungan menjadi seperti berikut

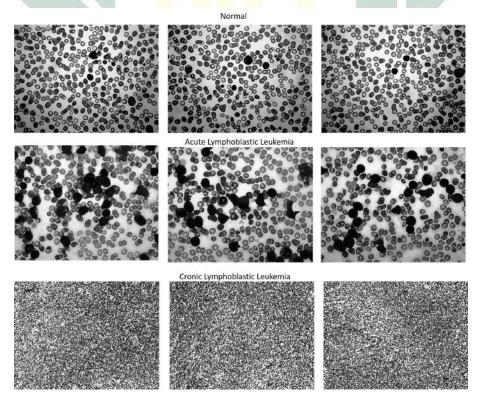
Tabel 4.3 Proses Histogram Equalization

Gray	0	1	 34	35	 244	245
n	0	0	 10	17	 3	1
S	0	0	 0.0000069	0.0000118	 0.0000021	0.0000007
gray(baru)	0	0	 33	34	 242	244

sehingga matriks citra setelah dilakukan *histogram equalization* menjadi seperti dibawah ini

$$histo = \begin{bmatrix} 109 & 113 & 125 & \dots & 16 & 73 & 142 \\ 109 & 113 & 121 & \dots & 20 & 81 & 154 \\ 121 & 125 & 134 & \dots & 73 & 146 & 194 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 215 & 210 & 202 & \dots & 89 & 93 & 69 \\ 190 & 186 & 182 & \dots & 73 & 81 & 73 \\ 170 & 162 & 166 & \dots & 53 & 73 & 61 \end{bmatrix}$$

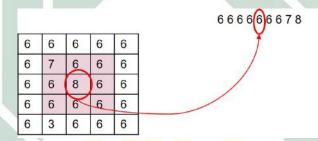
Matriks histo berukuran  $104 \times 1388$ . Sampel citra yang telah melalui proses histogram equalization ditampilkan dalam Gambar 4.6



Gambar 4.6 Sampel Citra Setelah Proses Histogram equalization

#### 4.1.3. Median Filter

Proses selanjutnya adalah *median filter*. *Median filter* digunakan untuk menghilangkan *noise* yang terdapat pada citra. *Noise* yang sering muncul adalah *salt* dan *pepper*. Pada penelitian ini, *median filter* dilakukan menggunakan *window*  $3 \times 3$ . Selanjutnya dicari nilai *median* dari piksel yang terdapat didalam *window* tersebut. Pencarian median dilakukan dengan mengurutkan nilai dari terkecil hingga terbesar. Kemudian, dicari nilai tengah dari urutan tersebut. berikut ilustrasi perhitungan *median filter* yang ditunjukkan pada Gambar 4.7

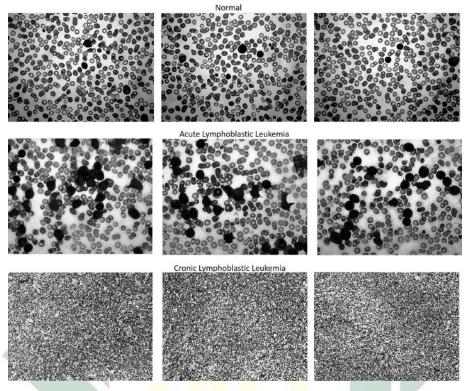


Gambar 4.7 Perhitungan Manual Median Filter

Untuk *median filter* dari matriks *gray*, dilakukan hal yang sama seperti contoh di atas. Sehingga terbentuk matriks baru setelah proses *median filter* yang berukuran  $1040 \times 1388$  yang ditampilkan dibawah ini.

$$median filter = \begin{bmatrix} 0 & 109 & 113 & \dots & 16 & 73 & 142 \\ 109 & 121 & 125 & \dots & 20 & 81 & 154 \\ 113 & 125 & 134 & \dots & 73 & 146 & 194 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 190 & 210 & 210 & \dots & 81 & 81 & 69 \\ 170 & 186 & 186 & \dots & 73 & 73 & 69 \\ 0 & 166 & 166 & \dots & 45 & 61 & 0 \end{bmatrix}$$

Berikut citra setelah dilakukan proses median filter.

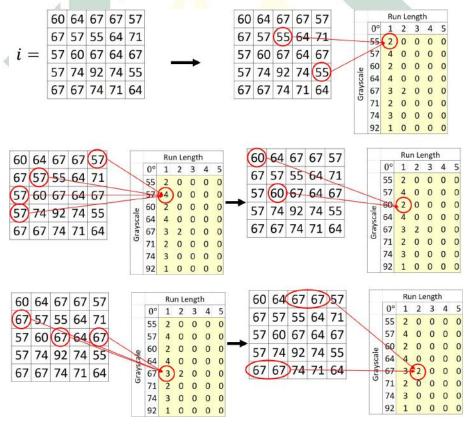


Gambar 4.8 Sampel Citra Setelah Proses Median Filter

#### 4.2. Ekstraksi Fitur

Ekstraksi fitur adalah sebuah proses yang dilakukan untuk mengambil informasi khusus yang dimiliki oleh sebuah citra. Fitur-fitur tersebut yang menjadi karakteristik dari sebuah citra sehingga citra tersebut dapat dikelompokkan dengan benar berdasarkan karakteristik yang diperoleh. Pengambilan fitur/analisis tekstur citra peripheral blood microscopic dilakukan menggunakan GLRLM. Konsep dari GLRLM yaitu dengan membagi citra menjadi beberapa tingkatan, sehingga dapat terlihat tekstur dari sebuah citra. GLRLM merupakan metode ekstaksi fitur dengan menggunakan matriks run length yang merepresentasikan jumlah total kemunculan run yang memiliki panjang dari tingkat keabuan dalam sebuah orientasi arah.

Pada penelitian ini, matriks  $run\ length$  dibentuk dari setiap orientasi arah yaitu  $0^{\circ}, 45^{\circ}, 90^{\circ}$  dan  $135^{\circ}$ , sehingga terdapat empat buah matriks  $run\ length$ . Perhitungan ekstraksi fitur dilakukan pada masing-masing matriks  $run\ length$ , sehingga setiap matriks memiliki 5 fitur. Langkah-langkah ekstraksi fitur menggunakan GLRLM dijelaskan berikut. Matriks  $run\ length$  dibangun dari citra  $peripheral\ blood\ microscopic$  yang diperoleh dari proses preprocessing. Contoh pembentukan matriks  $run\ length$  dari sebuah citra I. Asumsikan I adalah matriks hasil proses preprocessing dari citra  $peripheral\ blood\ microscopic$  yang ditunjukkan dalam dibawah ini. Selanjutnya hitung jumlah total kemunculan run yang memiliki panjang j dari tingkat keabuan i dalam sebuah orientasi arah  $0^{\circ}$ .



Gambar 4.9 Pembentukan Matriks Run Length

Dengan cara yang sama, bentuk matriks run length dari matriks median filter

berikut ini dengan orientasi arah 0°, 45°, 90° dan 135°.

$$median filter = \begin{bmatrix} 0 & 109 & 113 & \dots & 16 & 73 & 142 \\ 109 & 121 & 125 & \dots & 20 & 81 & 154 \\ 113 & 125 & 134 & \dots & 73 & 146 & 194 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 190 & 210 & 210 & \dots & 81 & 81 & 69 \\ 170 & 186 & 186 & \dots & 73 & 73 & 69 \\ 0 & 166 & 166 & \dots & 45 & 61 & 0 \end{bmatrix}$$

Sehingga diperoleh matriks *run length* dari masing-masing orientasi arah sebesar 0, 45, 90 dan 135 dengan dengan ukuran, sebagai berikut.

Apabila telah terbentuk matriks *run length*, maka proses selanjutnya adalah pengambilan fitur menggunakan Persamaan 2.4 - 2.8. Perhitungan fitur dari matriks

 $run\ length\ dengan\ orientasi\ arah\ 0^0\ ditunjukkan\ di\ bawah\ ini.$ 

$$SRE_{0} = \frac{\left(\left(\frac{860}{1^{2}}\right) + \left(\frac{1081}{2^{2}}\right) + \dots + \left(\frac{0}{1388^{2}}\right)\right) + \left(\left(\frac{0}{1^{2}}\right) + \left(\frac{0}{2^{2}}\right) + \dots + \left(\frac{0}{13^{2}}\right)\right) + \dots + \left(\left(\frac{1331}{1^{2}}\right) + \left(\frac{1377}{2^{2}}\right) + \dots + \left(\frac{0}{13^{2}}\right)\right)}{203781}$$

$$= 0.550$$

$$LRE_{0} = \frac{\left(\left(869 \times 1^{2}\right) + \dots + \left(0 \times 1388^{2}\right)\right) + \left(\left(0 \times 1^{2}\right) + \dots + \left(0 \times 1388^{2}\right)\right) + \dots + \left(\left(1331 \times 1^{2}\right) + \dots + \left(0 \times 13^{2}\right)\right)}{203781}$$

$$= 9.4173$$

$$GLN_{0} = \frac{\left(\left(860 + 1081 + \dots + 0\right)^{2} + \left(0 + 0 + \dots + 0\right)^{2} + \dots + \left(1331 + 1377 + \dots + 0\right)^{2}\right)}{203781}$$

$$= 658321.805$$

$$RLN_{0} = \frac{\left(\left(860 + 0 + \dots + 0 + 1331\right)^{2} + \left(1081 + 0 + \dots + 0 + 1377\right)^{2} + \dots + \left(818 + 0 + \dots + 0 + 1119\right)^{2}\right)}{203781}$$

$$= 67025.14$$

$$RP_{0} = \frac{\left(\left(860 + 1081 + \dots + 0\right) + \left(0 + 0 + \dots + 0\right) + \dots + \left(1331 + 1377 + \dots + 0\right)\right)}{94720}$$

$$= 3.334$$

Perhitungan serupa juga dilakukan pada orientasi arah lain yaitu  $45^{\circ}$ ,  $90^{\circ}dan135^{\circ}$ . Fitur di atas merupakan fitur yang diperoleh dari satu citra. Hal serupa dilakukan pada citra-citra yang lain. Berikut sampel fitur dari duabelas citra pada orientasi arah  $0^{\circ}$  yang disajikan dalam tabel 4.4

Tabel 4.4 Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah  $0^{0}$ 

Citra Ke -	SRE	LRE	GLN	RLN	RP	Kelas
1	0.550	9.417	658321.805	67025.136	3.335	Normal
2	0.544	9.991	638747.423	69185.604	3.291	Normal
3	0.547	9.768	648506.486	64299.421	3.313	Normal
4	0.536	10.499	612690.380	65939.087	3.234	Normal
5	0.634	7.653	437172.782	27380.224	2.658	ALL
6	0.625	7.936	417708.780	28055.258	2.609	ALL
7	0.558	11.821	308205.678	44053.685	2.316	ALL
8	0.630	7.799	429279.555	30373.273	2.641	ALL
9	0.865	2.068	813890.113	19528.020	3.256	CLL
10	0.857	2.100	787277.598	19664.787	3.222	CLL
11	0.851	2.063	774658.421	19817.337	3.221	CLL
12	0.852	2.009	780040.346	19844.478	3.239	CLL

Nilai SRE dipengaruhi oleh banyaknya *short run* dan diharapkan bernilai besar pada teksture yang halus. Sedangkan tekstur kasar memiliki *run* yang panjang karena memiliki banyak piksel tetangga dengan intentisas yang sama. Nilai SRE berbanding terbalik dengan *run*, semakin kecil *run* maka semakin besar nilai SRE yang artinya citra tersebut memiliki tekstur yang halus. Berdasarkan tabel diatas, citra darah normal memiliki nilai SRE yang lebih kecil dibandingkan dengan nilai SRE dari citra darah pasien ACL dan nilai SRE citra pasien ACL lebih kecil dibanding citra pasien CLL. Hal ini menunjukkan bahwa citra darah normal lebih memiliki tekstur yang lebih kasar dibandingkan dengan citra yang lainnya. Terlihat pada citra normal memiliki *run* yang semakin besar. Berbeda dengan citra pasien CLL yang memiliki *run* semakin kecil.

Tabel 4.5 Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah  $45^{\circ}$ 

					<b>X</b>	
Citra Ke -	SRE	LRE	GLN	RLN	RP	Kelas
1	0.681	5.227	1243921.475	70292.088	5.803	Normal
2	0.681	5.263	1240884.432	68132.374	5.791	Normal
3	0.673	5.366	1194898.094	70807.929	5.702	Normal
4	0.674	5.460	1193293.113	64281.495	5.684	Normal
5	0.652	6.569	1062183.896	70924.965	5.369	ALL
6	0.638	7.977	994323.668	81187.937	5.225	ALL
7	0.615	7.706	896530.459	77457.029	5.020	ALL
8	0.630	7.362	957349.216	73698.083	5.149	ALL
9	0.872	1.783	853083.425	20016.612	4.491	CLL
10	0.866	1.844	832195.576	20203.169	4.444	CLL
11	0.869	1.794	843895.109	20539.919	4.479	CLL
12	0.874	1.735	864188.472	20657.115	4.524	CLL

Nilai LRE dipengaruhi oleh jumlah *long run*. Citra dengan tektur kasar memiliki nilai LRE yang besar karena memiliki *run* yang panjang dan nilai *run* berbanding lurus dengan besar nilai LRE. Citra dengan teksture kasar memiliki nilai LRE yang lebih besar dibandingkan dengan citra dengan tektur halus karena citra dengan tekstur kasar memiliki *run* yang lebih panjang dibandingkan citra dengan tekstur halus. Berdasarkan tabel di atas menunjukkan bahwa citra darah normal memiliki nilai LRE yang lebih besar dibandingkan

citra darah pasien ACL dan citra pasien ACL memiliki nilai LRE yang lebih bedar dibandingkan citra pasien CLL. Nilai LRE terbesar dimiliki oleh citra darah normal artinya citra ini bertekstur kasar. Hal ini bersesuai dengan nilai SRE yang kecil. Sedangkan nilai LRE citra pasien CLL memiliki nilai yang paling sedikit yaitu sekitar 2.06 artinya citra pasien CLL memiliki tektur yang halus. Hal ini terjadi karena jumlah long rung yang sedikit. Sampel fitur dari 12 citra pada orientasi arah 45° yang disajikan dalam tabel 4.5

Berdasarkan Tabel 4.5, nilai SRE terendah terletak pada citra ALL. Nilai SRE pada citra normal lebih besar daripada citra ALL dan tidak lebih besar pada citra CLL artinya tekstur dari citra normal adalah sedang, citra CLL memiliki tekstur halus dan citra ALL memiliki tektur yang kasar. Nilai LRE dari citra CLL lebih rendah daripada citra normal. Citra normal memiliki LRE yang lebih kecil dari citra ALL. Hal ini menunjukkan bahwa citra ALL memiliki tekstur yang kasar daripada citra normal dan CLL. Berikut sampel fitur dari 12 citra pada orientasi arah 90° yang disajikan dalam tabel 4.6

Tabel 4.6 Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah  $90^{\circ}$ 

Citra Ke -	SRE	LRE	GLN	RLN	RP	Kelas
1	0.555	9.610	661119.828	66337.063	4.429	Normal
2	0.548	10.065	638076.047	68296.921	4.361	Normal
3	0.552	9.953	649727.580	63512.818	4.389	Normal
4	0.545	10.207	633304.212	65213.763	4.361	Normal
5	0.632	7.623	433186.756	27208.218	3.316	ALL
6	0.623	8.033	413256.159	27884.018	3.249	ALL
7	0.553	12.073	302911.844	43821.294	2.882	ALL
8	0.627	8.228	424015.320	30106.550	3.287	ALL
9	0.867	2.011	823299.910	19639.243	4.372	CLL
10	0.856	2.137	782572.651	19610.506	4.286	CLL
11	0.852	2.074	778318.347	19846.359	4.302	CLL
12	0.853	2.030	781749.211	19852.095	4.321	CLL

Berdasarkan Tabel 4.6, nilai SRE yang diperoleh pada citra CLL memiliki nilai yang lebih besar daripada SRE dari citra normal dan ALL. Nilai SRE dari citra normal lebih besar daripada citra ALL. Hal ini menunjukkan bahwa citra ALL memiliki tekstur

yang lebih kasar daripada citra normal dan CLL. Nilai LRE dari citra CLL lebih kecil daripada citra normal dan ALL dan nilai LRE citra ALL lebih besar dari citra normal artinya citra CLL memiliki tektur yang lebih halus dibandingkan citra normal dan ALL, sedangkan ALL memiliki tekstur paling kasar diantara yang lain. Hasil ini berbanding lurus dengan perolehan nilai SRE yang paling rendah. Sampel fitur dari 12 citra pada orientasi arah 1355<sup>0</sup> yang disajikan dalam tabel 4.7

Tabel 4.7 Sampel Hasil Ekstraksi Fitur Menggunakan GLRLM Pada Orientasi arah  $135^0$ 

		1100	10.7			
Citra Ke -	SRE	LRE	GLN	RLN	RP	Kelas
1	0.694	4.899	1313326.704	80081.676	5.921	Normal
2	0.675	5.229	1218445.035	74107.798	5.771	Normal
3	0.677	5.314	1221069.718	70469.334	5.757	Normal
4	0.680	5.243	197286.913	13020.581	2.752	Normal
5	0.638	7.982	997884.282	81188.466	5.233	ALL
6	0.619	7.602	915311.907	78073.381	5.065	ALL
7	0.634	7.187	975575.220	74179.079	5.190	ALL
8	0.647	7.186	1040370.027	72441.632	5.330	ALL
9	0.868	1.821	839090.499	19902.285	4.463	CLL
10	0.869	1.806	843023.889	20300.652	4.471	CLL
11	0.873	1.746	860302.394	20685.705	4.514	CLL
12	0.875	1.715	869519.424	20712.811	4.537	CLL

# 4.3. Klasifikasi Menggunakan Extreme Learning Machine

Extreme Learning Machine (ELM) digunakan untuk proses klasifikasi data yang diperoleh dari pengolahan citra sebelumnya. Proses klasifikasi terdiri dari dua tahap yaitu tahap training dan tahap testing. Tahap training dilakukan untuk membangun model terbaik sedangkan tahap testing dilakukan untuk menguji keakuratan model yang telah dibentuk. Pada penelitian ini menggunakan 128 data untuk tahap training dan 33 data untuk tahap testing. Training dan testing yang dilakukan menggunakan metode klasifikasi ELM. Pada penelitian ini, klasifikasi leukemia menggunakan lima parameter yang diperoleh dari ekstraksi fitur menggunakan GLRLM yaitu SRE, LRE, RLN, GLN, dan

RP yang nantinya akan dikelompokan kedalam tiga kelas yaitu normal, Acute Lymphoblastic Leukemia (ACL) dan Chronic Lymphoblastic Leukemia (ALL). Nilai fitur yang diperoleh memiliki range yang berbeda sehingga diperlukan proses normalisasi untuk mempermudah pada tahap training dan tahap testing.

## 1. Training

Tahap *training* dilakukan menggunakan data fitur yang diperoleh dari proses ekstraksi fitur menggunakan ELM dari 128 data yang terdiri dari 47 data normal, 39 data ACL, dan 42 data CLL. Pada tahap pelatihan ini memerlukan beberapa parameter dalam pembentukan sebuah jaringan seperti jumlah *node* dalam bobot *inputan*, *hidden layer*, fungsi aktivasi, bp, dan bobot bias. Berikut Algoritma klasifikasi menggunakan ELM:

a. Inisialisasi variabel dan parameter yang diperlukan.

 $x = x_1, x_2, x_3, \dots, x_m$ : sampel data training sebanyak m data

 $y = y_1, y_2, y_3, \dots, y_m$ : label data training/ target data training

 $w_{mm}$ : bobot inputan

 $b_{m1}$ : bobot bias

n: jumlah node pada hidden layer

Fungsi aktivasi : fungsi aktivasi yang digunakan

- b. Mencari matriks H menggunakan rumus yang terdapat pada subbab di tinjauan pustaka.
- c. Mencari pseudo invers dari matriks H
- d. Mencari bobot pada *hidden layer* ( $\beta$ )

Langkah pertama yang dilakukan adalah inisialisasi variabel dan parameter. Data hasil ekstraksi fitur yang digunakan sebagai parameter dalam klasifikasi ini antara lain SRE, LRE, GLN, RLN, dan RP. Variabel IW, b diperoleh secara acak. Pada

penelitian ini, dilakukan beberapa percobaan yaitu variasi arah orientasi GLRLM dan variasi jumlah neuron pada  $hidden\ layer$  yaitu 3-15 node. Berikut perhitungan manual dari klasifikasi ELM dengan 10 nod pada  $hidden\ layer$ , maka matriks IW berukuran  $5\times 10$ . Matriks b berukuran  $1\times 10$  dan matriks tersebut diperoleh secara acak dengan rentang  $[-1\ 1]$ 

$$w = \begin{bmatrix} 0.300 & -0.877 & 0.391 & 0.274 & \cdots & -0.559 \\ 0.788 & -0.177 & -1.000 & 0.377 & \cdots & 0.227 \\ 0.581 & 0.869 & -0.025 & -0.272 & \cdots & -0.483 \\ -0.977 & -0.929 & -0.509 & 0.292 & \cdots & -0.324 \\ 0.270 & 0.559 & 0.201 & 0.169 & \cdots & -0.076 \end{bmatrix}$$

$$b = \begin{bmatrix} -0.360 & -0.265 & -0.170 & 0.925 & \cdots & -0.274 \end{bmatrix}$$

langkah selanjutnya adalah mencari matriks H menggunakan persamaan 2.13

$$H(i,j) = g(x_{i,:}w_{:,j} + b_{j})$$

$$H(1,1) = g(x_{1,1:5}w_{1:5,1} + b_{1})$$

$$= sigmoid(g(x_{1,1:5}w_{1:5,1} + b_{1}))$$

$$= sigmoid((((-0.4096 * 0.3) + (-0.26 * 0.788) + \cdots + (1 * 0.27) + (-0.36)))$$

$$= \frac{1}{1 + e^{-0.6597}}$$

$$= 0.3408$$

$$\begin{split} H(1,2) &= g(x_{2,1:5}w_{1:5,2} + b_2) \\ &= sigmoid(g(x_{2,1:5}w_{1:5,2} + b_2)) \\ &= sigmoid((((-0.4096*(-0.877)) + (-0.26*(-0.177)) + \cdots \\ &+ (1*(0.559)) + (-0.265))) \\ &= \frac{1}{1 + e^{0.7813}} \\ &= 0.6860 \end{split}$$

Perhitungan di atas dilakukan terus menerus hingga sampai data ke-128, sehingga diperoleh matriks H yang berukuran 128 $\times$ 10. Berikut matriks H yang telah diperoleh

$$H = \begin{bmatrix} 0.341 & 0.686 & 0.421 & 0.702 & \cdots & 0.284 \\ 0.355 & 0.692 & 0.409 & 0.699 & \cdots & 0.338 \\ 0.384 & 0.70 & 0.417 & 0.695 & \cdots & 0.342 \\ 0.380 & 0.427 & 0.524 & 0.634 & \cdots & 0.703 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0.600 & 0.662 & 0.837 & 0.626 & \cdots & 0.238 \end{bmatrix}$$

Setelah diperoleh matriks H, langkah selanjutnya adalah menghitung output  $(\beta)$  menggunakan persamaan 2.13

$$\beta = H^{\dagger}T$$
$$= ((H^TH)^{-1}H^T)T$$

Sehingga diperoleh matrik  $\beta$  sebagai berikut

$$\beta = \begin{bmatrix} 2.324 & 0.377 & -20.593 & 2.923 & 0.605 & 20.032 & -21.224 & 13.396 & 7.499 & -14.191 \end{bmatrix}^T$$

## 2. Testing

Pada tahap ini, dilakukan proses testing menggunakan data testing sebanyak 33 data. Dari data tersebut, dihitung matriks H menggunakan bobot dan bias yang sama pada proses training menggunakan persamaan 2.13. Berikut matriks H dari proses testing ditampilkan dalam matrik berikut

$$H = \begin{bmatrix} 0.369 & 0.6931 & 0.4032 & 0.7001 & \cdots & 0.3437 \\ 0.3870 & 0.6977 & 0.051 & 0.7002 \cdots & 0.3369 \\ 0.4074 & 0.7323 & 0.4391 & 0.6897 & \cdots & 0.3140 \\ 0.3797 & 0.7125 & 0.166 & 0.6941 & \cdots & 0.3458 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0.6036 & 0.6669 & 0.8390 & 0.6250 & \cdots & 0.2344 \end{bmatrix}$$

Setelah diperoleh matriks H berukuran 33  $\times$  10, langkah selanjutnya adalah mencari output (T) menggunakan persamaan 2.12

$$T = H\beta$$

$$\begin{bmatrix} 0.369 & 0.6931 & 0.4032 & 0.7001 & \cdots & 0.3437 \\ 0.3870 & 0.6977 & 0.051 & 0.7002 \cdots & 0.3369 \\ 0.4074 & 0.7323 & 0.4391 & 0.6897 & \cdots & 0.3140 \\ 0.3797 & 0.7125 & 0.166 & 0.6941 & \cdots & 0.3458 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0.6036 & 0.6669 & 0.8390 & 0.6250 & \cdots & 0.2344 \end{bmatrix} \begin{bmatrix} 2.324 \\ 0.377 \\ -20.593 \\ 2.923 \\ 0.605 \\ 20.032 \\ -21.224 \\ 13.396 \\ 7.499 \\ -14.191 \end{bmatrix}$$

$$= \begin{bmatrix} -1 & -1 & \vdots & 1 \end{bmatrix}^{T}$$

Dari hasil klasifikasi tersebut, dilakukan evaluasi kinerja menggunakan akurasi, presisi dan recall dari sistem klasifikasi yang telah dibangun. Berikut hasil klasifikasi leukemia dengan percobaan  $hidden\ layer$  pada masing-masing orientasi arah GLRLM. Tabel 4.8 menunjukkan hasil klasifikasi leukemia pada orientasi arah  $0^0$  dengan percobaan jumlah node pada  $hidden\ layer$ .

Tabel 4.8 Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah  $0^0\,$  Menggunakan ELM

	Node Hidden	Precobaan	Akurasi	Presisi	Recall	
	Layer	Ke	Akulasi	FICSISI	Recall	
		1	58.06	58.79	58.79	
	3	2	21.21	7.78	23.33	
		3	56.25	57.74	58.33	
		1	83.85	84.35	83.37	ν,
	4	2	78.13	79.77	79.44	
		3	87.50	88.10	86.11	
		1	87.88	90.08	87.22	
	5	2	84.85	88.89	83.33	
		3	90.32	90.71	89.81	
		1	78.79	87.72	76.67	
	6	2	81.25	82.68	81.11	
		3	90.63	92.09	90.00	
1		1	83.87	89.58	83.33	
	7	2	90.63	92.86	90.74	
		3	87.50	89.83	87.22	
		1	90.63	93.33	88.89	
Ų	8	2	93.75	95.24	92.59	
		3	96.88	97.22	96.67	
		1	93.75	95.24	93.33	
	9	2	93.55	93.94	93.94	
		3	96.97	97.44	96.67	
		1	96.77	97.22	96.30	
	10	2	96.88	97.44	96.67	
		3	100.00	100.00	100.00	
		1	90.63	93.33	90.00	
	11	2	96.97	96.97	97.22	
		3	93.94	93.89	93.89	
		1	96.88	96.97	97.22	
	12	2	96.77	97.44	96.30	
		3	96.88	97.44	96.30	
		1	96.97	97.44	96.67	
	13	2	100.00	100.00	100.00	
		3	96.88	96.67	97.22	
		1	90.63	91.84	90.56	
	14	2	96.88	96.97	96.97	
		3	96.77	96.67	97.22	
		1	96.97	97.44	96.67	
	15	2	96.88	96.97	96.67	
		3	96.88	97.44	96.67	

Pada Tabel 4.8, kolom pertama menunjukkan variasi jumlah node pada *hidden layer*. Kolom kedua menunjukkan percobaan pengambilan bobot yang dilakukan tiga kali. Kolom tiga sampai lima menunjukkan hasil yang diperoleh dari evaluasi berupa akurasi, presisi dan recall dengan satuan persen. Model dikatakan sangat baik apabila memiliki nilai akurasi, presisi dan recall yang mencapai 100%. Berdasarkan tabel 4.8, hasil klasifikasi leukemia menggunakan fitur GLRLM dengan orientasi arah 00 menggunakan *extreme learning machine* diperoleh hasil terbaik pada 10 node *hidden layer* percobaan ketiga dan pada 13 node *hidden layer* percobaan kedua dengan akurasi masing-masing sebesar 100%, presisi sebesar 100% dan recall sebesar 100%. Karena memiliki nilai akurasi yang sama, maka digunakan indikator waktu untuk menentukan model mana yang terbaik.

Dari kedua model tersebut dipilih model dengan waktu tercepat. Klasifikasi dengan 10 node hidden layer pada percobaan ketiga memiliki waktu perhitungan selama 0.2 detik. Klasifikasi dengan 13 node hidden layer pada percobaan kedua memiliki waktu perhitungan selama 0.40 detik, sehingga yang menjadi model terbaik adalah model pada orientasi arah 00 dengan 10 node pada hidden layer dengan akurasi sebesar 100%, presisi sebesar 100% dan recall sebesar 100% dengan waktu perhitungan 0.2 detik. Model tersebut memiliki akurasi yang sangat tinggi menunjukkan bahwa model klasifikasi yang dilakukan sangat baik. Nilai recall dan presisi yang sangat tinggi menunjukkan seluruh data benar terklasifikasi pada masing-masing kelasnya. Selanjutnya dilakukan klasifikasi leukemia berdasarkan fitur GLRLM pada orientasi arah 450 menggunakan ELM. Tabel 4.9 menunjukkan hasil klasifikasi pada orientasi arah 450 dengan percobaan jumlah node pada hidden layer.

Tabel 4.9 Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah  $45^{0}$  Menggunakan ELM

Node Hidden Layer	Precobaan Ke	Akurasi	Presisi	Recall
	1	78.13	78.89	77.22
3	2	68.75	70.00	70.00
	3	84.38	86.35	83.89
4	1	93.75	95.24	93.33
	2	81.82	88.89	80.00
	3	87.50	91.67	86.67
5	1	93.94	95.24	93.33
	2	96.88	97.44	96.67
	3	87.88	88.69	87.22
	1	96.97	96.97	97.22
6	2	93.94	95.24	93.33
	3	93.94	94.44	93.89
	1	87.50	87.71	87.78
7	2	93.75	94.44	94.44
	3	90.63	93.33	88.89
8	1	96.67	97.22	96.30
	2	90.63	90.61	90.61
	3	93.94	93.89	93.89
9	1	96.77	96.67	97.22
	2	93.94	94.19	94.44
	3	96.77	96.97	96.97
	1	93.75	93.89	93.89
10	2	96.97	97.44	96.67
	3	93.55	93.64	93.64
	1	93.94	94.19	94.44
11	2	96.97	96.97	97.22
	3	90.91	91.17	90.56
12	1	93.55	94.87	93.33
	2	100.00	100.00	100.00
	3	96.77	96.97	96.97
13	1	90.91	92.31	91.67
	2	96.77	97.22	96.97
	3	100.00	100.00	100.00
	1	96.97	97.44	96.67
14	2	96.77	96.67	97.22
	3	87.50	88.33	88.33
	1	96.97	96.97	97.22
15	2	90.63	90.91	91.11
	3	99.22	99.17	99.29

Berdasarkan tabel 4.9, hasil klasifikasi leukemia dengan fitur GLRLM orientasi arah 45° menggunakan ELM diperoleh hasil terbaik pada 12 node *hidden layer* percobaan kedua dan pada 13 node *hidden layer* percobaan ketiga dengan akurasi sebesar 100%, presisi sebesar 100% dan recall sebesar 100%. Dari kedua model tersebut dipilih model dengan waktu tercepat. Klasifikasi dengan 12 node *hidden layer* percobaan kedua memiliki waktu perhitungan selama 0.32 detik. Klasifikasi dengan 13 node

hidden layer percobaan ketiga memiliki waktu perhitungan selama 0.40 detik.

Tabel 4.10 menunjukkan hasil klasifikasi pada orientasi arah  $90^0$  dengan percobaan jumlah node pada  $hidden\ layer.$ 

Tabel 4.10 Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah  $90^{0}\,$  Menggunakan ELM

		100			
	Node Hidden Layer	Precobaan Ke	Akurasi	Presisi	Recall
		1	84.38	86.35	83.89
	3	2	93.75	94.44	93.52
		3	68.75	70.00	70.00
	4	1	81.82	88.89	80.00
		2	87.50	91.67	86.67
		3	71.88	76.67	74.07
	5	1	93.75	95.24	93.33
		2	87.88	88.69	87.22
		3	90.63	93.33	90.00
	6	1	84.38	87.18	83.64
		2	87.88	91.67	86.67
		3	90.32	91.84	90.00
		1	87.50	91.11	86.67
	7	2	90.32	92.86	90.00
		3	87.10	89.28	86.97
		1	93.55	94.87	92.59
	8	2	93.75	93.89	93.89
		3	93.94	95.24	93.33
	9	1	96.88	96.97	97.22
-		2	93.33	94.87	92.59
		3	90.91	91.17	90.56
	10	1	90.63	93.33	88.89
		2	93.94	93.89	93.89
		3	96.88	97.44	96.67
	11	1	93.75	93.89	93.64
		2	93.55	94.19	93.27
		3	93.55	93.94	93.64
	12	1	96.97	97.44	96.67
		2	93.94	93.89	93.89
		3	93.94	94.19	94.44
	13	1	96.77	97.22	96.67
		2	100.00	100.00	100.00
		3	93.94	94.44	94.44
	14	1	96.97	97.44	96.67
		2	87.88	91.67	86.67
		3	100.00	100.00	100.00
		1	96.88	96.97	97.22
	15	2	93.75	93.89	93.89
		3	93.75	95.24	93.33

Berdasarkan tabel 4.10, hasil klasifikasi leukemia berdasarkan fitur GLRLM orientasi arah  $90^0$  menggunakan ELM diperoleh hasil terbaik pada 13 node *hidden* 

layer percobaan kedua dengan waktu perhitungan selama 0.31 detik dan pada 14 node hidden layer percobaan ketiga dengan waktu perhitungan selama 0.22 detik. Kedua model tersebut memiliki akurasi masing-masing sebesar 100%, presisi sebesar 100% dan recall sebesar 100% yang menunjukkan kinerja dari model yang dibangun sudah baik karena memiliki nilai recall dan presisi yang tinggi artinya data telah benar terklasifikasi pada masing-masing kelasnya.

Tabel 4.11 Hasil Klasifikasi Leukemia Berdasarkan Fitur GLRLM Orientasi Arah  $135^{0}$  Menggunakan ELM

	Node Hidden Layer	Precobaan Ke	Akurasi	Presisi	Recall
		1	62.50	57.94	62.22
	3	2	93.75	94.44	93.52
		3	68.75	70.00	70.00
		1	90.63	93.33	90.00
	4	2	81.82	88.89	80.00
		3	81.82	86.81	80.56
		1	84.38	84.93	85.56
	5	2	62.50	63.33	63.89
		3	93.75	93.89	93.89
		1	87.50	88.14	86.97
7	6	2	90.63	90.91	91.11
		3	93.94	94.44	93.89
		1	96.77	97.44	96.30
	7	2	90.63	92.86	90.00
		3	90.32	90.74	90.30
ľ		1	93.75	95.24	92.59
	8	2	100.00	100.00	100.00
		3	90.63	92.09	89.81
		1	90.91	93.33	90.00
	9	2	93.75	94.44	94.44
		3	90.91	91.17	90.56
		1	96.88	96.67	97.22
	10	2	100.00	100.00	100.00
		3	96.97	97.44	96.67
		1	93.94	93.89	93.89
	11	2	90.91	93.33	90.00
		3	93.75	93.94	94.44
		1	96.97	96.97	97.22
	12	2	96.88	97.06	96.73
		3	96.77	97.22	96.67
		1	100.00	100.00	100.00
	13	2	90.32	92.31	90.91
		3	96.88	97.44	96.67
		1	96.97	96.97	96.97
	14	2	96.97	96.97	97.22
		3	93.75	93.73	93.27
		1	96.77	97.44	96.30
	15	2	93.75	93.52	93.52
		3	96.88	96.67	97.22

Hasil Klasifikasi leukemia berdasarkan fitur GLRLM dengan orientasi arah 1350 menggunakan ELM ditunjukkan dalam Tabel 4.11. Berdasarkan Tabel 4.11 diperoleh hasil terbaik pada 8 node *hidden layer* percobaan kedua, 10 node percobaan kedua dan pada 13 node *hidden layer* percobaan pertama dengan akurasi sebesar 100%, presisi sebesar 100% dan recall sebesar 100%. Klasifikasi menggunakan 8 node memerlukan waktu sebanyak 0.37 detik, 10 node memerlukan waktu sebanyak 0.19 detik dan 13 node memerlukan waktu sebanyak 0.56 detik. Model dengan 10 node memiliki waktu perhitungan tercepat, sehingga model tersebut menjadi model terbaik. Kinerja dari model yang dibangun sudah baik karena memiliki nilai recall yang tinggi artinya sebagian data benar terklasifikasi pada masing-masing kelasnya. Masing-masing arah orientasi memiliki model terbaik dengan jumlah node *hidden layer* yang berbeda-beda.

# **BAB V**

# **PENUTUP**

Pada bab ini akan diberikan simpulan dan saran-saran yang dapat diambil berdasarkan materi-materi yang telah dibahas pada bab-bab sebelumnya.

### 5.1. Simpulan

Simpulan yang dapat diambil penulis setelah menyelesaikan pembuatan skripsi ini adalah :

- Proses histogram equalization mampu meratakan intensitas cahaya pada citra
   peripheral blood microscopic juga mampu mempertajam citra tersebut. Metode
   histogram equalization mampu menyebarkan intensitas cahaya secara merata.
   Sedangkan metode median filter mampu menghilangkan noise seperti noise salt dan
   pepper yang terdapat pada citra peripheral blood microscopic.
- Metode ekstaksi fitur GLRLM digunakan untuk menganalisis citra peripheral blood microscopic. Berdasarkan hasil ekstraksi fitur menunjukkan bahwa citra peripheral blood microscopic ALL memiliki tektur paling kasar dan citra CLL memiliki tekstur paling halus diantara tiga tekstur tersebut.
- 3. Klasifikasi leukemia menggunakan ELM menujukkan kinerja yang sangat baik. Metode ini memiliki tingkat akurasi yang sangat baik. Hasil klasifikasi leukemia kedalam tiga kelas yaitu normal, ALL dan CLL memperoleh hasil terbaik dari masing-masing arah orientasi.Pada orientasi arah 0 diperoleh hasil terbaik dengan jumlah neuron pada hidden layer sebanyak 13. Pada orientasi arah 45 diperoleh hasil terbaik dengan jumlah neuron pada hidden layer sebanyak 12. Pada orientasi

arah 90 diperoleh hasil terbaik dengan jumlah neuron pada hidden layer sebanyak 14. Pada orientasi arah 135 diperoleh hasil terbaik dengan jumlah neuron pada hidden layer sebanyak 13. Masing - masing diperoleh akurasi sebesar 100%, presisi sebesar 100% dan recall 100% Dari hasil yang diperoleh menunjukkan bahwa kinerja dari metode klasifikasi ELM pada citra *peripheral blood microscopic* sangat baik.

#### 5.2. Saran

Setelah membahas dan mengimplementasikan aplikasi *normally flat content* semimodules, penulis ingin menyampaikan beberapa saran.

- 1. Perlu dilakukan pecobaan beberapa metode preprocessing untuk memperbaiki kualitas citra dalam menghadapi permasalahan yang lain.
- 2. Variasi fungsi aktivasi ju<mark>ga</mark> patut dipertimbangkan dalam membangun sebuah model klasifikasi

# **DAFTAR PUSTAKA**

- Ahmad, U. (2005). Pengolahan Citra Digital dan Teknik Pemrogramannya. Yogyakarta: Graha Ilmu.
- Alfiyatin, A. N., Mahmudy, W. F., Ananda, C. F., & Anggodo, Y. P. (2019). Penerapan Extreme Learning Machine (ELM) Untuk Peramalan Laju Inflasi Di Indonesia. Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIIK), 6(2), 179–186. https://doi.org/10.25126/jtiik.20186900
- Andono, P. N., T, S., & Muljono. (2017). Pengolahan Citra Digital Pengenalan Pola, Watermarking, Steganografi, Kompresi Citra (Pertama; A. Pramesta, Ed.). Yogyakarta: ANDI.
- Anies. (2009). Cepat Tua Akibat Radiasi? (Pertama). Jakarta: PT Alex Media Komputindo.
- Ball, E. (2013). One Hundred Questions & Answers About Leukemia (Second). Subdury: Jones & Bartlet.
- Vincenzo Piuri , Fabio Scotti, Conference, I. I., & Processing, I., 2011, Automatic Morphological Analysis for Acute Leukemia Identification in Peripheral Blood Microscopic Images, Universita degli Studi di Milano, Department of Information Technology, 2045–2048.
- Daniel, T. (2017). Identifikasi Kelainan pada Jantung Menggunakan Extreme Learning Machine (ELM). Universitas Sumatera Utara.
- Devi, M. A., Ravi, S., Vaishnavi, J., & Punitha, S 2016, Classification of Cervical Cancer using Artificial Neural Networks. Procedia Procedia Computer Science, 89, 465–472. https://doi.org/10.1016/j.procs.2016.06.105

- Ding, S., Zhao, H., Zhang, Y., Xu, X., & Nie, R., 2015, Extreme learning machine algorithm, theory and applications, Artificial Intelligence Review, 103–115, https://doi.org/10.1007/s10462-013-9405-z
- Fikriya, Z. A., Irawan, M. I., & Soetrisno. (2017). Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. Jurnal Sains Dan Seni, 6(1).
- Filipczuk, P., Fevans, T., Krzyzak, A., & Obuchowicz, A. (2019). GLCM and GLRLM Based Texture Features For Compoter-Aided Breast Cancer Diagnosis. Journal of Medical Informatics & Technologies, 19.
- Filipczuk, Pawel, Fevens, T., Krzyzak, A., & Obuchowicz, A. (2012). GLCM And GLRLM Based Texture Features For Computer-Aided Breast Cancer Diagnosis. Journal Of Medical Informatics & Technologies, 19, 1–8.
- Firani, N. K. (2018). Mengenali Sel-Sel Darah dan Kelainan Darah (Pertama; T. U. Press, Ed.). Malang: UB Press.
- Gowthaman, R. (2014). Automatic Identification and Classification of Microaneurysms for Detection of Diabetic Retinopathy. International Journal of Research in Engineering and Technology, 3(02), 464–473.
- Gul, S. (2007). Darah dan Jantung (A. Vidianti & Nurhadi, Eds.). Indonesia: Yudhistira.
- Harmon, D. (2012). Leukemia: Current And Emerging Treads In Detection And Treatment.
  New York: Rosen Publishing.
- Harshavardhan, A., Babu, S., & Venugopal, T. (2017). Analysis of Feature Extraction Methods for the Classification of Brain Tumor Detection. International Journal of Pure and Applied Mathematics, 117(7), 147–155.
- Huang, G.-B., Zhu, Q., & Siew, C., 2006, Exrime learning machine: Theory and applications, International Journal of Neurocomputing, 70, 489–501.

- Humaini, Q. (2015). Jaringan Syaraf Tiruan Extreme Learning Machine (ELM) untuk Memprediksi Kondisi Cuaca di Wilayah Malang. Universitas Islam Negeri Maulana Malik Ibrahim Malang.
- Irwan, M., & Sianipar, R. H. (2018). Pengantar Pengolahan Citra Digital: Buku yang cocok untuk mahasiswa. Yogyakarta: Sparta Publisher.
- Kementrian Kesehatan, Republik Indonesia. (2016). Pusat Data dan Informasi Bulan Peduli Kanker 2016 Jakarta Selatan. Kemenkes.
- Kaur, J., Garg, N., & Kaur, D. (2012). Segmentation and Feature Extraction of Lung Region for the Early Detection of Lung Tumor. International Journal of Science and Research (IJSR) ISSN (Online Impact Factor, 3(6), 2319–7064. Retrieved from www.ijsr.net
- Klinis, D. O. (2017). Leukemia. Indonesia: Departemen Onkologi Klinis.
- Madero Orozco, H., Vergara Villegas, O. O., Cruz Sánchez, G. G., Ochoa Domínguez, J. J., & Nandayapa Alfaro, J. J. (2014). Automated system for lung nodules classification based on wavelet feature descriptor and support vector machine. BioMedical Engineering Online, 14(1), 1–20. https://doi.org/10.1186/s12938-015-0003-y
- Mishra, S., Majhi, B., & Sa, P. K. (2018). GLRLM-Based Feature Extraction for Acute Lymphoblastic Leukemia (ALL) Detection. In Recent Findings in Intelligent Computing Techniques (pp. 399–407). Springer.
- Morrison, C., & Hesdorffer, C. S. (2012). Patients' Guide to Leukemia (Panduan untuk Penderita Leukemia. Jakarta: PT Indeks.
- Munir, R. (2004). Pengolahan Citra Digital dengan Pendekatan Algoritmik. Bandung: Penerbit Informatika ITB.
- Nawi, N. M., & Fathurahman, M. (2018). Early Detection of Dengue Disease Using

- Extreme Learning Machine. International Journal on Advanced Science, Engineering and Information Technology, 8(5), 2219–2224.
- Nemissi, M., Salah, H., & Seridi, H. (1945). Breast cancer diagnosis using an enhanced Extreme Learning Machine based-Neural Network. 2018 International Conference on Signal, Image, Vision and Their Applications (SIVA), 1–4.
- Ortiz-Ramón, R., Valdés Hernández, M. del C., González-Castro, V., Makin, S., Armitage, P. A., Aribisala, B. S., ... Moratal, D. (2019). Identification of the presence of ischaemic stroke lesions by means of texture analysis on brain magnetic resonance images. Computerized Medical Imaging and Graphics, 74, 12–24. https://doi.org/10.1016/j.compmedimag.2019.02.006
- Pandiangan, T. D. (2017). Identifikasi Kelainan pada Jantung Menggunakan Extreme Learning Machine (ELM). Universitas Sumatera Utara.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A. R. I., Greer, T., Zuiderveld, K. A. (1987). Adaptive Histogram Equalization and Its Variations. 368, 355–368.
- Prasetya, E. (2014). Data Mining Mengolah Data Menjadi Informasi Menggunakan MATLAB. Yogyakarta: ANDI.
- Preetha, K., & Jayanthi, S. K. (2018). GLCM and GLRLM based Feature Extraction Technique in Mammogram Images. International Journal of Engineering & Technology Website:, 7, 266–270.
- Praida, A. R. (2008). Pengenalan penyakit darah menggunakan teknik pengolahan citra dan jaringan syaraf tiruan. Departemen Elektro Fakultas Teknik Universitas Indonesia.
- Punitha, S., Amuthan, A., & Joseph, K. S. (2018). Benign and malignant breast cancer segmentation using optimized region growing technique. Future Computing and Informatics Journal, 3(2), 348–358. https://doi.org/10.1016/j.fcij.2018.10.005

- Putra, D. (2010). Pengolahan Citra Digital (Westriningsih, Ed.). Yogyakarta: ANDI.
- Putra, R. E., Suciati, N., & Wijaya, A. Y. (2011). Implementing Content Based Image Retrieval For Batik Using Rotated Wavelet Transform And Canberra Distance. Bali International Seminar on Science and Technology, 1–5. Retrieved from http://www.its.ac.id/personal/files/pub/4548-arya-cs-Implementing Content Based Image Retrieval For Batik Using Rotated Wavelet Transform And Canberra Distance.Pdf
- Putzu, L., Caocci, G., & Di, C. (2014). Artificial Intelligence in Medicine Leucocyte classification for leukaemia detection using image processing techniques. Artificial Intelligence In Medicine, 62(3), 179–191. https://doi.org/10.1016/j.artmed.2014.09.002
- Rangole, J. (2019). Detection of Leukemia in Microscopic Images Using Image Processing.

  International Conference on Communication and Signal Processing, (April 2014).

  https://doi.org/10.1109/ICCSP.2014.6949840
- Kantarjian, H. M., DeAngelo, D. J., Stelljes, M., Martinelli, G., Liedtke, M., Stock, W., & Paccagnella, M. L. (2016). Inotuzumab ozogamicin versus standard therapy for acute lymphoblastic leukemia. New England Journal of Medicine, 375(8), 740-753.
- Sabu, A. M., & Ponraj, D. N., 2012, Textural Features Based Breast Cancer Detection A Survey. 3(9), 1329–1334.
- Saporetti, C. M., Duarte, G. R., Fonseca, T. L., da Fonseca, L. G., & Pereira, E. (2018). Extreme Learning Machine combined with a Differential Evolution algorithm for lithology identification. Revista de Informática Teórica e Aplicada, 25(4), 43-56.
- Scotti, F. (2005). Automatic Morphological Analysis for Acute Leukemia Identification in Peripheral Blood Microscopic Images. (July), 20–22.
- SEER Incidence Database. (2019). Cancer Stat Facts: Leukemia. Retrieved October 17, 2019, from Surveillace, Epidemiology and End Result Program website: https://seer.cancer.gov/

- Sembiring, A. (2015). Perbandingan Algoritma Mean Filter, Median Filter dan Wiener Filter pada Aplikasi Restorasi Citra RGB Terdegradasi Impulse Noise Menggunakan The Peak Signal To Noise Ratio (PSNR). Jurnal Saintek Fak. Teknik Universitas Islam Sumatera Utara (UISU), 2(2), 234–244.
- Society, L. and L., (2015), Fact and Statistic. Retrieved October 17, 2019, from https://www.lls.org/facts-and-statistics/facts-and-statistics-overview/facts-and-statistics#Leukemia
- Sohail, A. S. M., Bhattacharya, P., Mudur, S. P., & Krishnamurthy, S. (2011). Local relative glrlm-based texture feature extraction for classifying ultrasound medical images. Canadian Conference on Electrical and Computer Engineering, (1), 001092–001095. https://doi.org/10.1109/CCECE.2011.6030630
- Subbulakshmi, C. Deepa, S. & Malathi, N. (2012). Extreme Learning Machine for Two Category Data Classification 2 3. International Conference on Advanced Communication Control and Computing Technologies (ICACCCT) Extreme, 12(978), 458–461.
- Sutoyo, T., & Mulyanto. (2009). Teori Pengolahan Citra Digital. Yogyakarta: Penerit ANDI.
- Tambayong, J. (1999). Patofisiologi Untuk Keperawatan (Pertama; M. Ester, Ed.). Jakarta.
- Scotti, F., Piuri, V., & Labati, R. D. (2019). ALL-IDB. Retrieved from Universita degli Studi di Milano website: https://homes.di.unimi.it/scotti/all//
- Tang, H., Ni, R., Zhao, Y., & Li, X. (2018). Median Filtering Detection of Small-Size Image based on CNN. Journal of Visual Communication and Image Representation, (January). https://doi.org/10.1016/j.jvcir.2018.01.011
- Tun, K. M. M., & Khaing, A. S. (2014). Feature Extraction and Classification of Lung. International Journal of Engineering Research & Technology (IJERT), 3(3).

Wirawan, I. M. C. (2013). Mengenal Beragam Penyakit 2 (I. Pradina, ed.). Jakarta: Mizan Publika.

WHO. (2018). World Health Organization. Retrieved from https://www.who.int/

Yang, C. (2009). Image enhancement by the modified high-pass filtering approach.
Optik - International Journal for Light and Electron Optics, 120(17), 886–889.
https://doi.org/10.1016/j.ijleo.2008.03.016

Zhu, Y., & Huang, C. (2012). An Improved Median Filtering Algorithm for Image Noise. Physics Procedia, 25, 609–616. https://doi.org/10.1016/j.phpro.2012.03.133