

BAB II

TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1 Tinjauan Pustaka

Beberapa penelitian sebelumnya yang terkait sel darah putih (leukosit) damsel kanker lainnya serta metode ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM) dan *Multilayer Perceptron* (MLP) telah dijadikan referensi dan ide dalam melakukan penelitian ini. Adapun penelitian terkait dapat dilihat pada Tabel 2.1.

Pada Tabel 2.1 penelitian yang dilakukan oleh (Caraka, Sumbodo, & Candradewi, 2017) membahas tentang pengolahan citra sel darah putih yang dilakukan dengan metode Histogram Oriented Gradient sebagai ekstraksi ciri. Hasil ekstraksi fitur tersebut kemudian digunakan untuk klasifikasi menggunakan metode Support Vector Machine. Hasil yang didapat yaitu akurasi sebesar 72,26% dengan menggunakan data pelatihan sebanyak 308 citra positif dan 780 citra negatif. Sampel positif merupakan sampel yang memuat target berupa jenis sel darah putih (neutrofil, basofil, eosinofil, monosit, limfosit dan limfoblas) sedangkan sample negatif memuat objek selain sel darah putih

Penelitian selanjutnya dilakukan oleh (Madhukar, Agaian, & Chronopoulos, 2012) membahas tentang penelitian dengan memproses citra leukemia sebagai input guna melakukan analisis data yang lebih cepat dari menganalisis data secara manual. Citra yang digunakan sebanyak 50 citra (25 citra normal dan 25 citra abnormal). Dalam pemrosesan tersebut menggunakan metode K-Means Clustering sebagai segmentasi, Gray Level Co-Occurrence Matrix (GLCM) dan Fractal Dimension sebagai ekstraksi fitur, dan Support Vector Machine sebagai klasifikasi. Dari penelitian tersebut didapat hasil akurasi sebesar 93,5% dari 50 citra tersebut.

Selanjutnya penelitian yang dilakukan oleh (Laosai & Chamnongthai, 2014) membahas tentang penelitian klasifikasi sel darah putih menggunakan K-Means Clustering dan Support Vector Machine (SVM). Dari penelitian tersebut didapatkan hasil akurasi sebesar 92%.

(Lim et al., 2017) melakukan penelitian yang membahas tentang klasifikasi leukemia berdasarkan sumsum tulang belakang. Metode yang digunakan dalam penelitian ini yaitu Multilayer Perceptron Network. Hasil yang didapat dalam penelitian ini yaitu sebesar 97,55% pada saat melakukan testing.

Penelitian selanjutnya dilakukan oleh (Suratin, 2015) membahas tentang identifikasi sel Acute Lymphoblastic Leukemia (ALL) pada citra sediaan apus darah berdasarkan ciri morfologi. Prosesnya terdiri dari pra-pengolahan, segmentasi citra, perhitungan fitur dan klasifikasi. Segmentasi berdasarkan warna yang digunakan metode K- means Clustering untuk memisahkan latar belakang, nukleus WBC, sitoplasma WBC dan RBC. Sementara nukleus yang tumpang tindih kemudian dipisahkan dengan mengaplikasikan metode Watershed Transform. Kemudian untuk klasifikasinya menggunakan metode Support Vector Machine (SVM) dan menghasilkan akurasi sebesar 95.45%.

(Hazra et al., 2017) melakukan penelitian yang membahas tentang pengembangan teknik otomatis dengan metode K-Means Clustering dan klasifikasi menggunakan Support Vector Machine (SVM) untuk mengatasi kelemahan dalam pendeteksian yang dilakukan oleh dokter. Beberapa fitur seperti area, perimeter, rata-rata, centroid, soliditas, kehalusan, kemiringan, energi, entropi, homogenitas, standar deviasi dll diekstraksi dan dihitung dan diklasifikasi. Hasil penelitian ini mendapat akurasi sebesar 94.11%.

Penelitian selanjutnya oleh (Mishra, Majhi, Sa, & Sharma, 2017) membahas tentang deteksi leukemia limfoblastik akut dari gambar mikroskopis. Kontribusi penelitian ini ada pada marker-based segmentation (MBS), ekstraksi fitur Gray Level Co-Occurrence Matrix (GLCM), dan probabilistic principal component analysis (PPCA) pengurangan fitur berdasarkan. Kemudian untuk klasifikasinya menggunakan Random Forest (RF). Hasil penelitian ini yaitu nilai akurasi segmentasi 96,29% dan akurasi klasifikasi masing-masing 99,004% dan 96% untuk nukleus dan sitoplasma.

Penelitian selanjutnya yang dilakukan oleh (Singhal & Singh, 2015) membahas tentang pendeteksi deteksi ALL secara otomatis menggunakan fitur bentuk sel limfosit yang diekstraksi dari gambarnya. Ekstraksi fitur dilakukan

berrdasarkan Korelasi untuk menemukan serangkaian fitur yang menonjol yang dapat digunakan untuk memprediksi sel limfosit sebagai normal atau ledakan. Kemudian klasifikasi menggunakan Support Vector Machine (SVM) pada 260 citra dengan hasil akurasi sebesar 92.30%.

Penelitian selanjutnya diterbitkan pada jurnal ilmiah yang ditulis oleh (Satapathy, Joshi, Modi, & Pathak, 2016) yang membahas tentang klasifikasi menggunakan metode Sequential Minimal Optimization algorithm. Kontribusi penelitian ini terletak pada perbandingan 2 ekstraksi fitur yaitu Local Binary Pattern (LBP) dan Gray Level Co-Occurrence Matrix (GLCM). Penelitian ini menghasilkan nilai akurasi klasifikasi yang menggunakan ekstraksi fitur LBP sebesar 93.84% dan pada GLCM sebesar 87.30%.

Penelitian selanjutnya oleh (Asadi et al., 2018) membahas tentang implementasi klasifikasi Leukemia Akut menggunakan Hue Saturation Value (HSV), Gray Level Co-Occurence Matrix (GLCM), dan Multilayer Perceptron Network. Penelitian ini berfokus pada leukemia akut, yang dapat dikategorikan menjadi Acute Lymphoblastic Leukemia (ALL) dan Acute Myelogenous Leukemia (AML). Hasil percobaan mencapai akurasi sekitar 86,66% rata-rata dalam mengklasifikasikan jenis leukemia akut.

Tabel 2.1 Tinjauan Pustaka

Author	Judul	Tahun	Metode	Hasil
Caraka, Bhima Sumbodo, Bakhtiar Alldino Ardi Candradewi, Ika	Klasifikasi Sel Darah Putih Menggunakan Metode <i>Support Vector Machine</i> (SVM) Berbasis Pengolahan Citra Digital	2017	<i>Histogram Oriented Gradient. Support Vector Machine (SVM)</i>	72,26%

Tabel 2.1 Tinjauan Pustaka (lanjutan)

Author	Judul	Tahun	Metode	Hasil
Madhukar, Monica Agaian, Sos Chronopoulos, Anthony T.	<i>Deterministic Model for Acute Myelogenous Leukemia Classification</i>	2012	- <i>K-Means</i> - <i>Gray Level Co-OCCURRENCE Matrix (GLCM)</i> - <i>Fractal Dimension</i> - <i>Support Vector Machine</i>	93,5%
Suratin, M Dzikrullah	Identifikasi Sel <i>Acute Lymphoblastic Leukemia (ALL)</i> pada Citra <i>Peripheral Blood Smear</i> Berdasarkan Morfologi Sel Darah Putih	2015	- <i>K-Means Clustering</i> - <i>Watershed Transform</i> - <i>Support Vector Machine (SVM)</i>	95.45%
Hazra, Tathagata Kumar, Mrinal Tripathy, Sanjaya Shankar	<i>Automatic Leukemia Detection Using Image Processing Technique</i>	2017	- <i>K-Means Clustering</i> - <i>Support Vector Machine (SVM)</i>	90%
Mishra, Sonali Majhi, Banshidhar Sa, Pankaj Kumar Sharma, Lokesh	<i>Gray level co-occurrence matrix and random forest based acute lymphoblastic leukemia detection</i>	2017	- <i>marker-based segmentation</i> - <i>Gray Level Co-OCCURRENCE Matrix (GLCM)</i> - <i>probabilistic principal component analysis (PPCA)</i> - <i>Random Forest</i>	Segmentasi 96.29% dan klasifikasi nucleus 99.004% dan 96% sitoplasma .

Tabel 2.1 Tinjauan Pustaka (lanjutan)

Author	Judul	Tahun	Metode	Hasil
Singhal, Vanika Singh, Preety	<i>Correlation based Feature Selection for Diagnosis of Acute Lymphoblastic Leukemia</i>	2015	- <i>Support Vector Machine (SVM)</i>	92.30%
Satopathy, Suresh Chandra Joshi, Amit Modi, Nilesh Pathak, Nisarg	<i>Texture Features for the Detection of Acute Lymphoblastic Leukemia</i>	2016	- <i>Local Binary Pattern (LBP)</i> - <i>Gray Level Co-OCCURRENCE Matrix (GLCM)</i> - <i>Sequential Minimal Optimization algorithm</i>	Akurasi pada LBP (93.84%) dan pada GLCM (87.30%)
Asadi, Faisal Putra, Fiqhri Mulianda Indah Sakinatunnisa, Mutik Syafria, Fadhilah Okfalisa Marzuki, Ismail	<i>Implementation of Backpropagation Neural Network and Blood Cells Imagery Extraction for Acute Leukemia Classification</i>	2018	- <i>Hue Saturation Value (HSV)</i> - <i>Gray Level Co-Occurrence Matrix (GLCM)</i> - <i>Multilayer Perceptron Network</i>	86.66%


2.2 Landasan Teori

2.2.1 Penyakit Darah Leukemia

Leukemia merupakan kanker yang terjadi pada sel darah manusia. Leukemia merupakan penyakit keganasan sel darah yang berasal dari sumsum

tulang ditandai oleh proliferasi sel-sel darah putih, dengan manifestasi adanya sel-sel abnormal dalam darah tepi (Rendra, Yaswir, & Hanif, 2013). Leukemia biasanya ditandai oleh perbanyakan transformasi maligna yang tak normal dari sel-sel pembentuk darah di sumsum tulang dan jaringan limfoid, umumnya terjadi pada leukosit (sel darah putih). Kelainan dalam produksi sel darah yaitu biasanya leukosit, sehingga DNA dari sel darah yang masih muda (terutama sel darah putih) jadi rusak. Kelainan ini menyebabkan sel-sel darah berkembang dan membelah secara terus menerus. Sel darah yang sehat mati dalam waktu singkat dan digantikan dengan sel-sel baru yang diproduksi di dalam sumsum tulang. Sel-sel darah yang abnormal ini tidak mati pada waktu yang seharusnya, dan akhirnya berakumulasi, lalu memakan lebih banyak tempat dalam darah. Seiring dengan semakin banyaknya sel kanker yang dihasilkan, sel-sel ini menghambat fungsi dan pertumbuhan sel darah putih sehat dengan memenuhi ruang dalam darah. Kanker darah sendiri dibagi menjadi beberapa jenis yaitu leukemia, myeloma, dan limfoma. Penyakit kanker leukemia, diklasifikasikan menjadi:

1. *Acute Lymphotic Leukemia (ALL)* adalah salah satu jenis penyakit leukemia dimana sel-sel yang dalam keadaan normal berkembang menjadi limposit berubah menjadi ganas dan dengan segera akan menggantikan sel-sel normal di dalam sumsum tulang yang dapat berakibat fatal.
2. *Acute myelogenous leukemia (AML)* adalah kanker dari garis myeloid sel darah putih, yang ditandai dengan perkembangbiakan sel abnormal secara cepat yang diakumulasikan di dalam sumsum tulang belakang dan bercampur dengan sel darah normal yang dihasilkan.
3. *Chronic Lymphocytic Leukemia (CLL)* adalah kanker leukemia yang menyerang sel limfoid dewasa. Sebagian besar penyakit ini diderita oleh orang berusia lanjut (>60 tahun).
4. *Chronic Myelogenous Leukemia (CML)* adalah kanker yang menyerang sel *myeloid* yang disebabkan karena adanya kromosom *Philadelpia*. Sebagian besar penyakit ini diderita orang dewasa.




Gambar 2.1 Jenis-jenis Leukemia
(Sumber : www.dutasehat.com)

2.2.2 Citra

Citra merupakan suatu representasi (gambar), kemiripan, atau imitasi dari suatu objek. Citra sebagai keluaran suatu sistem perekaman data bersifat optic berupa foto, bersifat analog berupa sinyal-sinyal video seperti gambar pada monitor televisi, atau bersifat digital yang dapat langsung disimpan pada suatu media penyimpanan. Ada beberapa standar yang digunakan pada citra antara lain *Red, Green, Blue* (RGB), *Hue, Saturation, Value* (HSV), dan *Hue, Luminosity, Saturation* (HLS). Standar yang akan digunakan pada penelitian ini adalah *Red, Green, Blue* (RGB) dimana memiliki tiga indeks warna sesuai namanya, yaitu merah, hijau, dan biru. Dari citra berwarna yang memiliki tiga ruang dimensi dapat disederhanakan menjadi satu dimensi *grayscale*. Untuk mengkonversi citra RGB menjadi *Grayscale* dapat dilakukan dengan perhitungan mencari nilai rata-rata antara ketiga indeks dalam citra RGB. Dari hasil konversi citra yang telah dilakukan ke dalam RGB maka nilai dalam indeks *Grayscale* dapat diasumsikan mewakili nilai dan informasi yang terkandung dalam citra RGB.

a. Citra RGB

Citra RGB (*Red, Green, & Blue*) terdiri dari 3 kanal (*channel*) warna pada setiap pixelnya sehingga dapat direpresentasikan ke dalam beberapa kanal yang dapat menyatakan komponen warna penyusunnya.



Gambar 2.2 Citra RGB

(Sumber: www.adithgeek.wordpress.com)

b. Citra *Grayscale*

Grayscale merupakan citra warna-warna pixel yang memiliki rentang gradiasi tingkat warna keabuan dari suatu gambar hitam dan putih. Citra skala keabuan.




Gambar 2.3 Citra Grayscale

(Sumber: www.adithgeek.wordpress.com)

c. Citra Biner

Suatu citra biner hanya memiliki dua nilai warna yaitu 0 dan 1. Bit 1 berwarna putih dan bit 0 berwarna hitam. Maka 1 bit sudah cukup untuk merepresentasikan nilai pixel.



Gambar 2.4 Citra Biner

(Sumber : www.putuadisusanta.wordpress.com/)

2.2.3 Pengolahan Citra

Pengolahan citra (*Image Processing*) merupakan suatu proses dimana piksel pada suatu citra digital diolah untuk tujuan tertentu. Pengolahan citra dahulunya digunakan untuk memperbaiki kualitas citra yang akan diolah dari noise. Citra merupakan informasi bentuk visual dari suatu objek. Citra berbentuk dua dimensi dan tiga dimensi dalam merepresentasikan bentuk suatu objek. Saat akan melakukan proses komputasi, citra yang bersifat kontinu didigitalisasi terlebih dahulu sampai sehingga menjadi sebuah citra digital. Citra digital tersebut memiliki fungsi dua dimensi yaitu $f(x, y)$ dimana x dan y merupakan suatu koordinat dan f dari (x, y) menyatakan amplitudo atau intensitas atau derajat keabuan (grayscale). Nilai tingkat keabuan pada citra digital disebut sebagai piksel pada posisi tertentu. Nilai x , y dan f dari (x, y) merupakan nilai diskrit atau berhingga.

Pengolahan citra juga bisa digunakan untuk memaksimalkan kualitas citra dengan cara menghilangkan *noise*. Untuk meminimalisir bahkan menghilangkan noise, citra tersebut harus memasuki beberapa tahapan pengolahan citra berikut ini, perbaikan kualitas citra (*image enhancement*), pemugaran citra (*image restoration*), pemampatan citra (*image compression*), segmentasi citra (*image segmentation*), analisis citra

(*image analysis*), dan ekonstruksi citra (*image reconstruction*). Tetapi seiring dengan berkembangnya dunia komputasi dengan meningkatnya kapasitas dan kecepatan proses komputer serta munculnya ilmu-ilmu komputasi yang memungkinkan manusia dapat mengambil informasi dari suatu citra.

2.2.4 Matlab (Matrix Laboratory)

MATLAB atau biasa yang disebut dengan (*Matrix Laboratory*) yaitu sebuah program yang digunakan untuk menganalisis dan mengkomputasi data numerik. MATLAB ini merupakan suatu interface untuk koleksi rutin-rutin numerik dari proyek *Linpack* dan *Eispack*, dan dikembangkan dengan menggunakan bahasa *Fortran*, namun sekarang ini MATLAB merupakan produk komersial dari perusahaan Mathworks, Inc.


Matlab yang merupakan singkatan dari *Matrix Laboratory* juga merupakan bahasa pemrograman yang dikembangkan oleh The Mathwork Inc. yang hadir dengan fungsi dan karakteristik yang berbeda dengan bahasa pemrograman lain yang sudah ada lebih dahulu seperti Delphi, Basic maupun C++.



Gambar 2.5 Logo Matlab
(Sumber: www.eps.leeds.ac.uk/)

2.2.5 Gray Level Co-Occurrence Matrix (GLCM)

Metode GLCM (*Gray Level Co-Occurrence Matrix*) merupakan sebuah metode pada pengolahan citra dengan matlab yang digunakan untuk mengekstraksi ciri atau fitur yaitu mengatakan fitur-fitur dengan GLCM menggunakan 4 arah atau sudut (0° , 45° , 90° , 135°) dan jarak = 50 dapat digunakan untuk membedakan antara massa kistik dan massa non kistik (Listia, Harjoko, Mada, & Utara, 2014).



Gambar 2.6 GLCM
(Sumber: www.mathworks.com/)

Matriks GLCM (*Gray Level Co-Occurrence Matrix*) digunakan untuk mengekstraksi fitur tekstur dari gambar input. GLCM memberikan distribusi masing-masing pasangan tingkat abu-abu dari piksel tetangga dalam sebuah gambar. GLCM memanfaatkan hubungan spasial antara dua piksel, dan satu adalah piksel referensi, dan yang lainnya adalah piksel tetangga (Madhukar, Agaian, & Chronopoulos, 2012). Seperti $y(i, j)$ menjadi elemen GLCM dari gambar yang diberikan f dari ukuran yang didefinisikan sebagai elemen matriks dan dapat diberikan oleh, $X \times Y$ yang memiliki tingkat abu-abu L mulai dari 0 hingga $L - 1$. Kemudian $y(i, j)$ dapat didefinisikan sebagai elemen matriks dan dapat diberikan oleh

$$y(i, j) = \sum_{p=1}^X \sum_{q=1}^Y \begin{cases} 1, \\ 0, \end{cases} \quad (2.1)$$

Jika $f(p, q) = 1$ dan $f = (p + \Delta p, q + \Delta q) = j$ atau kebalikannya

Dimana $(p + q)$ dan $(p + \Delta p, q + \Delta q)$ menunjukkan referensi dan lokasi piksel tetangga masing-masing. $(\Delta p, \Delta q)$ mewakili jarak elemen $y(i, j)$ dalam GLCM yang masing-masing memiliki nilai tingkat abu-abu i dan j . Ini dapat direpresentasikan sebagai $y(i, j|D, \theta)$, Di mana D adalah jarak pemisahan antara dua piksel (referensi dan tetangga) dan θ adalah arah piksel tetangga dari piksel referensi (Mishra, Majhi, Sa, & Sharma, 2017). Untuk tujuan klasifikasi tekstur, GLCM harus mengandung nilai probabilitas yang dinormalisasi. Setiap komponen dari matriks kejadian bersama tingkat abu-abu terstandarisasi dapat ditandai dengan

$$x(i, j) = y(i, j) / \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} y(i, j) \quad (2.2)$$

Fitur ekstraksi terdiri dari kontras, korelasi, energi, dan homogenitas. Keempat fitur tersebut yang kemudian akan diolah.

a. Kontras

Fitur kontras digunakan untuk menghitung intensitas diantara piksel yang berdekatan pada suatu citra. Nilai tersebut dapat semakin tinggi jika nilai kontrasnya semakin tinggi (Satapathy, Joshi, Modi, & Pathak, 2016). Persamaan matematisnya yaitu

$$Kontras = \sum_{i,j=0} |i-j|^2 glcm(i,j) \quad (2.3)$$

b. Korelasi

Fitur korelasi digunakan untuk mengukur ketidakmiripan suatu tekstur yang nilainya akan semakin besar jika acak, sedangkan nilai suatu tekstur bernilai kecil jika seragam atau sama (Satapathy et al., 2016). Persamaan matematisnya yaitu

$$Korelasi = \sum_{i,j}^{N-1} \frac{(i-\mu_i)(j-\mu_j)glcm(i,j)}{\sigma_i\sigma_j} \quad (2.4)$$

Dimana $i = 1$ ke n dan $j = 1$ ke n , dan μ_x , μ_y , σ_x , dan σ_y adalah rata-rata dan varians dari jumlah baris dan kolom, masing-masing.

c. Energi

Fitur energi digunakan untuk menunjukkan sifat homogenitas pada suatu citra. Nilai energi akan tinggi jika tekstur citra yang seragam dalam penyebaran derajat keabuan (Satapathy et al., 2016). Persamaan matematisnya yaitu

$$Energi = \sum_{i,j=0}^{N-1} \{glcm(i,j)\}^2 \quad (2.5)$$

d. Homogenitas

Fitur homogenitas digunakan untuk menunjukkan sifat homogenitas atau keseragaman yang berderajat pada keabuan sejenis. Citra dapat dikatakan memiliki sifat homogenitas akan memiliki nilai tinggi dari sifat homogenitasnya (Satapathy et al., 2016). Persamaan matematisnya yaitu

$$\text{Homogenitas} = \sum_{i,j=0}^{N-1} \frac{\text{glcm}(i,j)}{1+(i,j)^2} \quad (2.6)$$

Berdasarkan Tabel 2.2 beberapa penelitian yang sudah diterbitkan menggunakan metode GLCM sebagai ekstraksi fitur. Seperti pada penelitian (Asadi et al., 2018) menggunakan GLCM sebagai ekstraksi fitur untuk sel *leukemia acute* dan *myeloid*. Kemudian pada penelitian (Mishra et al., 2017) juga menggunakan GLCM sebagai pendeteksi *leukemia* jenis ALL sementara pada penelitian (Madhukar et al., 2012) digunakan sebagai ekstraksi fitur citra *leukemia* jenis AML. Citra mammogram sel kanker payudara juga menggunakan GLCM pada penelitian yang dilakukan oleh (Listia et al., 2014). Pengaplikasian GLCM juga ada pada penelitian (Satapathy et al., 2016) yang dibandingkan dengan ekstraksi fitur lainnya.

Tabel 2.2 Penelitian Terkait GLCM

No.	Penulis, Tahun	Judul
1	Listia et al., 2014	Klasifikasi Massa pada Citra Mammogram Berdasarkan <i>Gray Level Cooccurrence Matrix (GLCM)</i>
2	Mishra et al., 2017	<i>Gray level co-occurrence matrix and random forest based acute lymphoblastic leukemia detection</i>
3	Madhukar et al., 2012	<i>Deterministic model for Acute Myelogenous Leukemia classification</i>
4	Satapathy et al., 2016	<i>Texture Features for the Detection of Acute Lymphoblastic Leukemia</i>
5	Moshavash, Danyali, & Helfroush, 2018	<i>An Automatic and Robust Decision Support System for Accurate Acute Leukemia Diagnosis from Blood Microscopic Images</i>
6	Asadi et al., 2018	<i>Implementation of Backpropagation Neural Network and Blood Cells Imagery Extraction for Acute Leukemia Classification</i>

2.2.6 *Multilayer Perceptron Network (MLP)*

Multilayer Perceptron Network (MLP) adalah suatu fitur yang digunakan untuk menentukan klasifikasi dari hasil ekstraksi fitur untuk setiap pada sebuah citra. Jaringan *Multilayer Perceptron Network (MLP)* yang pada dasarnya dilatih menggunakan algoritma *Levenberg Marquardt* digunakan untuk mengklasifikasikan 3 kelas, yaitu sel normal, sel *Acute Lymphocytic Leukemia (ALL)* dan *Acute Myelogenous Leukemia (AML)* lainnya. MLP merupakan fitur klasifikasi yang memiliki kekokohan yang tinggi, tingkat komputasi yang tinggi dan fleksibilitas (Lim et al., 2017).

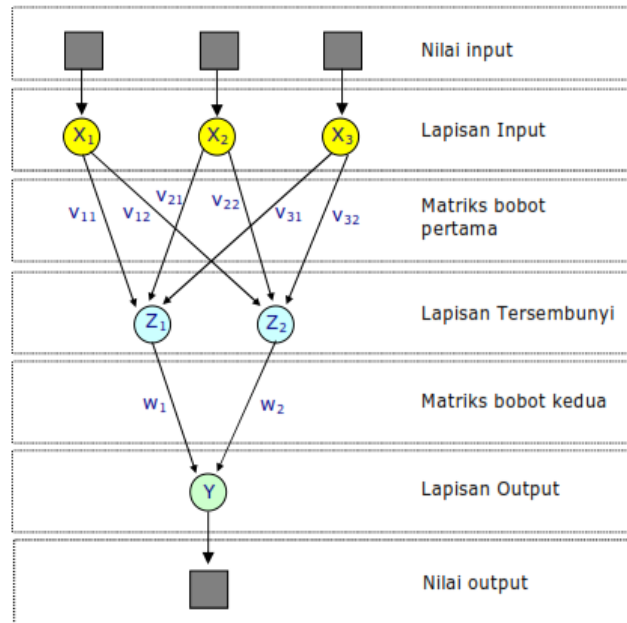
MLP memiliki kemampuan seperti yang dimiliki oleh otak manusia, diantaranya:

1. MLP berkemampuan untuk belajar dari pengalaman.
2. MLP berkemampuan untuk melakukan perumpamaan (*generalization*), terhadap *input* baru dari pengalaman yang dimilikinya.
3. MLP berkemampuan memisahkan (*abstraction*) karakteristik penting dari *input network* yang mengandung data tidak penting.

MLP terdiri dari *neuron* atau *node* dan hubungan antara neuron-neuron yang lain. Hubungan ini disebut dengan nama bobot. Informasi disimpan pada suatu nilai tertentu pada bobot tersebut. *Multilayer Perceptron (MLP)* memiliki layer yang tersembunyi antara *layer input* dan *layer output*. Berikut penjelasan mengenai komponen penyusun MLP:

- a. Neuron atau Node; sel syaraf tiruan yang merupakan elemen pengolahan MLP.
- b. *Input layer*; berisi banyak node yang masing-masing menyimpan sebuah nilai masukan untuk awal proses.
- c. *Hidden layer*; lapisan yang tidak pernah muncul. Semua proses pada fase pelatihan dan fase pengenalan dijalankan di dalam lapisan ini. *Hidden layer* memperluas MLP dalam menghadapi masalah kompleks. Jumlah *hidden layer* tergantung pada arsitektur yang dirancang, tetapi pada umumnya terdiri dari satu *layer*.

- d. *Output layer*; lapisan yang menampilkan hasil perhitungan sistem oleh fungsi aktivasi pada *hidden layer* berdasarkan *input*.



Gambar 2.7 *Multilayer Perceptron*
(Sumber : Kusumadewi, 2004)

Multi layer perceptron merupakan salah satu jaringan saraf tiruan *feed-forward* atau *backpropagation* yang memiliki sejumlah neuron atau saraf pada setiap layer yang saling terhubung dengan neuron lainnya dengan neuron bobot penghubung. Dimana setiap neuron yang ada, merupakan sebuah unit yang memiliki tugas untuk memproses dan menghitung nilai aktivasi, atau inputeksi yang melambangkan himpunan dari predecessor tiap unit, mulai dari input hingga output, atau dari unit satu ke unit lainnya (Halim, Mashor, Nasir, & Hassan, 2011).

Pada saat melakukan proses training, MLP memiliki parameter yang sering muncul yaitu :

1. *Epoch* yaitu banyaknya iterasi atau pengulangan yang dilakukan selama proses training dilakukan.
2. *Learning rate* atau laju pembelajaran. Terletak antara nilai 0 dan 1. Jika *learning rate* semakin kecil, maka algoritma akan konvergen dalam jangka waktu yang lama. Namun jika nilai *learning rate*

semakin besar, maka iterasi yang dipakai semakin sedikit (Kusumadewi, 2004).

3. *Goal* pada training berfungsi untuk membandingkan dengan goal pada jaringan saat training dilakukan. Jaringan akan konvergen ketika error jaringan lebih kecil dari goal.

Untuk mendapatkan klasifikasi kinerja tinggi, maka fitur yang ditugaskan untuk sistem jaringan saraf harus dalam kisaran yang sama, yang dapat dicapai dengan normalisasi (Francis, Mashor, Hassan, & Abdullah, 2011). Fitur-fitur dinormalisasi sehingga rata-rata adalah 0 dan standar deviasi adalah 1 dengan rumus berikut :

$$ft' = [fi - \mu(fi)]/\sigma(fi) \quad (2.7)$$

Di mana,

fi: Nilai awal fitur

fi ': Nilai akhir fitur

μ (fi): Rata-rata semua nilai kelas yang dimiliki oleh fitur

σ (fi): Deviasi Standar dari semua nilai kelas yang dimiliki oleh fitur

Berdasarkan Tabel 2.3 penelitian terkait MLP dapat ditemukan dalam penelitian (Asadi et al., 2018) tentang *acute leukemia*, MLP yang digunakan adalah jenis *backpropagation*. Selanjutnya penelitian (Aeinfar, Mazdarani, Deregeh, Hayati, & Payandeh, 2009) klasifikasi MLP digunakan untuk membedakan 5 jenis kanker darah yaitu *Megaloblastic Anaemia*, *Thalassemia*, *Idiopathic thrombocytopenic pupura (ITP)*, *chronic myelogenous leukemia and Lymphoproliferative*. Sedangkan pada penelitian (Francis et al., 2011) dan (Lim et al., 2017) menggunakan MLP untuk sel *leukemia* berdasarkan *screening* sumsum tulang belakang. (Halim et al., 2011) melakukan penelitian dengan menggunakan MLP sebagai pendeteksi ALL. Dan penelitian yang dilakukan oleh (Torrecilla, García, Rojo, & Rodríguez, 2009) mengukur ion racun pada *leukemia rat cell line*.

Tabel 2.3 Penelitian Terkait MLP

No.	Penulis, Tahun	Judul
1	Asadi et al., 2018	<i>Implementation of Backpropagation Neural Network and Blood Cells Imagery Extraction for Acute Leukemia Classification</i>
2	Francis et al., 2011	<i>Screening of bone marrow slide images for Leukemia using Multilayer Perceptron (MLP)</i>
3	Aeinfar et al., 2009	<i>Multilayer perceptron neural network with supervised training method for diagnosis and predicting blood disorder and cancer</i>
4	Halim et al., 2011	<i>Performance Comparison between Multilayer Perceptron and Fuzzy ARTMAP Networks for Acute Leukemia Detection</i>
5	Torrecilla, García, Rojo, & Rodríguez, 2009	<i>Estimation of toxicity of ionic liquids in Leukemia Rat Cell Line and Acetylcholinesterase enzyme by principal component analysis, neural networks and multiple lineal regressions</i>
6	Lim et al., 2017	<i>Classification of bone marrow acute leukemia cells using multilayer perceptron network</i>

2.2.7 *Graphical User Interface (GUI)*

GUI (*Graphical User Interface*) adalah aplikasi yang membuat tampilan *interface* dari MATLAB yang mengandung tugas, perintah, atau komponen program. GUI dibuat untuk mempermudah pengguna atau *end-user* dalam menjalankan sebuah program dalam MATLAB.