

## **BAB II**

### **KAJIAN TEORI**

Dalam penelitian ini diberikan beberapa teori yang diperlukan sebagai pendukung dalam pembahasan selanjutnya di antaranya adalah kanker otak, *fuzzy clustering*, konsep himpunan *fuzzy*, dan model *fuzzy*.

#### **A. Kanker Otak**

Kanker otak merupakan penyakit yang menyerang otak manusia. Kanker otak terjadi ketika sel-sel pada otak tumbuh atau berkembang secara tidak normal. Kanker dapat berkembang dari sel yang menyusun jaringan otak, dari saraf yang keluar-masuk ke otak, dan dari selaput pelindung otak dan saraf tulang belakang (American Cancer Society, 2013).

##### **1. Penyebab Kanker Otak**

Penyebab utama kanker otak belum diketahui secara pasti. Namun, terdapat beberapa faktor yang dapat mempengaruhi potensi terjadinya kanker otak pada seseorang. Mengacu pada *American Cancer Society* ([www.cancer.org](http://www.cancer.org)), faktor-faktor risiko tersebut di antaranya:

###### **a. Paparan radiasi**

Sebagian kanker otak akibat radiasi disebabkan oleh radiasi ke kepala yang diberikan untuk mengobati kanker lainnya. Hal ini terjadi pada anak-anak yang menerima radiasi ke otak sebagai pengobatan leukemia. Kanker otak ini berkembang 10 sampai 15 tahun setelah radiasi. Risiko yang mungkin timbul dari paparan tes pencitraan yang menggunakan radiasi, seperti sinar-x atau

CT scan, tidak diketahui secara pasti. Tes ini menggunakan tingkat radiasi yang jauh lebih rendah daripada yang digunakan dalam perawatan radiasi.

b. Gangguan sistem kekebalan tubuh

Orang dengan gangguan sistem kekebalan tubuh memiliki peningkatan risiko pengembangan limfoma otak atau sumsum tulang belakang. Limfoma adalah kanker limfosit, sejenis sel darah putih yang melawan penyakit. Sistem kekebalan tubuh yang lemah dapat menjadi bawaan (ada sejak lahir), atau dapat disebabkan oleh perawatan untuk kanker lain, pengobatan untuk mencegah penolakan terhadap organ transplantasi, atau penyakit seperti *acquired immunodeficiency syndrome* (AIDS).

## 2. Gejala Kanker Otak

Mengacu pada *American Cancer Society*, Kanker di otak dapat menyebabkan tekanan di dalam tengkorak meningkat. Hal ini disebabkan oleh pertumbuhan kanker itu sendiri, pembengkakan di otak, atau penyumbatan aliran cairan *serebrospinal* (CSF). Tekanan yang meningkat dapat menyebabkan gejala umum seperti:

- a. sakit kepala
- b. mual
- c. muntah
- d. penglihatan kabur
- e. perubahan kepribadian atau perilaku
- f. kejang
- g. mengantuk atau bahkan koma

### 3. Deteksi Dini

Tidak ada tes yang direkomendasikan secara luas untuk skrining (tes kanker pada orang tanpa gejala apapun). Namun jika berdasarkan gejala yang muncul dan pemeriksaan fisik dokter seseorang dicurigai terserang kanker otak, maka dokter akan menyarankan pemeriksaan lanjutan seperti *rontgen* (sinar-x), *Computed Tomography* (CT-scan), *Magnetic Resonance Imaging* (MRI), *Magnetic Resonance Spectroscopy* (MRS), atau perfusi resonansi magnetik. Berikut penjelasan mengenai CT-scan, MRI, dan MRS (American Cancer Society, 2013):

CT-scan merupakan pemeriksaan dengan sinar-x yang menghasilkan gambar *cross-sectional* yang rinci dari bagian tubuh. Tidak seperti sinar-x biasa yang hanya mengambil satu gambar, CT-scan mengambil banyak gambar saat berputar di sekitar tubuh. Kemudian komputer menggabungkan gambar-gambar tersebut menjadi gambar irisan tubuh. Sehingga CT-scan menciptakan gambaran rinci tentang jaringan lunak di tubuh.

Pada pemeriksaan CT-scan bahan kontras disuntikkan melalui jalur infus sebelum pemindaian dilakukan. Pemberian kontras dapat menyebabkan efek samping alergi dan gatal-gatal.

Pemindaian yang menghasilkan gambar lebih rinci daripada gambar yang diambil dari CT-scan adalah pemindaian MRI. Pemindaian ini tidak menggunakan sinar-x, melainkan gelombang radio dan magnet yang kuat. Energi dari gelombang radio diserap dan kemudian dilepas dalam pola yang dibentuk oleh jaringan tubuh dan penyakit tertentu. Komputer menerjemahkan pola itu menjadi gambar bagian tubuh yang sangat rinci. Agar detail terlihat dengan baik,

dapat menyuntikkan bahan kontras yang disebut gadolinium ke pembuluh darah sebelum pemindaian.

Pemindaian yang mirip dengan MRI adalah pemindaian MRS. Pemeriksaan *Magnetic Resonance Spectroscopy* (MRS) seperti pemeriksaan MRI tetapi MRS mengukur interaksi gelombang radio dengan berbagai bahan kimia di otak. MRS menyoroti beberapa ciri kanker otak yang tidak terlihat dengan jelas oleh MRI. Hasil yang dihasilkan oleh MRS berupa grafik yang disebut spektra.

Perfusi MRI juga dikenal sebagai perfusi resonansi magnetik. Pada pemeriksaan ini pewarna kontras disuntikkan dengan cepat ke pembuluh darah. Specimen khusus gambar MR kemudian diperoleh untuk melihat jumlah darah melalui berbagai bagian otak dan kanker. Kanker sering memiliki suplai darah lebih besar daripada area normal otak.

MRI fungsional (fMRI) merupakan jenis MRI baru yang mencari perubahan aliran darah kecil di bagian aktif otak. Hal ini digunakan untuk menentukan bagian otak mana yang menangani fungsi seperti ucapan, pikiran, sensasi, atau gerakan. Dokter dapat menggunakan ini untuk menentukan bagian otak mana yang harus dihindari saat merencanakan operasi atau terapi radiasi. Pemeriksaan fMRI mirip dengan MRI standar, ditambah dengan perintah melakukan tugas tertentu seperti menjawab pertanyaan sederhana atau menggerakkan jari.

#### **4. Klasifikasi Kanker Otak**

Kanker otak diklasifikasikan menjadi dua jenis yaitu kanker otak primer dan sekunder. Kanker otak primer yaitu sel kanker yang memang berasal dari sel-sel otak itu sendiri. Kanker otak sekunder yaitu kanker otak yang merupakan hasil

dari penyebaran kanker yang berasal dari organ tubuh lainnya, disebut juga sebagai kanker otak metastatik. Jenis kanker otak metastatik lebih sering terjadi daripada kanker otak primer. Beberapa kanker yang sering menyebar ke otak di antaranya kanker paru-paru, kanker usus, kanker ginjal, dan kanker payudara. (Media Khusus Kesehatan dan Medis, 2017).

## B. Ekstraksi Citra

Secara matematis citra adalah fungsi kontinu dari intensitas cahaya pada bidang dua dimensi  $f(x,y)$ , dengan  $(x,y)$  adalah koordinat pada bidang dua dimensi dan  $f$  adalah intensitas cahaya pada titik  $(x,y)$ . sistem koordinat yang digunakan mengacu pada sistem koordinat kartesius (Munir, 2004).

Proses ekstraksi citra merupakan salah satu karakteristik penting dalam mengidentifikasi objek citra. Salah satu metode yang digunakan dalam ekstraksi citra adalah *Gray Level Co-occurrence Matrix* (GLCM). Metode GLCM adalah suatu matrik yang elemen-elemennya merupakan jumlah pasangan pixel yang memiliki tingkat kecerahan tertentu (Toni, 2013). Hasil dari ekstraksi citra dengan menggunakan metode GLCM berupa 14 fitur ekstraksi. 14 fitur tersebut adalah sebagai berikut:

### 1. *Energy*

Nilai *energy* menggambarkan keteraturan penyebaran derajat suatu citra keabuan. Rumus *energy* adalah (Girisha et al, 2013):

$$Energy = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{ij}^2 \quad (2.1)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke-i dan kolom ke-j

$N_g$  = level keabu-abu

## 2. Contrast

*Contrast* digunakan untuk menghitung *range* perbedaan derajat keabuan dalam sebuah citra. Rumus *contrast* adalah (Girisha et al, 2013):

$$Contrast = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 P_{ij} \quad (2.2)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke-i dan kolom ke-j

$N_g$  = level keabu-abu

## 3. Correlation

*Correlation* adalah fitur yang digunakan untuk menghitung ketergantungan linier sebuah citra. Rumus *correlation* adalah (Girisha et al, 2013):

$$Correlation = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i, j, P_{ij}) - \mu_x \cdot \mu_y}{\sigma_x \cdot \sigma_y} \quad (2.3)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke-i dan kolom ke-j

$N_g$  = level keabu-abu

$\mu_x \cdot \mu_y$  = rata-rata dari peluang marginal  $P_x(i)$  dan  $P_y(j)$

$\sigma_x \cdot \sigma_y$  = standar deviasi dari peluang marginal  $P_x(i)$  dan  $P_y(j)$

## 4. Sum of Square (Varinace)

*Variance* merupakan ukuran heterogenitas atau variasi elemen-elemen matrik.

Rumus *variance* adalah (Haralick, Shanmugam & Dinstein, 1973: 619):

$$Variance = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 P(i, j) \quad (2.4)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$

$N_g$  = level keabu-abu

#### 5. *Invers Difference Moment (IDM)*

IDM merupakan ukuran dari homogenitas local. Rumus IDM adalah (Mohanaiah et al, 2013: 2):

$$IDM = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j)}{1 + (i - j)^2} \quad (2.5)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$

$N_g$  = level keabu-abu

#### 6. *Sum Average*

*Sum average* merupakan fitur yang menunjukkan banyaknya nilai rata-rata *pixel* yang ada di dalam citra. Rumus *sum average* adalah (Haralick, Shanmugam & Dinstein, 1973: 619):

$$Sum\ Average = \sum_{k=2}^{2N_g} k P_{x+y}(k) \quad (2.6)$$

$$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j); \quad i + j = k; \quad k = 2, 3, \dots, 2N_g$$

$N_g$  = level keabu-abu

### 7. *Sum Variance*

*Sum variance* menyatakan heterogenitas spasial (perbedaan) gambar (Abouelatta, 2013: 217). Rumus *sum variance* adalah (Haralick, Shanmugam & Dinstein, 1973: 619):

$$\text{Sum Variance} = \sum_{i=2}^{2N_g} (i - SE)^2 P_{x+y}(k) \quad (2.7)$$

$$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j); \quad i + j = k; \quad k = 2, 3, \dots, 2N_g$$

$N_g$  = level keabu-abu

### 8. *Sum Entropy (SE)*

*Sum entropy* adalah fitur yang menunjukkan seberapa banyak level keabu-abuan yang acak. Rumus *Sum entropy* adalah sebagai berikut (Haralick, Shanmugam & Dinstein, 1973: 619):

$$\text{Sum Entropy} = - \sum_{k=2}^{2N_g} P_{x+y}(k) \log\{P_{x+y}(k)\} \quad (2.8)$$

$$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j); \quad i + j = k; \quad k = 2, 3, \dots, 2N_g$$

$N_g$  = level keabu-abu

### 9. *Entropy*

Nilai *entropy* menunjukkan ketidakteraturan distribusi derajat keabuan sebuah citra. Rumus *entropy* adalah (Mohanaiah et al, 2013: 2):

$$\text{Entropy} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} - P_{ij} \cdot \log P_{ij} \quad (2.9)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$



$N_g$  = level keabu-abu

#### 10. *Difference Variance (DV)*

*Difference variance* menyatakan ukuran variabilitas lokal. Rumus *difference variance* adalah (Haralick, Shanmugam & Denstein, 1973: 619):

$$DV = \text{variansi dari } P_{x+y}(k) \quad (2.10)$$

$$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j); \quad i + j = k; \quad k = 2, 3, \dots, 2N_g$$

#### 11. *Difference Entropy (DE)*

*Difference entropy* merupakan ukuran variabilitas perbedaan mikro (lokal). Rumus *difference entropy* adalah (Haralick, Shanmugam & Dinstein, 1973: 619):

$$DE = - \sum_{j=0}^{N_g-1} P_{x+y}(k) \log\{P_{x+y}(k)\} \quad (2.11)$$

$$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j); \quad i + j = k; \quad k = 2, 3, \dots, 2N_g$$

$N_g$  = level keabu-abu

#### 12. *Maximum Probability*

*Maximum probability* menghitung tingkat keabu-abuan yang mempunyai peluang maksimum pada GLCM. Rumus *maximum probability* adalah:

$$\text{Maximum Probability} = \max_{i,j}\{P(i, j)\} \quad (2.12)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$

### 13. Homogeneity

*Homogeneity* menghitung keseragaman variasi derajat keabuan sebuah citra.

Rumus *homogeneity* adalah (Girisha et al, 2013: 2720):

$$Homogeneity = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} P_{ij} \quad (2.13)$$

$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$

$N_g$  = level keabu-abu

### 14. Dissimilarity

*Dissimilarity* mirip dengan *contrast*. Ketika daerah lokal memiliki nilai *contrast* tinggi, maka nilai *dissimilarity* akan tinggi. Rumus *dissimilarity* adalah (Aboueletta, 2013: 216):

$$Dissimilarity = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) |i - j| \quad (2.14)$$


$i, j$  = koordinat spasial fungsi  $P_{ij}$

$P_{ij}$  = peluang nilai level keabuan pada baris ke- $i$  dan kolom ke- $j$

$N_g$  = level keabu-abu

Contoh hasil ekstraksi citra dari 14 fitur citra berdasarkan Persamaan (2.1)

sampai Persamaan (2.14) sebagai berikut:



Gambar 2.1 Gambar Citra MRI yang akan diekstraksi

Hasil ekstraksi pada Gambar 2.1 dapat dilihat pada tabel berikut:

Tabel 2.1 Hasil Ekstraksi Citra MRI Gambar 2.1

<i>Contrast</i>	<i>Correlation</i>	<i>Dissimilarity</i>	<i>Energy</i>	<i>Entropy</i>	<i>Homogeneity</i>	<i>Max. Probability</i>
0,30852	0,9788	0,192586	0,2929	1,94726	0,9182	0,5050398
<i>Diff. Variance</i>	<i>Sum Average</i>	<i>Sum Variance</i>	<i>Sum Entropy</i>	<i>Sum of Square</i>	IDM	<i>Diff. Entropy</i>
0,308517	11,05545	115,3538	1,7534	37,6669	0,9956	0,5224791

### C. Fuzzy C-Means

*Fuzzy C-Means* (FCM) adalah suatu teknik pengklusteran data yang keberadaan tiap-tiap titik data dalam suatu *cluster* ditentukan oleh derajat keanggotaan. Teknik ini pertama kali diperkenalkan oleh Jim Bezdek pada tahun 1981. (Kusumadewi, 2002:159-160).

Konsep dasar FCM adalah menentukan pusat *cluster*. Pusat ini yang akan menandai lokasi rata-rata untuk tiap *cluster*. Pusat *cluster* masih belum akurat pada kondisi awal. Setiap data memiliki derajat keanggotaan untuk tiap-tiap *cluster*. Kemudian pusat *cluster* dan derajat keanggotaan tiap-tiap titik data diperbaiki secara berulang sehingga pusat *cluster* akan bergerak menuju lokasi yang tepat. Perulangan ini didasarkan pada minimisasi fungsi obyektif menggambarkan jarak dari titik data ke pusat *cluster* yang terbobot oleh derajat keanggotaan titik data tersebut. (Kusumadewi, 2002:159-160).

*Output* dari FCM bukan merupakan *fuzzy inference sistem*, melainkan himpunan pusat *cluster* dan derajat keanggotaan untuk tiap-tiap titik data. *Output* ini dapat digunakan untuk membangun suatu *fuzzy inference system*.

Algoritma FCM adalah sebagai berikut (Kusumadewi & Purnomo, 2013:84-85):

1. *Input* data yang akan dicluster X, berupa matriks berukuran n x m dengan n adalah jumlah sampel data dan m adalah atribut setiap data.  $X_{ij}$  adalah data sampel ke-i ( $i=1,2,\dots,n$ ), atribut ke-j ( $j=1,2,\dots,m$ ).
2. Tentukan jumlah *cluster* yang diinginkan (c), pangkat (w), maksimum iterasi (MaxIter), error terkecil yang diharapkan ( $\xi$ ), fungsi obyektif awal ( $P_0=0$ ), dan iterasi awal ( $t=1$ ).
3. Bangkitkan bilangan random  $\mu_{ik}$ , dengan  $i=1,2,\dots,n$ ;  $k=1,2,\dots,c$ ; sebagai elemen-elemen matriks partisi awal U.

Hitung jumlah setiap kolom (atribut):

$$Q_j = \sum_{k=1}^c \mu_{ik} \quad (2.15)$$

Dengan  $j=1,2,\dots,m$ .

Hitung:

$$\mu_{ik} = \frac{\mu_{ik}}{Q_j} \quad (2.16)$$

4. Hitung pusat *cluster* ke-k:  $V_{kj}$ , dengan  $k=1,2,\dots,c$ ; dan  $j=1,2,\dots,m$ .

$$V_{kj} = \frac{\sum_{i=1}^n ((\mu_{ik})^w * X_{ij})}{\sum_{i=1}^n (\mu_{ik})^w} \quad (2.17)$$

5. Hitung fungsi obyektif pada iterasi ke-t,

$$P_t = \sum_{i=1}^n \sum_{k=1}^c \left( \left[ \sum_{j=1}^m (X_{ij} - V_{kj})^2 \right] (\mu_{ik})^w \right) \quad (2.18)$$

6. Hitung perubahan matriks partisi:

$$\mu_{ik} = \frac{\left[ \sum_{j=1}^m (X_{ij} - V_{kj})^2 \right]^{\frac{-1}{w-1}}}{\sum_{k=1}^c \left[ \sum_{j=1}^m (X_{ij} - V_{kj})^2 \right]^{\frac{-1}{w-1}}} \quad (2.19)$$

dengan  $i=1,2,\dots,n$ ; dan  $k=1,2,\dots,c$ .

7. Cek kondisi berhenti:

Jika  $(|P_t - P_{t-1}| < \xi)$  atau  $(t > \text{MaxIter})$  maka berhenti, sedangkan jika  $t=t+1$ , ulangi langkah ke-4.

Berikut adalah contoh penggunaan metode *fuzzy C-Means Clustering*:

Misalkan empat data hasil ekstraksi MRI dengan dua variabel  $x_1$  dan  $x_2$  akan dikelompokkan menjadi dua kelompok. Data diberikan dalam Tabel 2.2:

Tabel 2.2 Hasil Ekstraksi Citra MRI

No	Nama	Atribut	
		$x_1$	$x_2$
1	2810.jpg	0,42126	0,973482
2	2811.jpg	0,26859	0,983691
3	2888.jpg	0,32095	0,978699
4	2993.jpg	0,27236	0,981548

Untuk mengimplementasi metode *fuzzy C-Means* dengan dua *cluster*, pertama tentukan pangkat ( $w$ ), maksimum iterasi ( $\text{MaxIter}$ ), error terkecil yang diharapkan ( $\xi$ ), fungsi obyektif awal ( $P_0$ ), dan iterasi awal ( $t$ ). Dalam perhitungan ini dipilih maksimal iterasi= 10, error terkecil=  $10^{-6}$ , fungsi obyektif awal= 0,  $t=1$ , dan  $w=2$ . Dipilih  $w=2$  karena berdasarkan penelitian yang dilakukan oleh Siwiasa

(2012) mengenai optimasi *fuzzy c-means* menggunakan Mamdani, diperoleh hasil bahwa pangkat yang optimal adalah dua.

Langkah selanjutnya adalah membangkitkan bilangan random  $\mu_{ik}$ , dengan  $i=1,2,\dots,n$ ;  $k=1,2,\dots,c$ ; sebagai elemen-elemen matriks partisi awal U. Matriks partisi awal yang terbentuk secara random dan memenuhi fungsi *constraint*.

$U = \text{initfcm}(4, 2)$

$$U_{(0)} = \begin{bmatrix} 0,3139 & 0,4014 \\ 0,3163 & 0,2035 \\ 0,0517 & 0,3356 \\ 0,3182 & 0,0595 \end{bmatrix}$$

Langkah selanjutnya adalah menghitung pusat *cluster* yang terbentuk berdasarkan matriks partisi awal. Pusat *cluster* pertama hasil iterasi ke-1 dapat dilihat pada Tabel 2.3 dan pusat *cluster* kedua hasil iterasi ke-1 dapat dilihat pada Tabel 2.4:

Tabel 2.3 Pusat *Cluster* Pertama yang Dihasilkan pada Iterasi Ke-1

$\mu_{i1}$	$x_{i1}$	$x_{i2}$	$\mu_{i1}^2$	$\mu_{i1}^2 \times x_{i1}$	$\mu_{i1}^2 \times x_{i2}$
0,3139	0,42126	0,973482	0,09853321	0,041508	0,09592
0,3163	0,26859	0,983691	0,10004569	0,026872	0,098414
0,0517	0,32095	0,978699	0,00267289	0,000858	0,002616
0,3182	0,27236	0,981548	0,10125124	0,027577	0,099383
$\Sigma$			0,30250303	0,096815	0,296333
$V_1 = \frac{\sum_{i=1}^4 ((\mu_{i1})^2 * X_{ij})}{\sum_{i=1}^4 (\mu_{i1})^2}$				0.320048	0,979604

Tabel 2.4 Pusat *Cluster* kedua yang dihasilkan pada iterasi ke-1

$\mu_{i2}$	$x_{i1}$	$x_{i2}$	$\mu_{i2}^2$	$\mu_{i2}^2 \times x_{i1}$	$\mu_{i2}^2 \times x_{i2}$
0,4014	0,42126	0,97348	0,16112196	0,0678746	0,156849397
0,2035	0,26859	0,98369	0,04141225	0,011123198	0,040736851
0,3356	0,32095	0,97869	0,11262736	0,036148414	0,110228249
0,0595	0,27236	0,98154	0,00354025	0,000964241	0,003474924
$\Sigma$			0,31870182	0,116110453	0,311289421
$V_1 = \frac{\sum_{i=1}^4 ((\mu_{i2})^2 \times X_{ij})}{\sum_{i=1}^4 (\mu_{i2})^2}$				0,364323156	0,976741899

Sehingga pusat *cluster* yang terbentuk adalah:

$$V_{(1)} = \begin{bmatrix} 0,320048 & 0,9796042 \\ 0,364323 & 0,9767419 \end{bmatrix}$$

Setelah didapat pusat *cluster*, selanjutnya adalah menghitung fungsi obyektif.

Fungsi obyektif yang dihasilkan adalah

$$P_1 = \sum_{i=1}^4 \sum_{k=1}^2 \left( \left[ \sum_{j=1}^2 (X_{ij} - V_{kj})^2 \right] (\mu_{ik})^2 \right) = 0,002658$$

Detail perhitungan dapat dilihat pada Tabel 2.5.

Tabel 2.5 Perhitungan Fungsi Obyektif pada iterasi ke-1

$\mu_{i1}^2$	$\mu_{i2}^2$	$\sum_{j=1}^2 (X_{i1} - V_{1j})^2$	$\sum_{j=1}^2 (X_{i2} - V_{2j})^2$	$(\mu_{i1})^2 \cdot d_{i1}$	$(\mu_{i2})^2 \cdot d_{i2}$	$L_1 + L_2$
		$d_{i1}$	$d_{i2}$	$L_1$	$L_2$	$LT$
0,0985	0,1611	0,010282	0,003253	0,001013	0,000524	0,00153
0,1000	0,0414	0,002664	0,009212	0,000267	0,000381	0,00064
0,0026	0,1126	$1,6 \times 10^{-6}$	0,001885	$4,4 \times 10^{-9}$	0,000212	0,00021
0,1012	0,0035	0,002277	0,008479	0,000231	$3 \times 10^{-5}$	0,00026
$P_{(1)}$						0,002658

Karena  $|P_1 - P_0| = |0,002658 - 0| = 0,002658 > \xi = 10^{-6}$  dan  $t = 1 <$

$\text{MaxIter} = 10$ , maka proses dilanjutkan ke iterasi ke-2 dengan menghitung perubahan matriks partisi terlebih dahulu. Detail perhitungan perubahan matriks partisi dapat dilihat pada Tabel 2.6:

Tabel 2.6 Perhitungan Matriks Partisi pada Iterasi ke-1

$(d_{i1})^{-1}$	$(d_{i2})^{-1}$	Total	$\mu_{i1}$	$\mu_{i2}$
97,25908	307,4383	404,6974	0,240325	0,759675
375,387	108,5562	483,9432	0,775684	0,224316
608,107	530,6308	608,6376	0,999128	0,000872
439,0933	117,9334	557,0266	0,788281	0,211719

Diperoleh matriks partisi yang baru sebagai berikut:

$$U_{(1)} = \begin{bmatrix} 0,2403 & 0,7596 \\ 0,7756 & 0,2243 \\ 0,9991 & 0,0008 \\ 0,7882 & 0,2117 \end{bmatrix}$$

Iterasi Ke-2

Selanjutnya menghitung pusat-pusat *cluster* yang terbentuk berdasarkan matriks partisi awal yang baru. Pusat *cluster* pertama hasil iterasi ke-2 dapat dilihat pada Tabel 2.7 dan pusat *cluster* kedua hasil iterasi ke-2 dapat dilihat pada Tabel 2.8:

Tabel 2.7 Pusat *Cluster* Pertama yang Dihasilkan pada Iterasi Ke-2

$\mu_{i1}$	$x_{i1}$	$x_{i2}$	$\mu_{i1}^2$	$\mu_{i1}^2 \times x_{i1}$	$\mu_{i1}^2 \times x_{i2}$
0,2403	0,42126	0,973482	0,057756322	0,024331	0,056225
0,7756	0,26859	0,983691	0,601685721	0,161611	0,591873
0,9991	0,32095	0,978699	0,998257093	0,320396	0,976993
0,7882	0,27236	0,981548	0,621386184	0,169244	0,60992
$\Sigma$			0,30250303	0,096815	2,279085
$V_2 = \frac{\sum_{i=1}^4 ((\mu_{i1})^2 * X_{ij})}{\sum_{i=1}^4 (\mu_{i1})^2}$				0,296427	0,980661



Tabel 2.8 Pusat *Cluster* Kedua yang Dihasilkan pada Iterasi Ke-2

$\mu_{i2}$	$x_{i1}$	$x_{i2}$	$\mu_{i2}^2$	$\mu_{i2}^2 \times x_{i1}$	$\mu_{i2}^2 \times x_{i2}$
0,7596	0,42126	0,973482	0,5771054	0,243113	0,561802
0,2243	0,26859	0,983691	0,0503176	0,013515	0,049497
0,0008	0,32095	0,978699	$7,6 \times 10^{-7}$	$2,44 \times 10^{-7}$	$7,44 \times 10^{-7}$
0,2117	0,27236	0,981548	0,0448251	0,012209	0,043998
$\Sigma$			0,6722489	0,268837	0,655298
$V_2 = \frac{\sum_{i=1}^4 ((\mu_{i1})^2 * X_{ij})}{\sum_{i=1}^4 (\mu_{i1})^2}$				0,399907	0,974784

Sehingga pusat *cluster* yang terbentuk adalah:

$$V_{(2)} = \begin{bmatrix} 0,2964 & 0,98066 \\ 0,3999 & 0,97478 \end{bmatrix}$$

Fungsi Obyektif yang dihasilkan adalah

$$P_2 = \sum_{i=1}^4 \sum_{k=1}^2 \left( \left[ \sum_{j=1}^2 (X_{ij} - V_{kj})^2 \right] (\mu_{ik})^2 \right) = 0,01312$$

Detail perhitungan dapat dilihat pada Tabel 2.9.

Tabel 2.9 Perhitungan Fungsi Obyektif pada iterasi ke-2

$\mu_{i1}^2$	$\mu_{i2}^2$	$\sum_{j=1}^2 (X_{i1} - V_{1j})^2$	$\sum_{j=1}^2 (X_{i2} - V_{2j})^2$	$(\mu_{i1})^2 \cdot d_{i1}$	$(\mu_{i2})^2 \cdot d_{i2}$	$L_1 + L_2$
		$d_{i1}$	$d_{i2}$	$L_1$	$L_2$	
0,0577	0,57710	0,015642	0,000458	0,003759	0,000348	0,00410
0,6016	0,05031	0,000782	0,01732	0,000607	0,003885	0,00449
0,9982	$7,6 \times 10^{-7}$	0,000607	0,006248	0,000606	$5,45 \times 10^{-6}$	0,00061
0,6213	0,04482	0,000578	0,016311	0,000456	0,003453	0,00390
$P_{(2)}$						0,01312

Karena  $|P_2 - P_1| = |0,01312 - 0,002658| = 0,010462 > \xi = 10^{-6}$  dan  $t = 2 < \text{MaxIter} = 10$ , maka proses dilanjutkan ke iterasi berikutnya dengan terlebih dahulu menghitung perubahan matriks partisi. Detail perhitungan perubahan matriks partisi pada iterasi ke-2 dapat dilihat pada Tabel 2.10:

Tabel 2.10 Perhitungan Matriks Partisi pada Iterasi ke-2

$(d_{i1})^{-1}$	$(d_{i2})^{-1}$	Total	$\mu_{i1}$	$\mu_{i2}$
63,93003	2183,265	2247,195	0,028449	0,971551
1278,44	57,73696	1336,177	0,956789	0,043211
1647,886	160,0633	1807,949	0,911467	0,088533
1728,728	61,30859	1790,037	0,96575	0,03425

Diperoleh matriks partisi yang baru sebagai berikut:

$$U_{(1)} = \begin{bmatrix} 0,0284 & 0,9715 \\ 0,9567 & 0,0432 \\ 0,9114 & 0,0885 \\ 0,9657 & 0,0342 \end{bmatrix}$$

Demikian seterusnya sampai terpenuhi kondisi  $|P_{(t+1)} - P_t| < \xi$  atau  $t > \text{MaxIter}$ . Proses perhitungan berhenti pada iterasi ke-6 ( $t=6$ ), karena terpenuhinya salah satu syarat yaitu:

$$|P_6 - P_5| = |0,001580 - 0,001585| = -0,000005 < \xi = 10^{-6}$$

Pusat *cluster* yang dihasilkan pada iterasi terakhir adalah:

$$V_{(2)} = \begin{bmatrix} 0,2847 & 0,9815 \\ 0,4197 & 0,9736 \end{bmatrix}$$

Berdasarkan pusat *cluster* tersebut, diperoleh informasi sebagai berikut:

- a. *Cluster* pertama terdiri dari objek-objek yang memiliki rata-rata  $X_1$  sebesar 0,2847 dan rata-rata  $X_2$  sebesar 0,9815.
- b. *Cluster* kedua terdiri dari objek-objek yang memiliki rata-rata  $X_1$  sebesar 0,4197 dan rata-rata  $X_2$  sebesar 0,9736.

Matriks partisi U pada iterasi terakhir adalah

$$U_{(6)} = \begin{bmatrix} 0,0001 & 0,9999 \\ 0,9886 & 0,0114 \\ 0,8809 & 0,1191 \\ 0,9931 & 0,0069 \end{bmatrix}$$

Berdasarkan matriks di atas, diperoleh informasi mengenai kecenderungan dari masing-masing objek untuk masuk ke dalam *cluster* tertentu. Setiap objek memiliki derajat keanggotaan tertentu pada setiap *cluster*. Derajat keanggotaan terbesar pada suatu *cluster* menunjukkan bahwa objek itu cenderung menjadi anggota dari *cluster* tersebut. Secara detail, dapat dilihat pada Tabel 2.11:

Tabel 2.11 Derajat Keanggotaan Setiap Objek pada Iterasi Terakhir

Objek	Variabel		Derajat Keanggotaan pada Iterasi Terakhir		Kecenderungan Data Masuk pada <i>Cluster</i>	
	$X_1$	$X_2$	$U_1$	$U_2$	$K_1$	$K_2$
2810.jpg	0,42126	0,973482	0,0001	0,9999		*
2811.jpg	0,26859	0,983691	0,9886	0,0114	*	
2888.jpg	0,32095	0,978699	0,8809	0,1191	*	
2993.jpg	0,27236	0,981548	0,9931	0,0069	*	

Hasil akhirnya adalah terbentuknya dua buah *cluster*, dengan *cluster* pertama beranggotakan objek 2810.jpg, sedangkan objek 2811.jpg, 2888.jpg, dan 2993.jpg menjadi anggota *cluster* kedua.

## D. Konsep Himpunan *Fuzzy*

### 1. Himpunan *Fuzzy*

Teori himpunan *fuzzy* merupakan generalisasi dari teori himpunan tegas. Pada himpunan tegas, nilai keanggotaan elemen  $x$  dalam himpunan  $H$  dinotasikan dengan  $\mu_H(x)$  memiliki dua kemungkinan. Bernilai 1 jika  $x$  merupakan elemen dari himpunan  $H$ , dan bernilai nol jika  $x$  bukan elemen dari himpunan  $H$  (Kusumadewi & Hartati, 2010).

**Definisi 2.1** (Wang, 1997: 21). *Suatu himpunan fuzzy  $A$  pada himpunan semesta  $P$  direpresentasikan oleh fungsi keanggotaan  $\mu_A(x)$  yang nilainya berada pada interval  $[0,1]$ .*

Fungsi keanggotaan  $\mu_A(x)$  dinotasikan sebagai berikut:

$$\mu_A(x): P \rightarrow [0,1] \quad (2.20)$$

Himpunan *fuzzy* memiliki dua atribut, yaitu (Kusumadewi & Purnomo, 2013: 6):

- a. Linguistik, yaitu penamaan suatu grup yang mewakili suatu keadaan atau kondisi tertentu dengan menggunakan bahasa alami, seperti muda, dewasa, tua. Penamaan suatu grup juga menggunakan alphabet seperti pada variabel *contrast* yang dibagi menjadi 50 himpunan *fuzzy*, yaitu  $A_1, A_2, \dots, A_{50}$ .
- b. Numerik, yaitu suatu nilai yang menunjukkan ukuran dari suatu variabel, seperti pada variabel *contrast* memiliki nilai 0,26097 dan 0,34078.

## 2. Fungsi Keanggotaan

Fungsi keanggotaan adalah suatu kurva yang menunjukkan pemetaan titik-titik *input* data ke dalam nilai keanggotaannya atau disebut juga derajat keanggotaan, yang memiliki interval antara 0 sampai 1. Salah satu cara untuk mendapatkan nilai keanggotaan adalah dengan pendekatan fungsi. Beberapa fungsi yang dapat digunakan antara lain (Kusumadewi & Purnomo, 2013: 8- 23):


- a. Representasi Linear
- b. Representasi Kurva Segitiga
- c. Representasi Kurva Trapesium
- d. Representasi Kurva Bahu
- e. Representasi Kurva-S
- f. Representasi Kurva bentuk Lonceng

Kurva berbentuk lonceng biasa digunakan untuk merepresentasikan bilangan *fuzzy*. Kurva ini terbagi menjadi tiga kelas yaitu kurva  $\pi$ , kurva beta, dan kurva gauss.

Penelitian ini menggunakan fungsi keanggotaan gauss. Kurva gauss menggunakan dua parameter, yaitu pusat kurva ( $k$ ) dan setengah lebar kurva ( $b$ ) (Kusumadewi & Purnomo, 2013: 8-23).

Fungsi keanggotaan


$$G(x; k, b) = e^{-\frac{(x-b)^2}{2k^2}} \quad (2.21)$$



**Gambar 2.2** Kurva Gauss

**Contoh 2.1.** Fungsi keanggotaan untuk himpunan *fuzzy sum average* sedang dengan kurva gauss ditunjukkan pada Gambar 2.18 dengan fungsi keanggotaan sebagai berikut:

$$G(x; 10,94; 0,7975) = e^{-\frac{(x-0,7975)^2}{(2(10,94))^2}}$$



**Gambar 2.3** Fungsi Keanggotaan dari Himpunan *Fuzzy Sum Average* Sedang

### 3. Operator Dasar Zadeh untuk Operasi Himpunan *Fuzzy*

Terdapat beberapa operasi yang didefinisikan secara khusus untuk mengkombinasikan dan memodifikasi himpunan *fuzzy*. Nilai keanggotaan sebagai hasil dari operasi dua himpunan dikenal dengan nama *firestrength* atau  $\alpha$ -predikat. Ada tiga operator dasar yang diciptakan oleh Zadeh, yaitu:

#### 1. Operator AND

Operator ini berhubungan dengan operasi interseksi atau irisan pada himpunan.  $\alpha$ -predikat sebagai hasil operasi dengan operator AND diperoleh dengan mengambil nilai keanggotaan terkecil antar elemen pada himpunan-himpunan yang bersangkutan.

$$\mu_{(A \cap B)} = \min(\mu_A[x], \mu_B[y]) \quad (2.22)$$

#### 2. Operator OR

Operator ini berhubungan dengan operasi *union* (gabungan) pada himpunan.  $\alpha$ -predikat sebagai hasil operasi dengan operator OR diperoleh dengan

mengambil nilai keanggotaan terbesar antar elemen pada himpunan-himpunan yang bersangkutan.

$$\mu_{(A \cup B)} = \max(\mu_A[x], \mu_B[y]) \quad (2.23)$$

### 3. Operator *NOT*

Operator ini berhubungan dengan operasi komplemen pada himpunan.  $\alpha$ -predikat sebagai hasil operasi dengan operator *NOT* diperoleh dengan mengurangi nilai keanggotaan elemen pada himpunan yang bersangkutan dari 1.

$$\mu_{A^c}(x) = 1 - \mu_A[x] \quad (2.24)$$

(Kusumadewi & Purnomo, 2010: 25-26)

### 4. Fungsi Implikasi

Tiap-tiap aturan pada basis pengetahuan *fuzzy* akan berhubungan dengan suatu relasi *fuzzy*. Bentuk umum dari aturan yang digunakan dalam fungsi implikasi adalah:

$$IF \ x \ is \ A \ THEN \ y \ is \ B$$

Dengan  $x$  dan  $y$  adalah scalar.  $A$  dan  $B$  adalah himpunan *fuzzy*. Proposisi yang mengikuti *IF* disebut sebagai anteseden, sedangkan proposisi yang mengikuti *THEN* disebut sebagai konsekuen. Proposisi ini dapat diperluas dengan menggunakan operator *fuzzy*, seperti berikut:

$$IF(x_1 \ is \ A_1) \cdot (x_2 \ is \ A_2) \cdot (x_3 \ is \ A_3) \cdot \dots \cdot (x_n \ is \ A_n) \ THEN \ y \ is \ B$$

dengan  $\cdot$  adalah operator (misal *OR* atau *AND*) (Kusumadewi & Purnomo, 2010).

## **E. Model *Fuzzy***

Dalam membuat suatu model *fuzzy* terdapat empat tahapan. Empat tahapan tersebut yaitu:

### **1. Fuzzifikasi**

Fuzzifikasi adalah pemetaan dari himpunan tegas ke himpunan *fuzzy* dengan suatu fungsi keanggotaan. Semua anggota pada himpunan tegas harus termuat dalam himpunan *fuzzy*. Melalui fungsi keanggotaan yang telah disusun maka nilai-nilai *input* yang ditentukan menjadi informasi *fuzzy*. (Wang, 1997: 105).

### **2. Pembentukan Aturan**

Aturan dalam himpunan *fuzzy* adalah aturan jika-maka (*If-Then*). Menurut Wang (1997:62-63), aturan *fuzzy If-Then* merupakan pernyataan yang direpresentasikan dengan *IF*<*proposisi fuzzy*> *THEN* <*proposisi fuzzy*>. Terdapat dua macam *proposisi fuzzy*, yaitu *proposisi fuzzy atomic* dan *proposisi fuzzy compound*. *Proporsi fuzzy atomic* adalah pernyataan *single* dengan  $x$  sebagai variabel linguistik dan  $F$  adalah himpunan *fuzzy* dari  $x$ . Sedangkan *proposisi fuzzy compound* adalah gabungan dari *proposisi fuzzy atomic* dengan operator “*or*”, “*and*”, dan “*not*”.

### **3. Inferensi *Fuzzy***

Inferensi *fuzzy* bertujuan untuk memperoleh *output* menggunakan penalaran *input* dan aturan *fuzzy*. Sistem inferensi *fuzzy* memiliki beberapa



metode, berikut adalah metode yang sering digunakan dalam berbagai penelitian (Kusumadewi & Purnomo, 2013: 31-46):

a. Metode Tsukamoto

Pada metode Tsukamoto, setiap konsekuen pada aturan *if-then* direpresentasikan ke dalam suatu himpunan *fuzzy* dengan fungsi keanggotaan monoton. *Output* hasil inferensi dari setiap aturan yang diberikan secara tegas berdasarkan tingkat keanggotaannya. Untuk menentukan hasil tegas digunakan rumus penegasan (defuzzifikasi) yaitu dengan menggunakan rata-rata terbobot.

b. Metode Mamdani

Metode Mamdani pertama kali diperkenalkan oleh Ebrahim Mamdani pada tahun 1975. Metode ini merupakan metode paling sederhana dibandingkan dengan metode lainnya sehingga metode ini sering digunakan pada penelitian. Inferensi dengan metode Mamdani menggunakan fungsi implikasi *Min*, sedangkan komposisi aturannya menggunakan *Max*. Untuk variabel *input* maupun *output* dibagi menjadi satu atau dua lebih himpunan *fuzzy*.

c. Metode Sugeno

Metode ini pertama kali diperkenalkan oleh Sugeno pada tahun 1985. Metode Sugeno mirip dengan metode Mamdani. Namun *output* dari metode Sugeno berupa konstanta atau persamaan linier. Metode Sugeno terbagi menjadi dua sistem yaitu (Cox, 1994):

1) Sugeno orde nol

Secara umum bentuk *fuzzy* Sugeno orde nol adalah

$IF(x_1 \text{ is } A_1) o (x_2 \text{ is } A_2) o \dots o (x_i \text{ is } A_i) THEN y = k$

$A_i$  = himpunan *fuzzy* ke- $i$  pada variabel  $x_1$

$k$  = konstanta tegas sebagai konsekuen

$o$  = operator *fuzzy*

## 2) Sugeno orde satu

Secara umum bentuk *fuzzy* Sugeno orde satu adalah

$IF(x_1 \text{ is } A_1) o (x_2 \text{ is } A_2) o \dots o (x_i \text{ is } A_i) THEN y = b_1 * x_1 + \dots + b * x_0 + b_0$

$A_i$  = himpunan *fuzzy* ke- $i$  pada variabel  $x_i$

$b_i$  = konstanta tegas ke- $i$  pada variabel  $x_i$

$b_0$  = konstanta tegas sebagai konsekuen

$o$  = operator *fuzzy*

Dalam penelitian ini, sistem inferensi yang digunakan adalah metode

Sugeno orde nol.

## 4. Defuzzifikasi

*Output* dari sistem inferensi masih berupa himpunan *fuzzy*, oleh karena itu perlu diubah ke himpunan tegas melalui proses defuzzifikasi. Defuzzifikasi pada metode sugeno yaitu dengan mencari nilai rata-rata dari aturan yang telah dibangun. Nilai hasil defuzzifikasi adalah *output* dari model *fuzzy*. Di dalam penelitian ini digunakan metode defuzzifikasi *weight average* sebagai berikut (Kusumadewi & Purnomo, 2010):

$$y = \frac{\sum_{i=1}^L (\alpha \text{pred}_i \times y_i)}{\sum_{i=1}^L (\alpha \text{pred}_i)} \quad (2.25)$$

dengan  $y_i =$  konsekuen aturan ke- $i$

$L =$  Banyaknya aturan

$\alpha_{pred_i} = \alpha$ -predikat aturan ke- $i$ .

## 5. Uji Ketepatan Diagnosis

Tingkat ketepatan hasil diagnosis suatu penelitian dapat ditentukan dengan menghitung akurasi, sensitivitas, dan spesififikasi dari model yang telah dibuat. Berikut ukuran hasil diagnosis untuk menghitung sensitivitas dan spesififikasi (Sharma & Mukherjee, 2013):

- a. *True Positive* (TP), yaitu banyaknya pasien yang sakit dan hasil klasifikasi menyatakan pasien tersebut sakit.
- b. *False Positive* (FP), yaitu banyaknya pasien sehat dan hasil klasifikasi menyatakan pasien tersebut sakit.
- c. *True Negative* (TN), yaitu banyaknya pasien sehat dan hasil klasifikasi menyatakan pasien tersebut sehat.
- d. *False Negative* (FN), yaitu banyaknya pasien sakit dan hasil klasifikasi menyatakan pasien tersebut sehat.

### 1. Akurasi

Model yang baik akan memiliki tingkat akurasi 100%. Secara umum akurasi dapat dihitung dengan rumus:

$$akurasi = \frac{jumlah\ data\ benar}{jumlah\ data\ keseluruhan} \times 100\% \quad (2.26)$$

## 2. Sensitifitas

Sensitifitas berkaitan dengan tes kemampuan untuk mengidentifikasi hasil yang positif. Rumus untuk menghitung sensitifitas adalah (Altman & Bland, 1994)

$$\text{sensitifitas} = \frac{TP}{TP + FN} \times 100\% \quad (2.27)$$

## 3. Spesifikasi

Spesifikasi berkaitan dengan tes kemampuan untuk mengidentifikasi hasil yang negatif. Rumus untuk spesifikasi adalah (Altman & Bland, 1994)

$$\text{spesifikasi} = \frac{TN}{TN + FP} \times 100\% \quad (2.28)$$