

BAB II

KAJIAN TEORI

Bab II berisi tentang kajian teori yang akan digunakan dalam penelitian ini di antaranya mengenai kanker paru, pengolahan citra digital, perbaikan kualitas citra, ekstraksi fitur citra, jaringan saraf tiruan, logika *fuzzy*, dan ketepatan hasil diagnosa.

A. Kanker Paru

Penyakit kanker merupakan salah satu penyebab kematian utama diseluruh dunia. Pada tahun 2012, kanker menjadi penyebab kematian sekitar 8,2 juta orang. Kanker paru, hati, perut, kolorektal, dan kanker payudara adalah penyebab terbesar kematian akibat kanker setiap tahunnya. Kanker paru telah menjadi salah satu kanker yang sering terjadi dalam beberapa dekade ini. Pada tahun 2012 diperkirakan terdapat kasus baru kanker paru diseluruh dunia yaitu 1,8 juta dengan angka kematian sebesar 1,59 juta dan 58% kasus kanker paru ditemukan dikawasan negara-negara yang belum berkembang. Kanker paru menjadi penyebab kematian terbanyak pada segala jenis kanker yang terjadi di seluruh dunia, diperkirakan 1 dari 5 penderita kanker paru meninggal dunia (GLOBOCAN, 2012).

1. Pengertian Kanker Paru

Kanker paru merupakan pertumbuhan sel-sel abnormal yang tak terkendali pada salah satu atau kedua paru-paru. Selama masa pertumbuhan, sel-sel abnormal dapat berubah menjadi tumor dan mengganggu fungsi dari paru-paru, yang memberi oksigen ke tubuh melalui darah. Sel kanker dimulai dari mutasi yang terjadi pada DNA (*deoxyribonucleic acid*) sel. Mutasi DNA disebabkan oleh proses penuaan dini atau adanya faktor lingkungan seperti asap rokok, polusi udara, hingga terpapar

zat karsinogenik seperti arsen, asbestos, radon, kadmium (*Cancer Care*, 2017). Menurut WHO (*World Health Organization*), kanker paru merupakan penyumbang insiden kanker pada laki-laki tertinggi di Indonesia, diikuti kanker kolorektal, prostat, hati dan nasofaring dan merupakan penyumbang kasus kelima pada perempuan setelah kanker payudara, serviks, kolorektal, ovarium. Gejala awal kanker paru seperti batuk, suara serak dan lain-lain dapat dengan mudah disalah artikan sebagai penyakit flu atau gejala perokok biasa sehingga banyak kanker paru pada stadium awal sulit terdeteksi.

2. Jenis Kanker Paru

Kanker paru dibagi menjadi dua jenis yaitu (Varalakshmi, 2013: 63-64):

a. Kanker paru jenis karsinoma sel kecil (*Small Cell Lung Cancer*)

Kanker paru jenis karsinoma sel kecil terjadi sekitar 20% dari seluruh kasus kanker paru. Jenis kanker ini berhubungan erat dengan kebiasaan merokok. Pada kasus jenis kanker ini 1% terjadi pada penderita yang bukan perokok.

b. Kanker paru jenis karsinoma bukan sel kecil (*Non-Small Cell Lung Cancer*)

Kanker paru jenis karsinoma bukan sel kecil merupakan jenis kanker paru-paru yang paling umum terjadi, yaitu sekitar 80% dari seluruh jenis kanker paru. Kanker paru jenis karsinoma bukan sel kecil memiliki 3 jenis utama yang diberi nama berdasarkan jenis sel yang ditemukan, yaitu:

1) Karsinoma sel skuamosa

Karsinoma sel skuamosa dikenal juga dengan nama *epidermoid carcinomas*. Karsinoma sel skuamosa paling sering tumbuh di daerah pusat paru-paru, yaitu bronkus (percabangan terbesar dari *trachea* menuju ke paru-paru).

2) Adenokarsinoma

Adenokarsinoma adalah jenis kanker paru bukan sel kecil yang paling umum sekitar 30-40 %. Jenis ini terjadi lebih umum pada wanita dan mereka yang tidak merokok. sebagian besar kasus adenokarsinoma tumbuh di daerah tepi atau bagian luar paru-paru. Namun, adenokarsinoma dapat menyebar ke limfe (kelenjar getah bening) dan daerah yang jauh dari paru-paru.

3) Karsinoma sel besar

Karsinoma sel besar disebut juga dengan *undifferentiated carcinomas*. Jenis ini paling jarang terjadi, terhitung sekitar 10-15 % dari seluruh kasus kanker paru-paru.

3. Faktor Resiko Kanker Paru

Seperti umumnya penyakit kanker yang lain, penyebab yang pasti dari kanker paru belum diketahui. Namun, faktor resiko seseorang mengalami kanker paru sangat berhubungan erat dengan rokok atau paparan zat yang bersifat karsinogenik. Berikut ini faktor resiko penyebab terjadinya kanker paru (*American Cancer Society*, 2017):

a. Merokok

Merokok merupakan faktor yang berperan paling penting. Sekitar 80% kematian kanker paru disebabkan dari kebiasaan merokok. Resiko seorang perokok aktif lebih tinggi dibanding perokok pasif. Kejadian kanker paru pada perokok dipengaruhi oleh lamanya kebiasaan merokok, jumlah rokok yang dihisap setiap hari dan lamanya berhenti merokok.

b. Polusi Udara

Polusi udara menyebabkan resiko kanker paru terutama di daerah perkotaan yang padat kendaraan. Namun, resiko kanker paru yang ditimbulkan lebih rendah dibandingkan dengan kebiasaan merokok. Pada beberapa penelitian, diperkirakan sekitar 5% kematian kanker paru diseluruh dunia disebabkan dari polusi udara.

c. Paparan zat karsinogenik

Beberapa zat karsinogenik seperti radon, asbestos, arsen, uranium, kadmium, nikel, vinil klorida, kromium dapat menyebabkan kanker paru. Zat-zat karsinogenik tersebut dapat ditemui di lingkungan kerja seperti kawasan pabrik industri dan pertambangan.

d. Genetika

Faktor resiko penyebab kanker paru juga dapat disebabkan oleh genetika. Apabila keluarga memiliki riwayat kanker paru dapat meningkatkan resiko terkena kanker paru, namun belum begitu jelas seberapa besar tingkat resiko yang dialami.

4. Gejala Kanker Paru

Pada umumnya gejala kanker paru akan mulai dirasakan apabila kanker telah menyebar, akan tetapi beberapa orang mengalami gejala-gejala pada tahap awal. Berikut ini gejala-gejala kanker paru pada tahap awal (*American Cancer Society*, 2017):

- a. Mengalami batuk jangka panjang dan batuk berdarah
- b. Sakit di dada pada saat menarik nafas panjang atau pada saat tertawa
- c. Nafsu makan berkurang sehingga berat badan turun
- d. Nafas yang pendek, mudah merasakan letih dan lesu

- e. Mengalami infeksi seperti *bronchitis* dan *pneumonia*

5. Deteksi Dini Kanker Paru

Menurut *Japanese Society of Radiology Technology*, nodul atau benjolan yang terdeteksi pada paru-paru dikategorikan menjadi dua yaitu *non cancerous nodule* (tumor jinak) dan *cancerous nodule* (tumor ganas). Tumor jinak yang terdapat pada jaringan paru tidak akan menyerang selain organ paru karena tumor jinak hanya menyerang satu tempat dan tidak menyebar ke organ tubuh lainnya. Gejala awal kanker paru seperti batuk, demam, suara serak dan lain-lain dapat dengan mudah disalah artikan sebagai penyakit flu atau gejala pada orang merokok. sehingga banyak kanker paru pada stadium awal sulit dideteksi. Berikut ini beberapa cara deteksi dini kanker paru (*Modern Cancer Hospital Guangzhou*, 2015):

a. *X-Ray*

X-Ray adalah metode penting dalam pendeteksian kanker paru, sebagian besar kanker paru terdeteksi saat melakukan *x-ray* di bagian dada. Melalui pemeriksaan ini, dapat diketahui ada tidaknya tumor, letak dan ukuran tumor, serta melihat perubahan inflamasi paru yang disebabkan hambatan tumor pada bronkus yang menimbulkan emfisema lokal atau lesi sekitar. Teknik radiografi *x-ray* di bagian dada terdiri dari bermacam-macam posisi yang harus dipilih disesuaikan dengan indikasi pemeriksaan, misalnya bronchitis kronis, fleural effusion, pneumo thorax dan lain-lain. Foto thorax menggunakan radiasi terionisasi dalam bentuk *x-ray*. Dosis radiasi yang digunakan pada orang dewasa untuk membentuk radiografi adalah sekitar 0,006 mSv.

b. Sitologi sputum (dahak)

Sitologi sputum adalah tindakan diagnostik yang paling mudah dan murah. Kekurangan pemeriksaan ini terjadi bila tumor ada di perifer, penderita batuk kering dan teknik pengumpulan dan pengambilan sputum yang tidak memenuhi syarat. Dengan bantuan inhalasi NaCl 3% untuk merangsang pengeluaran sputum dapat ditingkatkan. Semua bahan yang diambil dengan pemeriksaan tersebut di atas harus dikirim ke laboratorium Patologi Anatomi untuk pemeriksaan sitologi. Pemeriksaan sitologi sputum dapat menentukan jenis patologi sel kanker dan kanker paru. Metode ini memiliki tingkat keakuratan lebih dari 80%. Secara klinis, pada pasien yang memiliki resiko lebih besar dapat melakukan sitologi sputum secara berulang.

c. Bronkoskopi

Bronkoskopi adalah pemeriksaan dengan tujuan diagnostik sekaligus dapat diandalkan untuk dapat mengambil jaringan atau bahan agar dapat dipastikan ada tidaknya sel ganas. Pemeriksaan ada tidaknya masa intrabronkus atau perubahan mukosa saluran napas, seperti terlihat kelainan mukosa tumor misalnya, benjolan, hiperemis, atau stenosis infiltratif, mudah berdarah. Pendiagnosaan melalui bronkoskopi terhadap pasien kanker paru cenderung lebih tinggi. Melalui cara ini dapat dilihat secara langsung tumor di bagian rongga bronkus, serta mengambil jaringan kecil untuk dilakukan biopsi.

d. Biopsi jaringan

Biopsi adalah tindakan diagnostik yang dilakukan dengan mengambil sampel jaringan atau sel untuk dianalisis di laboratorium, baik untuk mendiagnosis suatu

penyakit atau untuk mengetahui jenis pengobatan atau terapi yang terbaik bagi pasien. Biopsi seringkali dikaitkan dengan kanker. Kanker dapat dideteksi dalam sel dan jaringan tubuh, dimana sel dapat menjadi tumor atau massa yang melekat pada organ tubuh. Ada banyak cara untuk melakukan biopsi, tergantung jenis jaringan yang dibutuhkan oleh dokter, penyakit yang diduga menyebabkan gangguan, atau hasil tes awal. Biasanya, biopsi dilakukan pada pasien kanker paru yang telah memasuki stadium lanjut, misalnya tumor sudah menyebar ke tulang selangka, bagian leher, ketiak dan kelenjar getah bening atau muncul nodul pada bagian bawah kulit.

B. Pengolahan Citra Digital

Secara umum, pengolahan citra digital merupakan pemrosesan gambar dua dimensi menggunakan komputer. Sebuah citra dapat didefinisikan sebagai fungsi dua dimensi $f(x, y)$, dengan x dan y adalah koordinat spasial dan amplitudo f pada sembarang pasangan koordinat (x, y) disebut tingkat keabuan citra pada titik tersebut (Gonzales & Woods, 2002: 1).

Nilai atau amplitudo f pada koordinat spasial (x, y) merupakan kuantitas positif skalar dan terbatas,

$$0 < f(x, y) < \infty \quad (2.1)$$

Fungsi $f(x, y)$ dapat diartikan sebagai karakteristik dari dua komponen yaitu jumlah cahaya yang terdapat pada citra $i(x, y)$ dan jumlah cahaya yang dipantulkan oleh objek pada citra $r(x, y)$ (Gonzales & Woods, 2002: 50-51). Fungsi $f(x, y)$ diperoleh dari perkalian dua fungsi $i(x, y)$ dan $r(x, y)$.

$$f(x, y) = i(x, y)r(x, y) \quad (2.2)$$

dengan

$$0 < i(x, y) < \infty \quad (2.3)$$

dan

$$0 < r(x, y) < 1 \quad (2.4)$$

Intensitas citra monokrom pada setiap koordinat (x_0, y_0) , tingkat keabuan (ℓ) gambar pada titik tersebut adalah,

$$\ell = f(x_0, y_0) \quad (2.5)$$

Berdasarkan Persamaan (2.2) s.d (2.4), menjelaskan bahwa ℓ terletak pada interval

$$L_{min} \leq \ell \leq L_{max} \quad (2.6)$$

Interval $[L_{min}, L_{max}]$ atau $[0, L - 1]$ disebut sebagai skala keabuan, dengan $\ell = 0$ adalah warna hitam dan $\ell = L - 1$ adalah warna putih pada skala keabuan.

Matriks yang dibentuk oleh citra digital dua dimensi berukuran $M \times N$, dengan M adalah jumlah baris dan N adalah jumlah kolom ditunjukkan sebagai berikut,

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,0) & \dots & f(0, n-1) \\ f(1,0) & f(1,1) & \dots & f(1, n-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(m-1,0) & f(m-1,1) & \dots & f(m-1, n-1) \end{bmatrix} \quad (2.7)$$

Indeks baris (x) dan indeks kolom (y) menyatakan suatu koordinat titik pada citra, sedangkan $f(x, y)$ merupakan intensitas atau derajat keabuan pada titik (x, y) . Elemen pada matriks merupakan elemen citra digital yang disebut dengan piksel.

Citra digital terbagi menjadi tiga jenis yaitu citra biner, citra *grayscale*, dan citra warna. Berikut ini penjelasan jenis-jenis citra digital (Putra, 2010: 40 – 44):

1. Citra Biner

Citra biner adalah citra digital yang hanya memiliki dua kemungkinan nilai piksel yaitu hitam dan putih. Citra biner juga disebut sebagai citra B&W (*black and white*) atau citra monokrom. Citra biner seringkali muncul sebagai hasil dari proses pengolahan citra seperti segmentasi, morfologi, mengurangi jumlah warna (*dithering*).

2. Citra *Grayscale*

Citra *Grayscale* merupakan citra yang hanya memiliki suatu nilai kernel pada setiap *pixel* ($Red=Green=Blue$). Warna yang dimiliki adalah warna dari hitam, keabuan, dan putih. Tingkat keabuan merupakan warna abu dengan berbagai tingkatan dari hitam hingga mendekati putih. Citra *grayscale* tersimpan dalam format 8 bit untuk setiap piksel dan memungkinkan sebanyak 256 nilai intensitas.

3. Citra Warna

Setiap *pixel* dari citra warna 24 bit diwakili dengan 24 bit sehingga terdapat 16.777.216 variasi warna. Penglihatan manusia dipercaya hanya dapat membedakan hingga 10 juta warna. Setiap poin informasi piksel (RGB) disimpan ke dalam 1 bit data. 8 bit pertama menyimpan warna biru, kemudian diikuti dengan warna hijau pada 8 bit kedua dan 8 bit terakhir merupakan warna merah.

C. Perbaikan Kualitas Citra

Perbaikan kualitas citra (*image enhancement*) merupakan salah satu proses awal dalam pengolahan citra. Perbaikan kualitas citra bertujuan untuk memperbaiki kualitas citra yang buruk, seperti halnya citra yang mengalami *noise*, citra yang terlalu terang atau gelap, citra yang kurang tajam atau kabur dan sebagainya.

Melalui pemrosesan awal inilah kualitas citra diperbaiki sesuai kebutuhan yang diinginkan melalui berbagai cara, dapat berupa fungsi transformasi, operasi matematis, pemfilteran, dan lain-lain.

Perbaikan kualitas citra adalah proses mendapatkan citra yang lebih mudah diinterpretasikan oleh mata manusia. Pada proses ini, ciri-ciri tertentu yang terdapat di dalam citra lebih diperjelas kemunculannya. Secara matematis, perbaikan kualitas citra dapat diartikan sebagai proses mengubah citra $f(x,y)$ menjadi $g(x,y)$ sehingga ciri-ciri yang dilihat pada $f(x,y)$ lebih ditonjolkan. Proses-proses yang termasuk dalam perbaikan kualitas citra diantaranya pengubahan kecerahan citra (*image brightness*), peregangan kontras (*contrast stretching*), pengubahan histogram citra, pelembutan citra (*image smoothing*), penajaman (*sharpening*), pewarnaan semu (*pseudocolouring*), pengubahan geometrik (Munir, 2004: 91).

Untuk melakukan perbaikan kualitas citra terdapat beberapa teknik berdasarkan cakupan atau domain salah satunya adalah perbaikan citra pada domain frekuensi. Domain frekuensi adalah rentang sistem koordinat oleh $F(u,v)$ dengan u dan v sebagai variabel frekuensi. Secara analogi, pada domain spasial dimana rentang sistem koordinat $f(x,y)$ dengan x dan y sebagai variabel spasial (Prasetyo, 2011: 75).

Dalam proses pengolahan citra, Transformasi Fourier dapat digunakan sebagai perbaikan citra atau peningkatan kualitas citra. Transformasi Fourier mengubah suatu citra dari domain spasial menjadi domain frekuensi. Citra hasil proses transformasi dapat dianalisis kembali, diinterpretasikan, dan dijadikan acuan untuk melakukan pemrosesan selanjutnya. Transformasi Fourier yang biasa

diterapkan pada data citra adalah Transformasi Fourier Diskrit (*Discrete Fourier Transform*). Citra digital merupakan besaran diskrit 2-D, maka untuk melakukan pengolahan citra hanya membutuhkan Transformasi Fourier Diskrit 2-D.

1. Transformasi Fourier Diskrit (DFT 2-D)

Transformasi Fourier Diskrit 2-D dari sebuah fungsi diskrit $f(x, y)$ dinyatakan sebagai berikut (Gonzales & Woods, 2002: 154),

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \exp \left[-2\pi j \left(\frac{ux}{M} + \frac{vy}{N} \right) \right] \quad (2.8)$$

untuk $u = 0, 1, 2, \dots, M-1$, $v = 0, 1, 2, \dots, N-1$.

Sedangkan transformasi balik ke domain spasial dapat dinyatakan sebagai berikut,

$$f(x, y) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(u, v) \exp \left[2\pi j \left(\frac{ux}{M} + \frac{vy}{N} \right) \right] \quad (2.9)$$

untuk $x = 0, 1, 2, \dots, M-1$, $y = 0, 1, 2, \dots, N-1$.

Misalkan $R(u, v)$ dan $I(u, v)$ adalah komponen real dan imajiner dari $F(u, v)$, spektrum fourier atau yang dikenal sebagai *magnitude* didefinisikan sebagai berikut,

$$|F(u, v)| = [R^2(u, v) + I^2(u, v)]^{1/2} \quad (2.10)$$

dan sudut fase transformasi didefinisikan sebagai,

$$\phi(u, v) = \tan^{-1} \left[\frac{I(u, v)}{R(u, v)} \right] \quad (2.11)$$

Persamaan (2.10) dan (2.11) dapat digunakan untuk merepresentasikan $F(u, v)$ dalam representasi polar kuantitas kompleks

$$F(u, v) = |F(u, v)| e^{-i\phi(u, v)} \quad (2.12)$$

Power spektrum didefinisikan sebagai kuadrat dari *magnitude* sebagai berikut,


$$P(u, v) = |F(u, v)|^2 = R^2(u, v) + I^2(u, v) \quad (2.13)$$

Secara umum, untuk menentukan transformasi fourier pada suatu citra perlu dilakukan operasi perkalian pada fungsi input citra $f(x, y)$ dengan $(-1)^{x+y}$ terlebih dahulu sebagai berikut (Gonzales & Woods, 2002:154),


$$\mathfrak{F}[f(x, y)(-1)^{x+y}] = F(u - \frac{M}{2}, v - \frac{N}{2}) \quad (2.14)$$

dengan argumen $\mathfrak{F}(\cdot)$ menyatakan transformasi fourier. Persamaan (2.14) menyatakan bahwa titik origin pada transformasi fourier dari suatu citra adalah $F(0,0)$ berada pada titik koordinat suatu citra yaitu $u = M/2$ dan $v = N/2$. Dengan kata lain, melakukan operasi perkalian $f(x, y)$ dengan $(-1)^{x+y}$ adalah memindahkan titik origin dari $F(u, v)$ pada koordinat frekuensi $(\frac{M}{2}, \frac{N}{2})$ yang merupakan pusat daerah transformasi diskrit fourier 2-D berukuran $M \times N$.

Sebagai contoh, perhitungan DFT 2-D yang mentransformasikan titik-titik ke dalam interval persegi panjang yang ditunjukkan pada Gambar 2.1. Persegi panjang dengan garis putus-putus adalah perulangan periodik. Analisis visual spektrum transformasi fourier 2-D secara sederhana dengan memindahkan nilai origin transformasi ke pusat dari persegi panjang frekuensi. Nilai spektrum pada $(M/2, N/2)$ dalam Gambar 2.1(b) adalah sama dengan nilai di $(0,0)$ pada Gambar 2.1(a) dan nilai di $(0,0)$ pada Gambar 2.1(b) adalah sama dengan nilai di $(-M/2, -N/2)$ pada Gambar 2.1(a). Dengan cara yang sama, nilai di $(M-1, N-1)$ pada Gambar 2.1(b) adalah sama dengan nilai di $(M/2-1, N/2-1)$ pada Gambar 2.1(a).



(a)



(b)

-  = Periode Transformasi Diskrit Fourier 2-D
 = M x N larik data hasil dari komputasi F(u,v)

Gambar 2.1 Spektrum Fourier 2-D

Nilai Transformasi Fourier pada $(u, v) = (0, 0)$ dari Persamaan (2.8) adalah sebagai berikut (Gonzales & Woods, 2002:155),

$$F(0,0) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \quad (2.15)$$


yang merupakan rata-rata pada $f(x, y)$. Dengan kata lain, apabila $f(x, y)$ adalah suatu citra, nilai transformasi fourier pada titik origin akan sama dengan rata-rata dari derajat keabuan suatu citra.

2. Konsep Filter dalam Domain Frekuensi

Pada dasarnya, ide dalam pemfilteran pada domain frekuensi adalah untuk memilih fungsi transfer filter yang memodifikasi $F(u, v)$ dengan cara tertentu. Berikut ini adalah langkah – langkah melakukan *filtering* pada domain frekuensi adalah (Gonzales & Woods, 158):

- a. Kalikan citra input dengan $(-1)^{x+y}$ untuk memusatkan transformasi.

Pada Gambar 2.2(a) merupakan citra input, sedangkan Gambar 2.2(b) merupakan perkalian citra input (a) dengan $(-1)^{x+y}$.



(a)




(b)

Gambar 2.2 Citra Lena.jpg

- b. Hitung $F(u, v)$ pada Persamaan (2.8), DFT 2-D dari citra pada langkah (1).

Pada Gambar 2.3 merupakan spektrum fourier dari citra pada Gambar 2.2(b).

Untuk menghitung spektrum fourier pada suatu citra menggunakan Persamaan (2.8).



Gambar 2.3 Spektrum Fourier Citra pada Gambar 2.2(b)

- c. Kalikan $F(u, v)$ dengan fungsi filter $H(u, v)$.

Pada Gambar 2.4(a) merupakan spektrum fourier untuk fungsi filter $H(u, v)$.


Hasil perkalian antara $F(u, v)$ dan $H(u, v)$ ditunjukkan pada Gambar 2.4(b).



Gambar 2.4 Spektrum Fourier, (a) Spektrum Fourier Filter $H(u, v)$, (b) Spektrum Fourier hasil perkalian $F(u, v)$ dengan $H(u, v)$.

- d. Hitung invers DFT 2-D dari citra pada langkah (3) dengan Persamaan (2.9).


Untuk menghitung transformasi balik suatu citra dari domain frekuensi ke dalam domain spasial dengan menggunakan Persamaan (2.9). Selanjutnya menggunakan bagian real dari citra. Gambar 2.5 merupakan citra hasil transformasi balik dari citra pada langkah (3).



Gambar 2.5 Citra Hasil Transformasi Balik dari Citra pada Langkah (3)

- e. Kalikan hasil pada langkah (4) dengan $(-1)^{x+y}$.

Pada Gambar 2.6 merupakan citra hasil akhir dari perbaikan kualitas citra pada Gambar 2.2(a) dengan menggunakan domain frekuensi.



Gambar 2.6 Citra Hasil Perbaikan Kualitas Citra pada Domain Frekuensi

Misalkan $F(u, v)$ dan $H(u, v)$ merupakan Transformasi Fourier dari $f(x, y)$ dan $h(x, y)$. Pernyataan sederhana dari teorema konvolusi bahwa $f(x, y) * h(x, y)$ dan $F(u, v)H(u, v)$ menyatakan pasangan Transformasi Fourier. Hal tersebut dapat dinyatakan sebagai berikut (Gonzales & Woods, 2002:162),

$$f(x, y) * h(x, y) \Leftrightarrow F(u, v)H(u, v) \quad (2.16)$$

Simbol ‘*’ menyatakan konvolusi dari dua fungsi dan simbol ‘ $\Leftrightarrow$ ’ digunakan untuk menyatakan bahwa pada sisi kiri Persamaan (2.16) yang merupakan konvolusi pada domain spasial $[f(x, y) * h(x, y)]$ dapat diperoleh dengan mentransformasi balik hasil perkalian dari Transformasi Fourier $[F(u, v)H(u, v)]$ pada sisi kanan Persamaan (2.16). Sebaliknya, pada Persamaan (2.17) menyatakan bahwa pada sisi kanan Persamaan (2.17) yang merupakan konvolusi $[F(u, v) * H(u, v)]$ dapat diperoleh dengan melakukan Transformasi Fourier pada sisi kiri Persamaan (2.17).

$$f(x, y)h(x, y) \Leftrightarrow F(u, v) * H(u, v) \quad (2.17)$$

3. Filter Penajaman pada Domain Frekuensi

Filter penghalusan (*smoothing*) pada domain frekuensi dilakukan dengan pelemahan komponen frekuensi tinggi dari transformasi fourier atau yang disebut dengan *lowpass filter*. Berbeda pada filter penajaman (*sharpening*) pada domain frekuensi dapat dicapai dengan melemahkan frekuensi rendah tanpa mengganggu

informasi frekuensi tinggi dalam transformasi fouriernya. Filter penajaman biasanya disebut sebagai *highpass filter*. Filter *highpass* diperoleh dari filter *lowpass* dengan formula berikut (Gonzales & Woods, 2002: 180),

$$H_{hp}(u, v) = 1 - H_{lp}(u, v) \quad (2.18)$$

dengan,

$H_{lp}(u, v)$ = fungsi transfer filter *lowpass*.

Butterworth highpass filter merupakan salah satu filter *highpass* pada domain frekuensi. Pada *Butterworth Highpass Filter* (BHPF) menampilkan citra yang lebih halus jika dibandingkan dengan *Ideal Highpass Filter* (IHPF). BHPF dengan order n , *cut-off* frekuensi (D_0) dan jarak sembarang titik (u, v) ke titik origin ($D(u, v)$) didefinisikan sebagai berikut (Gonzales & Woods, 2002: 183),

$$H_{bt}(u, v) = \frac{1}{1 + [D_0/D(u, v)]^{2n}} \quad (2.19)$$

dengan

$$D(u, v) = [(u - M/2)^2 + (v - N/2)^2]^{1/2}$$

4. High Frequency Emphasis Filter (HFEF)

Terkadang dalam melakukan perbaikan kualitas citra pada doman frekuensi dapat difokuskan pada komponen frekuensi tinggi suatu citra tersebut. Pada kasus ini, dengan melakukan operasi perkalian pada fungsi filter *highpass* dengan suatu konstanta (b) dan menambahkan suatu *offset* (a) maka pendekatan ini disebut dengan *High Frequency Emphasis Filtering* (Sun, 2009: 1). Nilai konstanta pengali meningkatkan amplitudo frekuensi rendah, tetapi frekuensi rendah menerima efek *enhancement* yang lebih sedikit daripada frekuensi tinggi, dengan $a \geq 0$ dan $b > a$. Fungsi transfer filter *high frequency emphasis* diberikan sebagai berikut,

$$H_{hfe}(u, v) = a + bH_{hp}(u, v) \quad (2.20)$$

dengan,

$H_{hp}(u, v)$ = fungsi transfer filter *highpass*.

D. Ekstraksi Fitur Citra

Tekstur merupakan salah satu karakteristik terpenting yang dapat digunakan untuk mengidentifikasi objek atau daerah suatu citra yang diamati. Tekstur mengandung informasi penting tentang susunan struktural bidang. Fitur tekstur yang didasarkan atas warna abu-abu spasial secara umum digunakan dalam mengklasifikasikan citra (Gadkari, 2004: 8).

Haralick, Shanmugam & Dinstein (1973) pertama kali memperkenalkan penggunaan *co-occurrence probabilities* menggunakan GLCM untuk mengekstraksi beberapa fitur tekstur. GLCM atau yang disebut dengan *Gray Level Co-occurrence Matrix*. GLCM adalah sebuah matriks yang menyimpan nilai frekuensi kombinasi perbedaan tingkat kecerahan antara satu *pixel* dengan *pixel* sekitarnya pada sebuah citra (Sahaduta & Lubis, 2013: 4). Metode GLCM merupakan salah satu cara mengekstraksi *second-order statistical* fitur tekstur (Albregtsen, 2008: 1). Pendekatan ini banyak digunakan di beberapa aplikasi.

Berikut ini adalah beberapa ekstraksi fitur metode GLCM yang dapat digunakan (Gadkari, 2004: 12-15):

1. *Energy*

Ciri fitur statistik ini sering juga disebut dengan *Angular Second Moment* (ASM). Nilai *energy* mengukur keseragaman tekstur pada pengulangan pasangan piksel. Rumus fitur *energy* didefinisikan sebagai berikut,

$$energy = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{ij}^2 \quad (2.21)$$

keterangan :

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

P_{ij} = entri pada GLCM baris ke- i dan kolom ke- j .

N_g = banyak tingkat keabuan pada suatu citra.

2. Contrast

Nilai fitur *contrast* merupakan hasil perhitungan yang berkaitan dengan jumlah keberagaman intensitas keabuan dalam sebuah citra. Semakin tinggi tingkat keberagaman intensitas keabuan, maka semakin tinggi pula nilai *contrast*. Rumus fitur *contrast* didefinisikan sebagai berikut,

$$contrast = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 P_{ij} \quad (2.22)$$

keterangan :

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

P_{ij} = entri pada GLCM baris ke- i dan kolom ke- j .

N_g = banyak tingkat keabuan pada suatu citra.

3. Correlation

Nilai *Correlation* menunjukkan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra. Jika derajat keabuan antar pasangan piksel memiliki hubungan linear maka nilai korelasi akan menjadi tinggi. Rumus fitur *correlation* didefinisikan sebagai berikut,

$$correlation = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (ij) P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.23)$$

keterangan :

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

P_{ij} = entri pada GLCM baris ke- i dan kolom ke- j .

N_g = banyak tingkat keabuan pada suatu citra.

$$\mu_x = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} iP(i, j)$$

$$\mu_y = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} jP(i, j)$$

$$\sigma_x = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu_x)^2 P(i, j)$$

$$\sigma_y = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (j - \mu_y)^2 P(i, j)$$

4. *Inverse Difference Moment (IDM)*

Inverse Difference Moment (IDM) merupakan ukuran homogenitas lokal.

Nilai IDM tinggi ketika tingkat keabuan seragam dan invers GLCM tinggi. Rumus fitur IDM didefinisikan sebagai berikut,

$$IDM = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{P_{ij}}{1+(i-j)^2} \quad (2.24)$$

keterangan :

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

P_{ij} = entri pada GLCM baris ke- i dan kolom ke- j .

N_g = banyak tingkat keabuan pada suatu citra.

5. Entropy

Nilai *entropy* menunjukkan sejumlah informasi dari suatu citra. *Entropy* mengukur informasi atau pesan yang hilang dari sebuah sinyal transmisi dan juga menghitung informasi gambar. Rumus fitur *entropy* didefinisikan sebagai berikut,

$$entropy = - \sum_{i=1}^{N_g} \sum_{l=1}^{N_g} P_{ij} \log(P_{ij}) \quad (2.25)$$

keterangan :

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

P_{ij} = entri pada GLCM baris ke- i dan kolom ke- j .

N_g = banyak tingkat keabuan pada suatu citra.

E. Teori Himpunan *Fuzzy*

1. Himpunan Klasik

Himpunan adalah sekumpulan dari objek-objek yang didefinisikan dengan jelas. Artinya objek-objek tersebut dapat ditentukan dengan jelas keberadaannya. Objek yang termasuk ke dalam himpunan disebut sebagai anggota atau elemen dari himpunan itu (Sukirman, 2006: 116). Secara umum, himpunan disimbolkan dengan huruf kapital (A, B, C, D) dan elemen-elemen dari himpunan disimbolkan dengan alfabet kecil (a, b, c, d). Notasi " $b \in B$ " dibaca "b ialah elemen (anggota) dari himpunan B" dan notasi " $c \notin C$ " dibaca "c bukan elemen (anggota) dari himpunan D".

Pada himpunan klasik (*crisp*) nilai keanggotaan suatu item x dalam suatu himpunan A , yang disimbolkan dengan $\mu_A(x)$ memiliki 2 kemungkinan yaitu $\mu_A(x) = 1$ artinya x anggota himpunan A dan $\mu_B(x) = 0$ artinya x bukan anggota

himpunan B (Kusumadewi, 2003: 156). Himpunan tegas dapat juga dikatakan sebagai fungsi karakteristik (Lin & Lee, 1996: 10).

2. Himpunan *Fuzzy*

Himpunan *fuzzy* pada ruang semesta U didefinisikan sebagai suatu fungsi keanggotaan $\mu_A(x)$ yang memiliki nilai pada interval $[0,1]$. Oleh karena itu, himpunan *fuzzy* merupakan bentuk umum dari himpunan klasik dengan nilai fungsi keanggotaan pada interval $[0,1]$. Dengan kata lain, fungsi keanggotaan pada himpunan klasik memiliki dua nilai 0 dan 1, sedangkan fungsi keanggotaan pada himpunan *fuzzy* adalah fungsi kontinu dengan *range* $[0,1]$ (Wang, 1997: 21-22).

Himpunan *fuzzy* A dalam U dapat direpresentasikan sebagai himpunan pasangan berurutan elemen x dan nilai keanggotaannya, yaitu

$$A = \{(x, \mu_A(x)) | x \in U\} \quad (2.26)$$

dengan $\mu_A(x)$ adalah derajat keanggotaan x di A (Wang, 1997: 22).

3. Fungsi Keanggotaan

Fungsi keanggotaan himpunan *fuzzy* (*membership function*) adalah suatu kurva yang menunjukkan pemetaan titik-titik input data ke dalam nilai keanggotaannya yang memiliki interval antara 0 sampai dengan 1. Salah satu cara yang dapat digunakan untuk mendapat nilai keanggotaan adalah dengan melalui pendekatan fungsi (Kusumadewi, 2003: 160). Ada beberapa fungsi keanggotaan yang dapat digunakan sebagai berikut,


a. Representasi Linier

Pada representasi linier, pemetaan input ke derajat keanggotaannya digambarkan sebagai suatu garis lurus. Bentuk representasi linier merupakan

bentuk yang paling sederhana. Terdapat dua keadaan himpunan *fuzzy* pada representasi linier. Pertama, kenaikan himpunan dimulai pada nilai domain yang memiliki derajat keanggotaan nol (0) dan bergerak ke kanan menuju ke nilai domain yang memiliki derajat keanggotaan yang lebih tinggi.

Fungsi keanggotaan representasi linier naik adalah sebagai berikut,

$$\mu(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & x > b \end{cases} \quad (2.27)$$




Gambar 2.7 Representasi Kurva Linier Naik

Kedua, garis lurus dari nilai domain dengan derajat keanggotaan yang tertinggi pada sisi kiri, kemudian bergerak menurun ke nilai domain yang memiliki derajat keanggotaan yang lebih rendah.

Fungsi keanggotaan representasi linier turun adalah sebagai berikut,

$$\mu(x) = \begin{cases} \frac{b-x}{b-a}, & a \leq x < b \\ 0, & x \geq b \end{cases} \quad (2.28)$$




Gambar 2.8 Representasi Kurva Linier Turun

b. Representasi Kurva Segitiga

Kurva segitiga pada dasarnya merupakan gabungan antara 2 garis (linier).

Representasi kurva segitiga ditunjukkan pada Gambar 2.9.



Gambar 2.9 Representasi Kurva Segitiga

Fungsi keanggotaan kurva segitiga adalah sebagai berikut,


$$\mu(x) = \begin{cases} 0, & x \leq a \text{ atau } x \geq c \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b \leq x < c \end{cases} \quad (2.29)$$

c. Representasi Kurva Trapesium

Kurva trapesium pada dasarnya seperti bentuk kurva segitiga, namun ada beberapa titik yang memiliki nilai keanggotaan 1. Berikut adalah fungsi keanggotaan kurva trapesium.

Fungsi keanggotaan kurva trapesium sebagai berikut,

$$\mu(x) = \begin{cases} 0; & x \leq a \text{ atau } x \geq d \\ \frac{x-a}{b-a}; & a < x < b \\ 1; & b \leq x \leq c \\ \frac{d-x}{d-c}; & c < x < d \end{cases} \quad (2.30)$$



Gambar 2.10 Representasi Kurva Trapesium

4. Operasi Dasar Zadeh

Terdapat beberapa operasi yang didefinisikan secara khusus untuk mengkombinasi dan memodifikasi himpunan *fuzzy*. Nilai keanggotaan sebagai hasil dari operasi dua himpunan sering dikenal dengan nama *fire strength* atau α -predikat. Menurut Zadeh, terdapat tiga operator dasar pada himpunan *fuzzy*, yaitu (Zimmermann, 1996: 16-17):

a. Operator AND

Operator ini berhubungan dengan operasi interaksi pada himpunan. Fungsi keanggotaan $\mu_C(x)$ dari interaksi $C = A \cap B$ didefinisikan sebagai berikut:

$$\mu_C(x) = \min\{\mu_A(x), \mu_B(y)\}, x \in X \quad (2.31)$$

b. Operator OR

Operator ini berhubungan dengan operasi gabungan pada himpunan. Fungsi keanggotaan $\mu_D(x)$ dari gabungan $D = A \cup B$ didefinisikan sebagai berikut:

$$\mu_D(x) = \max\{\mu_A(x), \mu_B(y)\}, x \in X \quad (2.32)$$


c. Operator NOT

Operator ini berhubungan dengan operasi komplemen pada himpunan. Fungsi keanggotaan dari komplemen himpunan *fuzzy* A didefinisikan sebagai berikut:

$$\mu_{\complement A}(x) = 1 - \mu_A(x), x \in X \quad (2.33)$$

F. Jaringan Saraf Tiruan (*Artificial Neural Network*)

Artificial Neural Network (ANN) atau yang biasa dikenal dengan jaringan saraf tiruan adalah suatu sistem pemrosesan informasi yang memiliki karakteristik kinerja tertentu yang sama dengan jaringan saraf biologis yang ditunjukkan pada Gambar 2.11 (Fausett, 1994: 3). Diperkirakan manusia memiliki 10^{12} neuron dan 6×10^8 sinapsis. Dengan jumlah yang begitu banyak, otak mampu mengenali pola, melakukan perhitungan, dan mengontrol organ-organ tubuh dengan kecepatan lebih tinggi (Siang, 2005: 1).




Gambar 2.11 Jaringan Saraf Biologis

Jaringan saraf tiruan telah berkembang menjadi suatu generalisasi model matematika dari jaringan saraf manusia, dengan asumsi bahwa (Fausett, 1994: 3):

1. Pemrosesan informasi terjadi pada banyak elemen sederhana yang disebut dengan neuron.
2. Sinyal dikirimkan diantara neuron-neuron melalui penghubung-penghubung.
3. Tiap penghubung antar neuron memiliki bobot yang dapat memperkuat atau memperlemah sinyal yang dikirimkan.
4. Tiap neuron menggunakan suatu fungsi aktivasi (biasanya fungsi nonlinear) yang dikenakan pada jumlahan input yang diterima untuk menentukan sinyal output.

Jaringan saraf tiruan memiliki karakteristik diantaranya adalah pola hubungan antar neuron atau disebut arsitektur, metode untuk menentukan bobot penghubung atau disebut metode *training*, *learning*, algoritma, dan fungsi aktivasi (Fausett, 1994: 3). Jaringan saraf tiruan sederhana pertama kali diperkenalkan oleh McCulloch dan Pitts di tahun 1943. McCulloch dan Pitts menyimpulkan bahwa

Model jaringan saraf tiruan merupakan model non-linear jaringan saraf tiruan, terdapat suatu bias yang dinotasikan dengan b_k yang ditunjukkan pada Gambar 2.12 (Haykin, 1999: 33). Bias b_k tersebut memiliki pengaruh untuk meningkatkan atau menurunkan jaringan input dari fungsi aktivasi.



Secara matematis, neuron k ditulis berdasarkan hubungan persamaan,

dan


dengan $x_1, x_2, \dots, x_m$ merupakan input, $w_{k1}, w_{k2}, \dots, w_{km}$ merupakan bobot pada tiap penghubung neuron k , dan u_k adalah kombinasi linear antara bobot (w_{km}) dan input (x_m), sedangkan $\varphi(\cdot)$ adalah fungsi aktivasi, dan terakhir y_k merupakan sinyal output dari neuron (Haykin, 1999: 33).

1. Arsitektur Jaringan

Pada umumnya terdapat 3 jenis arsitektur pada jaringan saraf tiruan diantaranya adalah sebagai berikut (Haykin, 1999: 43 – 45):

a. Jaringan Lapisan Tunggal (*Single Layer Network*)


Pada jaringan lapisan tunggal sekumpulan input neuron dihubungkan langsung dengan sekumpulan output. Selain itu, pada jaringan lapisan tunggal semua unit input dihubungkan dengan semua unit output dengan bobot yang berbeda-beda. Namun, pada unit input tidak terhubung dengan unit input lainnya dan sebaliknya yaitu pada unit output juga tidak terhubung dengan unit output lainnya. Dengan kata lain, jaringan lapisan tunggal disebut jaringan *feedforward* atau *acyclic*. Sebagai ilustrasi pada Gambar 2.13 merupakan arsitektur jaringan lapisan tunggal dengan 4 neuron pada lapisan input dan 2 neuron pada lapisan output dengan bobot-bobot yang menghubungkan lapisan input dan output.



Gambar 2.13 Arsitektur Jaringan Lapisan Tunggal

b. Jaringan Lapisan Jamak (*Multi Layer Network*)

Jaringan lapisan jamak merupakan suatu jaringan dengan satu atau lebih jaringan dimana terdapat penambahan lapisan yaitu lapisan tersembunyi. Lapisan tersembunyi terletak diantara lapisan input dan lapisan output. Dimungkinkan pula terdapat beberapa lapisan tersembunyi. Semua unit dalam satu lapisan tidak saling terhubung. Jaringan lapisan jamak dapat menyelesaikan beberapa permasalahan yang lebih kompleks dibanding jaringan lapisan tunggal, tetapi proses pelatihan jaringan terkadang lebih sulit dan memakan waktu lama. Sebagai ilustrasi pada Gambar 2.14 merupakan arsitektur jaringan lapisan jamak dengan 4 neuron pada lapisan input, 3 neuron pada lapisan tersembunyi dan 2 neuron pada lapisan output.



Gambar 2.14 Arsitektur Jaringan Lapisan Jamak

2. Fungsi Aktivasi

Pada jaringan saraf tiruan, fungsi aktivasi digunakan untuk menentukan keluaran suatu neuron. Jika *net* merupakan kombinasi linear antara input dan bobot

($net = \sum_{j=1}^m w_{kj}x_j$), maka fungsi aktivasinya adalah $f(net) = f(\sum_{j=1}^m w_{kj}x_j)$

(Siang, 2005: 26). Pada beberapa kasus, fungsi aktivasi nonlinear dapat digunakan.

Berikut ini adalah fungsi aktivasi yang umum digunakan pada jaringan saraf tiruan (Fausett, 1994: 17-19):

a. Fungsi Linier

Fungsi linier sering dipakai apabila menginginkan output jaringan berupa sembarang bilangan riil. Pada fungsi identitas, nilai output yang dihasilkan sama dengan nilai input.


Fungsi linier dirumuskan sebagai berikut:

$$f(x) = ax + b, x \in R \quad (2.36)$$

Fungsi identitas merupakan fungsi *linier* dengan nilai $a = 1$ dan $b = 0$.

Fungsi identitas dirumuskan sebagai berikut:

$$f(x) = x, x \in R \quad (2.37)$$




Gambar 2.15 Fungsi Identitas

b. Fungsi Tangga Biner (dengan *threshold* θ)

Pada jaringan lapisan tunggal sering menggunakan fungsi tangga biner untuk mengkonversi input dari variabel yang bernilai kontinu ke suatu output yang biner

(0 dan 1). Fungsi tangga biner biasa disebut dengan *threshol function* atau *heaviside function*. Fungsi tangga biner dirumuskan sebagai berikut:

$$f(x) = \begin{cases} 0 & ; \text{jika } x < \theta \\ 1 & ; \text{jika } x \geq \theta \end{cases} \quad (2.38)$$



Gambar 2.16 Fungsi Tangga Biner


c. Fungsi Sigmoid Biner

Fungsi sigmoid biner memiliki daerah hasil dengan interval 0 sampai 1. Fungsi sigmoid biner sering digunakan pada jaringan saraf tiruan sebagai fungsi aktivasi dimana nilai dari outputnya berupa biner atau interval antara 0 dan 1. Kurva fungsi sigmoid biner ditunjukkan pada Gambar 2.17. Fungsi ini sering disebut juga dengan *logistic sigmoid function*. Fungsi sigmoid biner dirumuskan sebagai berikut:

$$f(x) = \frac{1}{1 + \exp(-\sigma x)}, x \in R \quad (2.39)$$

dengan turunan pertama fungsi pada Persamaan (2.39) adalah:

$$f'(x) = \frac{\sigma \exp(-\sigma x)}{[\exp(-\sigma x) + 1]^2} \quad (2.40)$$



Gambar 2.17 Fungsi Sigmoid Biner


d. Fungsi Sigmoid Bipolar

Fungsi Sigmoid Bipolar hampir sama dengan fungsi sigmoid biner dimana pada fungsi sigmoid bipolar memiliki daerah hasil antara -1 sampai 1. Kurva fungsi sigmoid bipolar ditunjukkan pada Gambar 2.18. Fungsi sigmoid bipolar dirumuskan sebagai berikut:

$$f(x) = \frac{1 - \exp(-\sigma x)}{1 + \exp(-\sigma x)}, x \in R \quad (2.41)$$

dengan turunan pertama fungsi pada Persamaan (2.41) adalah :

$$f'(x) = \frac{\sigma \exp(-\sigma x)}{\exp(-\sigma x) + 1} - \frac{\sigma \exp(-\sigma x) [\exp(-\sigma x) - 1]}{[\exp(-\sigma x) + 1]^2} \quad (2.42)$$



Gambar 2.18 Fungsi Sigmoid Bipolar

3. Algoritma Pembelajaran (*Learning Algorithm*)

Jaringan saraf tiruan tersusun atas neuron-neuron dan dendrit. Tidak seperti model biologis, jaringan saraf tiruan memiliki struktur yang tidak dapat diubah, dibangun oleh sejumlah neuron dan memiliki nilai tertentu yang menunjukkan seberapa besar koneksi antar neuron (yang dikenal dengan nama bobot). Tujuan utama dari proses pembelajaran yaitu melakukan pengaturan bobot-bobot yang ada dalam jaringan saraf tiruan, sehingga diperoleh bobot akhir yang tepat dan sesuai dengan pola data yang dilatih. Terdapat 2 metode pembelajaran pada jaringan saraf tiruan yaitu (Kusumadewi, 2003: 220):

a. Pembelajaran Terawasi (*supervised learning*)

Metode pembelajaran pada jaringan saraf tiruan disebut terawasi jika output yang diharapkan telah ditentukan atau disebut juga sebagai target output. Pada proses pembelajaran, satu pola input akan diberikan ke satu neuron pada lapisan input. Pola ini akan dirambatkan di sepanjang jaringan saraf tiruan hingga sampai ke neuron pada lapisan output. Lapisan output ini akan membangkitkan pola output yang nantinya akan dicocokkan dengan pola output target. Selisih antara pola output hasil pembelajaran dengan pola target disebut dengan *error*.

b. Pembelajaran Tak Terawasi (*unsupervised learning*)

Pada metode pembelajaran yang tak terawasi ini tidak memerlukan target output. Pada metode ini, tidak dapat ditentukan hasil yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu *range* tertentu tergantung pada nilai input yang diberikan. Pembelajaran tak terawasi sangat cocok untuk pengelompokkan atau klasifikasi pola.

G. Ketepatan Hasil Diagnosa

Pengujian ketepatan hasil diagnosa dilakukan untuk menguji sejauh mana model memberikan ketepatan hasil diagnosa. Untuk menghitung ketepatan hasil diagnosa digunakan tiga ukuran statistik. Tiga ukuran statistik tersebut adalah sensitivitas, spesifisitas, dan akurasi (Zhu, Zeng & Wang, 2010: 1). Hasil kemungkinan yang dapat terjadi dalam hasil uji diagnosa tersaji pada Tabel 2.1 di bawah ini:

Tabel 2.1 Hasil Uji Diagnosa 2 Kategori

Hasil Uji Diagnosa	Kondisi Penyakit sebagaimana yang ditetapkan oleh Standar Kebenaran		
	Positif	Negatif	Jumlah Baris
Positif	TP	FP	$TP + FP$
Negatif	FN	TN	$FN + TN$
Jumlah Kolom	$TP + FN$	$FP + TN$	$N = TP + FN + FP + FN$

dengan,

TP (*True Positive*) : subjek yang memiliki penyakit dan hasil diagnosa menyatakan subjek memiliki penyakit.

FP (*False Positive*) : subjek yang tidak memiliki penyakit namun hasil diagnosa menyatakan subjek memiliki penyakit.

TN (*True Negative*) : subjek yang tidak memiliki penyakit dan hasil diagnosa menyatakan subjek tidak memiliki penyakit.

FN (*False Negative*) : subjek yang memiliki penyakit namun hasil diagnosa menyatakan subjek tidak memiliki penyakit.

Sensitivitas menyatakan proporsi subjek yang terindikasi positif berdasarkan hasil pengujian dalam jumlah keseluruhan subjek yang memiliki penyakit. Dengan

kata lain, sensitivitas adalah peluang mendapatkan hasil positif pada subjek yang memiliki penyakit (Simundic, 2003: 3). Rumus sensitivitas adalah sebagai berikut:

$$Sensitivitas = \frac{TP}{TP+FN} \times 100\% \quad (2.43)$$

Spesifisitas menyatakan proporsi subjek yang terindikasi negatif berdasarkan hasil pengujian dalam jumlah keseluruhan subjek yang tidak memiliki penyakit. Dengan kata lain, spesifisitas adalah peluang mendapatkan hasil negatif pada subjek yang tidak memiliki penyakit (Simundic, 2003: 4). Rumus spesifisitas adalah sebagai berikut:

$$Spesifisitas = \frac{TN}{TN+FP} \times 100\% \quad (2.44)$$

Akurasi adalah proporsi dari kebenaran hasil dimana hasil positif dan hasil negatif dalam populasi. Rumus akurasi adalah sebagai berikut:

$$Akurasi = \frac{TN+TP}{N} \times 100\% \quad (2.45)$$