

PENGENALAN POLA BERBASIS JARINGAN SYARAF TIRUAN DALAM ANALISA CT SCAN TUMOR OTAK BELIGNA

Mike Susmikanti

Pusat Pengembangan Informatika Nuklir – BATAN
Kawasan PUSPIPTEK, Gd. 71, Serpong, Tangerang
Email : mike@batan.go.id

ABSTRAKS

Dalam pemahaman hasil analisis CT Scan tumor otak masih sulit mengidentifikasi jenis tumor otak. Klasifikasi jenis tumor otak dari segi klinis dibedakan menjadi primary brain tumor dan metastatic brain tumor. Secara klinis sukar membedakan antara tumor otak benigna maupun maligna, karena gejala yang timbul ditentukan pula oleh lokasi tumor, kecepatan tumbuhnya dan efek masa tumor ke jaringan otak. Gambaran CT Scan tumor otak benigna meliputi Meningioma, Adenoma Pituitari, Kraniosaringioma, Pilocytic Astrocytoma dan Akustik Neurinoma. Dengan menggunakan Artificial Neural Network (AAN) diharapkan dapat membantu para medis dibidangnya untuk mengidentifikasi jenis tumor otak. Telah dilakukan identifikasi pola berbasis jaringan syaraf tiruan terhadap jenis tumor melalui hasil pola citra menggunakan CT Scan maupun MRI. Selanjutnya citra dari hasil CT Scan ataupun MRI dikonversi kedalam bentuk digital standard menggunakan teknik pengolahan citra. Hasil konversi digital, menggunakan PCA menghasilkan karakteristik dominan sehingga mewakili pola citra tersebut. Karakteristik dominan ini digunakan pada jaringan syaraf tiruan, untuk tahap pembelajaran, pelatihan dan pengujian atau simulasi. Dalam identifikasi pola, pada tahap pembelajaran dengan pengawasan digunakan metode perceptron. Jenis tumor otak terhadap hasil CT Scan maupun MRI diklasifikasikan sesuai dengan kode masukan. Sampel untuk keperluan pembelajaran, pelatihan dan simulasi menggunakan basis data hasil CT Scan ataupun MRI. Sistem perangkat lunak untuk pengenalan pola jenis tumor otak dikembangkan menggunakan MATLAB. Diperoleh perangkat lunak yang dapat mengidentifikasi pola jenis tumor otak jinak.

Kata kunci: Jaringan Syaraf Tiruan, Pengenalan Pola, Tumor Otak, CT Scan

1. PENDAHULUAN

Dalam bidang medis masih terdapat mengidentifikasi jenis tumor otak melalui hasil analisis CT (Computerized Tomografi) Scan maupun MRI (Magnetic Resonance Imaging). Klasifikasi tumor otak yang penting dari segi klinis dibedakan menjadi primary brain tumor dan metastatic brain tumor dapat pula disebut tumor jinak (benigna) dan tumor ganas (maligna). Secara klinis sukar membedakan antara tumor otak yang jinak atau yang ganas, karena gejala yang timbul ditentukan pula oleh lokasi tumor, kecepatan tumbuhnya dan efek masa tumor ke jaringan otak. Gambaran CT Scan tumor otak jinak meliputi Meningioma, Adenoma Pituitari, Kraniosaringioma, Pilocytic Astrocytoma dan Akustik Neurinoma. Dengan pemeriksaan radiologi dan patologi anatomi hampir pasti dapat dibedakan tumor benigna dan maligna^[5].

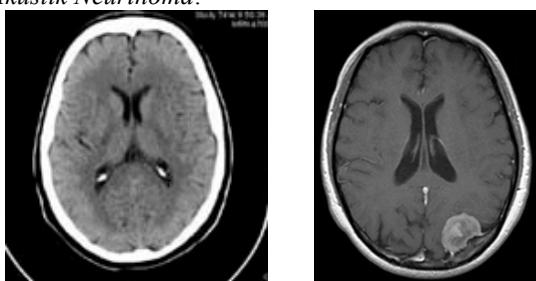
Sistem pengenalan pola berbasis jaringan syaraf tiruan terhadap hasil CT Scan maupun MRI, dengan menggunakan teknik pengolahan citra, dikonversi kedalam bentuk digital sehingga dapat diproses menggunakan Principle Component Analysis (PCA) yang menghasilkan karakteristik paling dominan sehingga mewakili struktur pola citra tersebut^[1, 12].

Karakteristik dominan ini digunakan pada jaringan syaraf tiruan, untuk tahap pembelajaran, pelatihan dan pengujian. Identifikasi pola, pada tahap pembelajaran dengan pengawasan menggunakan metode perceptron, dikarenakan lebih sesuai untuk identifikasi pola dikarenakan terdapat pemisahan secara linier dalam rancangan input untuk identifikasi dan lebih cepat mencapai konvergenitas dalam iterasi pelatihan dan simulasi dibandingkan metoda back propagation^[13]. Pada jaringan syaraf tiruan, jenis tumor benigna diklasifikasikan sesuai dengan kode masukan. Sampel citra untuk keperluan pembelajaran jenis tumor benigna, pelatihan dan simulasi menggunakan data hasil CT Scan dan data pustaka. Diperlukan rancangan input sebagai pembelajaran untuk identifikasi pola jenis tumor jinak. Jenis tumor otak terhadap hasil CT Scan maupun MRI diklasifikasikan sesuai dengan kode masukan. Sistem perangkat lunak untuk pengenalan pola jenis tumor otak jinak dikembangkan menggunakan MATLAB. Diperoleh perangkat lunak yang dapat mengidentifikasi pola jenis tumor otak benigna.

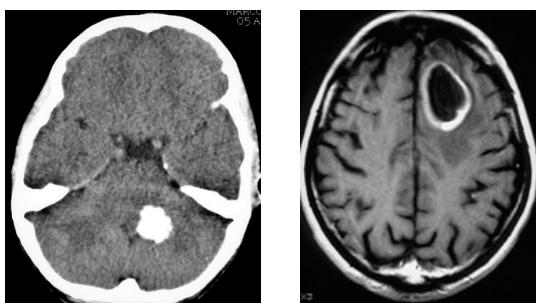
2. METODOLOGI

2.1 Tumor Otak

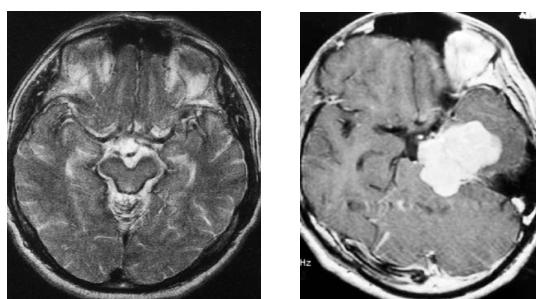
Klasifikasi tumor otak yang penting dari segi klinis dibedakan menjadi *primary brain tumor* dan *metastatic brain tumor* dapat pula disebut tumor *benigna* (jinak) dan tumor *maligna* (ganas). Tumor adalah pertumbuhan tidak normal dalam tubuh, terdiri dari sel-sel ekstra. Umumnya sel lama mati, dan yang baru mengambil tempat pada sel lama. Kadang-kadang, proses ini berlangsung tidak sesuai sehingga sel-sel baru terbentuk dan sel-sel tua tidak mati. Tumor jinak hanya tumbuh di satu tempat, tidak dapat menyebar atau menyerang bagian tubuh lain. Meskipun demikian, bisa berbahaya jika menekan pada organ vital, seperti otak [5]. Gambar 1(a) dan 1(b) menunjukkan hasil *CT Scan* otak normal dan tumor otak *jinak* jenis *Meningioma*. Sedangkan pada Gambar 2(a) dan 2(b), menunjukkan hasil *CT Scan* tumor otak *jinak* jenis *Adenoma Pituitari* dan *Kranifaringioma*. Gambar 3 (a) dan 3(b) menampilkan hasil *CT Scan* tumor otak *jinak* jenis *Pilocytic Astrocytoma* dan *Akustik Neurinoma*.



Gambar 1. Hasil CT Scan Tumor Otak
(a) Normal (b) *Meningioma*



Gambar 2. Hasil CT Scan Tumor Otak
(a) *Adenoma Pituitari* (b) *Kranifaringioma*

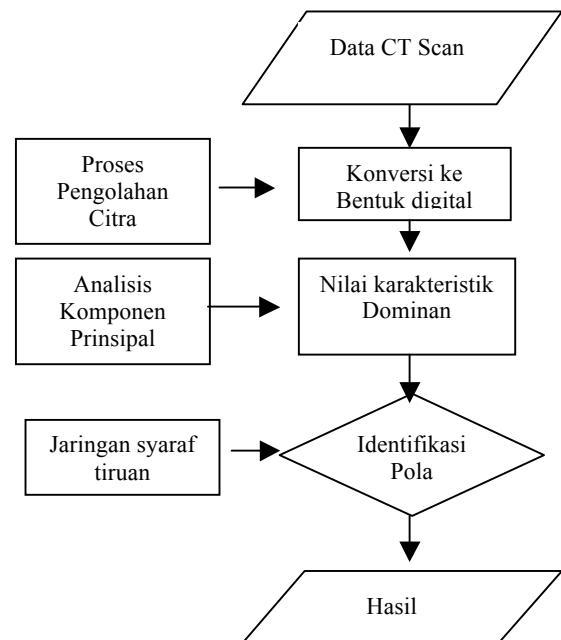


Gambar 3. Hasil CT Scan Tumor Otak
(a) *Pilocytic Astrocytoma* (b) *Akustik Neurinoma*

2.2 Sistem Pengenalan Pola

Dalam sistem pengenalan pola jenis tumor otak jinak, digunakan alat *CT Scan* atau *MRI* untuk menganalisis rincian bentuk tomografi yang dengan kasat mata tidak mampu diamati. Pengenalan pola jenis tumor otak jinak meliputi tahapan proses pengolahan citra, analisis komponen prinsipal dan jaringan syaraf tiruan^[1]. Dalam tahap pertama dengan proses pengolahan citra dilakukan konversi dari file hasil *CT Scan* kedalam bentuk file data matriks dengan unsur tingkat keabuan^[2]. Tahap kedua dengan analisis komponen prinsipal, dilakukan penentuan karakteristik pola, melalui perhitungan *eigen value* dan *eigen vector* terhadap matriks kovarian. Dalam hal ini diambil enam nilai karakteristik yang paling dominan dengan urutan nilai peluang terbesar^[3]. Tahap ketiga, pada identifikasi pola mikrostruktur bahan digunakan konsep jaringan syaraf tiruan dengan metode perceptron. Metoda *perceptron* dalam kasus ini lebih sesuai dibandingkan metoda *backpropagation*, walaupun metoda *perceptron* lebih sederhana dalam perancangan inputnya, akan tetapi lebih cepat mencapai nilai konvergenitas, baik dalam iterasi pembelajaran, pelatihan maupun simulasi^[6]. Dalam tahapan pembelajaran dan pelatihan diambil beberapa contoh hasil pengujian. Diperlukan rancangan input sebagai pembelajaran dan pelatihan untuk identifikasi pola.

Pada Gambar 4, diberikan sistem diagram alur proses pengenalan pola^[4].



Gambar 4. Sistem diagram alur untuk pengenalan pola

2.3 Proses Pengolahan Citra

Suatu pola mempunyai tekstur khusus, dengan berbagai variasi tingkat-keabuan atau warna yang digambarkan dalam bentuk piksel-piksel. Matriks tingkat-keabuan mengandung informasi tentang

gabungan posisi piksel-piksel dari tekstur. Posisi piksel dinyatakan dengan nilai jarak d . Nilai gabungan tersebut sama seperti nilai tingkat keabuan. Unsur-unsur pada matriks tingkat-keabuan digunakan untuk melihat karakteristik tekstur^[1]. Selain hal tersebut, arah diantara dua piksel juga perlu diperhatikan. Dasar analisis untuk tekstur dalam bentuk citra tingkat-keabuan menggunakan beberapa ukuran statistik rata-rata tingkat keabuan dan simpangan baku yang dinyatakan sebagai momen^[10]. Rata-rata dihubungkan dengan momen pertama, simpangan baku tergantung pada momen kedua. Secara umum momen dinyatakan pada persamaan (1) berikut,

$$M_n = \frac{\sum (x - \bar{x})^n}{N} \quad (1)$$

N adalah jumlah titik-titik data, dan n adalah urutan momen. Momen digunakan untuk menghitung statistik terhadap *window*/jendela dan nilai piksel pada pusat jendela dan sekitarnya. Ukuran lain yang diperlukan adalah order atau urutan selisih momen. Order selisih momen unsur k di definisikan pada persamaan (2) berikut,

$$Momen_k = \sum_i \sum_j (i - j)^k M[i, j] \quad (2)$$

$M[i, j]$ adalah matriks tingkat-keabuan yang mengandung informasi mengenai posisi piksel-piksel yang dinyatakan dengan nilai jarak (d). Setiap nilai d , dengan empat faktor arah citra, yang masing-masing mempunyai ukuran tingkat-keabuan maksimal 256×256 (*colour bitmap*), membentuk citra gabungan dalam bentuk matriks dengan 256 tingkat-keabuan sehingga secara keseluruhan menghasilkan konversi dari struktur citra menjadi bentuk digital^[11].

2.4 Analisis Komponen Prinsipal

Principle Component Analysis (PCA) adalah teknik statistik untuk menyederhanakan kumpulan data banyak-dimensi menjadi dimensi yang lebih rendah (*extraction feature*)^[4, 12]. *PCA* merupakan transformasi linier ortogonal yang mentransformasi data ke sistem koordinat baru, sehingga keragaman terbesar dengan suatu proyeksi berada pada koordinat pertama (disebut prinsipal komponen pertama), keragaman terbesar kedua berada pada koordinat kedua dan seterusnya. Konsep penggunaan *PCA* meliputi perhitungan nilai-nilai simpangan baku, matriks kovarian, nilai karakteristik (*eigen value*) dan vektor karakteristik (*eigen vector*). *PCA* dapat menggunakan metoda kovariansi atau korelasi^[3, 4]. Jika diperlukan, data distandardisasi terlebih dahulu sehingga menghampiri sebaran normal baku. Dalam hal ini digunakan metoda kovariansi dengan algoritma berikut, Mengumpulkan data dalam bentuk matrix

tingkat-keabuan X berukuran $M \times N$. Misalkan

x_1, x_2, \dots, x_M adalah vektor $N \times 1$:

- (i) Menghitung rata-rata: $\bar{x} = \frac{1}{M} \sum_{i=1}^M x_i$
- (ii) Menghitung selisih *rata-rata*: $\Phi_i = x_i - \bar{x}$
- (iii) Menentukan matriks kovarian
Dari matriks $X = [\Phi_1 \Phi_2 \dots \Phi_M]$ (matriks $N \times M$),
Hitung *kovarian*: $C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = X X^T$
- (iv) Menentukan nilai karakteristik dan vektor karakteristik dari matriks kovarian
 $C : \lambda_1 > \lambda_2 > \dots > \lambda_N$ dan $C : u_1, u_2, \dots, u_n$
- (v) Mengurutkan vektor karakteristik u dan nilai karakteristik λ dalam matriks diagonal dalam urutan menurun sesuai dengan nilai peluang kumulatif terbesar untuk tiap vektor karakteristik sehingga diperoleh nilai-nilai karakteristik yang dominan.

2.5 Sistem Jaringan Syaraf Tiruan

Pemodelan berbasis jaringan syaraf tiruan merupakan pembelajaran dan adaptasi suatu obyek. Terdapat beberapa metode dalam pembelajaran dengan pengawasan pada jaringan syaraf tiruan diantaranya metode *perceptron* dan metode *back propagation*. Metode *perceptron* adalah metode pembelajaran dengan pengawasan dalam jaringan syaraf tiruan, sehingga jaringan yang dihasilkan harus mempunyai parameter yang dapat diatur dengan cara mengubah melalui aturan pembelajaran dengan pengawasan. *Perceptron* merupakan bentuk jaringan sederhana dan digunakan untuk mengklasifikasikan pola tipe tertentu yang dikenal dengan pemisahan secara linier^[7, 9].

Jaringan syaraf tiruan terdiri dari sejumlah *neuron*. Dalam merancang jaringan syaraf tiruan perlu diperhatikan banyaknya spesifikasi yang akan diidentifikasi. Penggunaan metoda *perceptron* untuk aplikasi pengenalan pola digambarkan sebagai unsur matrik antara 0 dan 1. *Layer* pertama *perceptron* menyatakan suatu kumpulan "detektor tanda" sebagai isyarat input untuk mengetahui tanda khusus. *Layer* kedua mengambil output dari tanda khusus dalam *layer* pertama dan mengklasifikasikan pola data yang diberikan. Pembelajaran dinyatakan dengan membuat aturan hubungan yang relevan (bobot w_i) dengan suatu nilai ambang (θ) atau *threshold*. Untuk persoalan dua-kelas, *layer output* hanya mempunyai satu simpul. Untuk persoalan n -kelas dengan $n \geq 3$, *layer output* mempunyai n simpul, yang masing-masing berkorespondensi terhadap suatu kelas, dan simpul *output* dengan nilai terbesar mengindikasi kelas mana vektor input termasuk di dalamnya. Fungsi g_i dalam *layer-1* adalah konstan, dan memetakan semua atau sebagian pola input ke dalam nilai biner $x_i \in \{-1, 1\}$ atau nilai bipolar $x_i \in \{0, 1\}$. Apabila data direpresentasikan

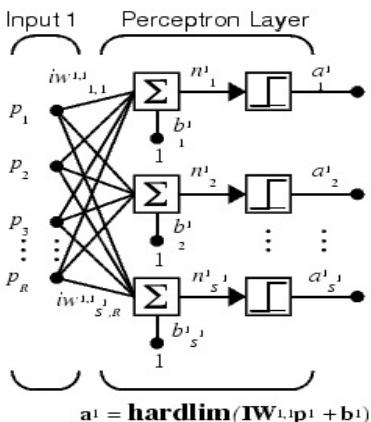
secara bipolar, maka perbaikan bobotnya dinyatakan pada persamaan (3)^[8],

$$w_i(\text{baru}) = w_i(\text{lama}) + t \cdot x_i \quad (3)$$

w_i : bobot yang dapat dimodifikasi sehubungan kedatangan isyarat x_i , dan $w_0 (= -\theta)$ merupakan pendekatan awal. Fungsi $f(.)$ adalah fungsi *aktivasi perceptron* dan khusus berlaku untuk suatu fungsi *signum sgn(x)* atau fungsi *step step(x)*^[6], yang dinyatakan pada persamaan (4) dibawah ini

$$\begin{aligned} \text{sgn}(x) &= 1 \quad \text{jika } x > 0 \\ &= -1 \quad \text{jika lainnya} \\ \text{step}(x) &= 1 \quad \text{jika } x > 0 \\ &= 0 \quad \text{jika lainnya} \end{aligned} \quad (4)$$

algoritma pembelajaran *perceptron layer* tunggal diulangi mengikuti tahapan memilih suatu vektor input x dari kumpulan data pelatihan. Jika *perceptron* memberikan jawaban salah, modifikasi semua bobot terhubung w_i sampai bobot konvergen ($\Delta w_i = t \cdot x_i$; t : target output). Arsitektur jaringan syaraf tiruan terdiri dari s neuron dan r masukan dapat dinyatakan dalam Gambar 5^[3]:



Gambar 5. Contoh arsitektur *neural network* dengan s neuron dan r masukan

3. HASIL DAN PEMBAHASAN

Telah dilakukan tahapan proses pengenalan pola untuk klasifikasi jenis tumor otak yang meliputi proses pengolahan citra, analisis komponen prinsipal serta identifikasi. Setiap kegiatan dari proses pengenalan pola tersebut di atas masing-masing dilakukan sesuai dengan sistem diagram alir terhadap proses pengenalan pola pada Gambar 4. Diperoleh hasil identifikasi pola untuk jenis tumor jinak. Dalam pengujian jenis tumor jinak dianalisis beberapa contoh hasil *CT Scan* dengan proses pengolahan citra dan *PCA* yang diberikan prosedurnya pada lampiran A.1. Tahap pertama, citra dalam file elektronik, dikonversi dengan proses pengolahan citra menjadi bentuk digital. Pada tahap kedua, setelah diperoleh matriks tingkat keabuan, dibentuk matriks kovarian dengan instruksi menghitung matriks kovarian dan berikutnya dengan analisis *PCA* diperoleh hasil enam nilai karakteristik

yang dominan. Tahap pertama dan kedua dilakukan masing-masing untuk data pembelajaran, data pelatihan dan data simulasi yang masing-masing diproses sesuai prosedur pada lampiran A. Tahap ketiga dilakukan identifikasi menggunakan proses jaringan syaraf tiruan sesuai prosedur yang diberikan pada lampiran B yang meliputi proses pembelajaran yang terdiri atas enam contoh input, terdiri dari satu contoh *masukan CT Scan* otak normal dan lima contoh *masukan CT Scan* jenis tumor jinak. Proses pelatihan diambil satu contoh *masukan CT Scan* otak normal dan lima contoh *masukan CT Scan* jenis tumor jinak. Selanjutnya proses simulasi pertama diambil satu contoh *masukan CT Scan* otak normal dan lima contoh *masukan CT Scan* jenis tumor jinak. Berikutnya pada proses simulasi kedua diambil satu contoh diambil satu contoh *masukan CT Scan* otak normal dan lima contoh *masukan CT Scan* jenis tumor jinak. Sedangkan pada proses simulasi ketiga diambil satu contoh *masukan CT Scan* otak normal dan lima contoh *masukan CT Scan* jenis tumor jinak.

Program dan hasil diberikan pada lampiran B dengan kode 100000 untuk jenis otak normal, kode 010000 untuk jenis tumor otak jinak *Meningioma*, kode 001000 untuk *jenis tumor Adenoma Pituitari*, kode 000100 untuk *jenis tumor Kraniosaringioma*, kode 111110 untuk *jenis tumor Pilocytic Astrocytoma* dan kode 000001 untuk *jenis tumor Akustik Neurinoma*. Hasil identifikasi diberikan untuk 120 sampel. Secara keseluruhan keberhasilan identifikasi diberikan dalam Tabel 1 berikut ini,

Tabel 1 : Hasil Identifikasi

Hasil CT Scan	Jumlah benar	Jumlah salah	% ketelitian
Normal	20	0	100%
<i>Meningioma</i>	19	1	95%
<i>Adenoma Pituitari</i>	17	3	85%
<i>Kraniosaringioma</i>	19	1	95%
<i>Pilocytic Astrocytoma</i>	20	0	100%
<i>Akustik Neurinoma</i>	20	0	100%

4. KESIMPULAN

Dengan proses pengenalan pola, hasil *CT Scan* jenis tumor jinak dapat dinyatakan dan dikonversi dalam bentuk digital dengan teknik pengolahan citra. Analisis komponen prinsipal dapat menentukan nilai karakteristik yang dominan dari pola jenis tumor jinak yang dapat digunakan untuk identifikasi pada jaringan syaraf tiruan. Pemodelan untuk membedakan klasifikasi jenis tumor jinak dapat menggunakan jaringan syaraf tiruan. Metoda perceptron dalam jaringan syaraf tiruan merupakan pembelajaran dan adaptasi suatu obyek yang cukup baik serta sesuai untuk pemodelan identifikasi jenis tumor. Diperoleh pengembangan perangkat lunak untuk identifikasi jenis tumor berbasis jaringan syaraf tiruan.

PUSTAKA

- [1] Ariyanto, Gunawan,; cs, (2007) "Hand Gesture Recognition Using Neural Network for Robotic Arm Control", Proceedings of National Conference on Computer Science & Information Technology page 412, Faculty of Computer Science, University of Indonesia, Jakarta
- [2] Frucci, M; Sanniti G., (2008) "From Segmentation to Binarization of Gray-level Images" Institute of Cybernetics "E.Caianiello", CNR Via Campi Flegrei 34, Pozzuoli, Naples, 80078, Italy, Journal of Pattern Recognition Research 1, 1-13
- [3] Hanselman, D.; Littlefield, B., (1998) "Mastering MATLAB 5, A Comprehensive Tutorial and Reference", Prentice-Hall Inc.
- [4] Ronald Scrofano, Myungsook Klassen, (2001) "Pattern Recognition with Feedforward, Artificial Neural Networks", California LutheranUniversity,diakses 18 Desember 2009, <http://halcyon.usc.edu/~rscrofan/capstone.pdf>
- [5] Japardi, Iskandar Dr., (2002) "Gambaran CT Scan pada Tumor Otak Benigna", Fakultas Kedokteran Bagian Bedah, Universitas Sumatera Utara, Digitized by USU digital library
- [6] Kosko, Bart, (1992). "Neural Networks and Fuzzy Systems, A Dynamical Systems Approach to Machine Intelligence", Prentice-Hall International Editions
- [7] Kumar, Satish, (2004) "Neural Networks", Mc Graw-Hill, New Delhi
- [8] Kuswadi, Son, (2007) "Kendali Cerdas, Teori dan Aplikasi Praktisnya", Penerbit ANDI, Yogyakarta
- [9] Mattiussi, C.; Marbach, N. (2008), "The Age of Analog Networks", Artificial Intelligence Magazine, Vol 29, number 3
- [10] Parker J.R., (1997) "Algorithms for Image Processing and Computer Vision", Wiley Computer Publishing, John Wiley & Sons, Inc.
- [11] Pearson, Don, (1991) "Image Processing", McGraw-Hill International Editions
- [12] Susmikanti, Mike, (2001) "Penyederhanaan Pemetaan Struktur Ketergantungan Variabel Menggunakan Teknik Prinsipal Komponen", Prosiding Lokakarya Komputasi dalam Sains dan Teknologi Nuklir XII, BATAN, Jakarta.
- [13] Susmikanti, M; Entin H; Dinan A, (2009) "Identifikasi Pengenalan Pola Osteoporosis terhadap Hasil Rontgen Jari Tangan dan Tulang Belakang", Seminar SRITI, STMIK AKAKOM, Yogyakarta

Lampiran A. Program konversi citra dan karakteristik dominan satu citra jenis tumor otak

```
clear;clc;
fb=fopen('normal_1.m','w');
```

```
X=imread('normal_1.bmp');
DX=double(X);
COVDX=cov(DX);
fprintf(fb,' \n Eigen Value S \n');
EIGDX=eigs(COVDX);
fprintf(fb,'%9.2f\n',EIGDX);
[VS,DS,FLAG]=eigs(COVDX);
fprintf(fb,' \n VS \n');
fprintf(fb,'%9.2f',VS);
fprintf(fb,' \n DS \n');
fprintf(fb,'%9.2f %9.2f %9.2f %9.2f
%9.2f %9.2f\n',DS);
fprintf(fb,' \n Flag \n');
fprintf(fb,'%9.2f\n',FLAG);
SVDS=svds(COVDX);
fprintf(fb,' \n SVDS : \n');
fprintf(fb,'%9.2f\n',SVDS);
fprintf(fb,' \n Principal componen from covariance : ');
[PC,LATENT,EXPLAINED]=pcacov(COVDX);
fprintf(fb,' \n LATENT \n');
fprintf(fb,'%9.2f\n',LATENT);
fprintf(fb,' \n Explained \n');
fprintf(fb,'%9.2f\n',EXPLAINED);
fclose(fb);
Hasil :
Eigen Value S
2127.83 920.43 604.79 417.82 208.53 120.96
DS
2127.83 0.00 0.00 0.00 0.00 0.00
0.00 920.43 0.00 0.00 0.00 0.00
0.00 0.00 604.79 0.00 0.00 0.00
0.00 0.00 0.00 417.82 0.00 0.00
0.00 0.00 0.00 0.00 208.53 0.00
0.00 0.00 0.00 0.00 0.00 120.96
SVDS :
2127.83 920.43 604.79 417.82 208.53 120.96
Principal componen from covariance :
LATENT
2127.83
920.43
604.79
417.82
208.53
120.96
```

Lampiran B. Program identifikasi jenis tumor otak dan Hasil

```
clear;clc;
fb=fopen('out_tumor_brain_5.txt','w');
% A. Tahap pembelajaran jaringan
% Jenis Tumor & Normal
% A.1 Deklarasi dan Inisialisasi jaringan
neuron
net1=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net2=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net3=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net4=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net5=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net6=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
w1=net1.IW{1,1,1,1,1,1};
w2=net2.IW{1,1,1,1,1,1};
w3=net3.IW{1,1,1,1,1,1};
w4=net4.IW{1,1,1,1,1,1};
w5=net5.IW{1,1,1,1,1,1};
w6=net6.IW{1,1,1,1,1,1};
b1=net1.b{1}; b2=net2.b{1};
b3=net3.b{1}; b4=net4.b{1};
b5=net5.b{1}; b6=net6.b{1};
% A.2 Deklarasi matriks karakteristik
p=[1647.95 745.96 518.89 366.80 267.63
221.17;%Normal
```

```

        408.90 214.43 172.87 115.95 114.54
68.10;%Meningioma
        1138.85 573.77 483.90 289.61 196.72
141.93;%Adenoma H
        602.44 273.63 207.60 178.07 165.47
110.93;%Kraniofaringioma
        978.46 451.62 341.68 278.27 207.82
184.45;%Pilocytic A
        778.98 515.95 338.25 187.57 153.40
147.24];%Akustik N
    pTotal1=p';
% A.3 Deklarasi Target
t1 = [1 0 0 0 0 0];
t2 = [0 1 0 0 0 0];
t3 = [0 0 1 0 0 0];
t4 = [0 0 0 1 0 0];
t5 = [1 1 1 1 1 0];
t6 = [0 0 0 0 0 1];
% A.4 Proses Pembelajaran
net1=train(net1,pTotal,t1);
net2=train(net2,pTotal,t2);
net3=train(net3,pTotal,t3);
net4=train(net4,pTotal,t4);
net5=train(net5,pTotal,t5);
net6=train(net6,pTotal,t6);
fprintf(fb,' Proses Pembelajaran :\n');
alearn=[sim(net1,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
alearn=[sim(net2,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
alearn=[sim(net3,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
alearn=[sim(net4,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
alearn=[sim(net5,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
alearn=[sim(net6,pTotal)]
fprintf(fb,'%4.0f\n',alearn);
% B. Tahap Pelatihan
% B.1 Deklarasi dan Inisialisasi Jaringan
net11=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net21=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net31=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net41=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net51=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
net61=newp([0 1;0 1;0 1;0 1;0 1;0 1],1);
w1=net11.IW{1,1,1,1,1,1};
w2=net21.IW{1,1,1,1,1,1};
w3=net31.IW{1,1,1,1,1,1};
w4=net41.IW{1,1,1,1,1,1};
w5=net51.IW{1,1,1,1,1,1};
w6=net61.IW{1,1,1,1,1,1};
b1=net11.b{1}; b2=net21.b{1};
b3=net31.b{1}; b4=net41.b{1};
b5=net51.b{1}; b6=net61.b{1};
% B.2 Deklarasi Matriks
p1=[1018.60 562.61 319.20 177.01 123.21
101.57;%Normal
        298.76 179.02 98.99 81.66 73.27
63.06;%Meningioma
        1857.49 792.25 623.12 343.65 216.98
186.47;%Adenoma H
        781.05 610.28 453.72 306.23 250.60
186.48;%Kraniofaringioma
        1352.06 537.14 375.49 285.66 221.15
149.33;%Pilocytic A
        1722.61 1414.34 616.85 509.11 292.25
272.33];%Akustik N
    pTotal1=p1';
% B.3 Deklarasi Target
t11 = t1;t21 = t2;
t31 = t3;t41 = t4;
t51 = t5;t61 = t6;
% B.4 Proses Pelatihan
net11=train(net11,pTotal1,t11);
net21=train(net21,pTotal1,t21);
net31=train(net31,pTotal1,t31);
net41=train(net41,pTotal1,t41);
net51=train(net51,pTotal1,t51);
net61=train(net61,pTotal1,t61);
fprintf(fb,' Proses Pelatihan :\n');
atrain=[sim(net11,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
atrain=[sim(net21,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
atrain=[sim(net31,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
atrain=[sim(net41,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
atrain=[sim(net51,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
atrain=[sim(net61,pTotal1)]
fprintf(fb,'%4.0f\n',atrain);
% C. Simulasi 1
% C.1 Deklarasi
p2=[1000.64 556.42 342.17 196.72 117.19
92.77;%Normal
        985.00 701.23 425.37 347.89 306.45
241.90;%Meningioma
        1670.58 684.77 499.83 347.06 261.39
195.54;%Adenoma H
        267.17 163.00 132.62 82.98 48.05
38.25;%Kraniofaringioma
        278.95 198.32 85.74 74.50 50.57
49.14;%Pilocytic A
        720.19 449.20 386.56 244.10 143.90
102.47];%Akustik Neurinoma
    pTotal2=p2';
% C.2 Proses Simulasi 1
net12=train(net11,pTotal2,t11);
net22=train(net21,pTotal2,t21);
net32=train(net31,pTotal2,t31);
net42=train(net41,pTotal2,t41);
net52=train(net51,pTotal2,t51);
net62=train(net61,pTotal2,t61);
fprintf(fb,' Proses Simulasi 1 :\n');
asim1=[sim(net12,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
asim1=[sim(net22,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
asim1=[sim(net32,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
asim1=[sim(net42,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
asim1=[sim(net52,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
asim1=[sim(net62,pTotal2)]
fprintf(fb,'%4.0f\n',asim1);
Hasil :
Proses Pembelajaran :
1 0 0 0 0 0
0 1 0 0 0 0
0 0 1 0 0 0
0 0 0 1 0 0
1 1 1 1 1 0
0 0 0 0 0 1
Proses Pelatihan :
1 0 0 0 0 0
0 1 0 0 0 0
0 0 1 0 0 0
0 0 0 1 0 0
1 1 1 1 1 0
0 0 0 0 0 1
Proses Simulasi 1 :
1 0 0 0 0 0
0 1 0 0 0 0
0 0 1 0 0 0
0 0 0 0 0 0 (seharusnya 0 0 0 1 0 0)
1 1 1 1 1 0
0 0 0 0 0 1

```