

KLASIFIKASI CITRA MAMOGRAFI MENGGUNAKAN JARINGAN SYARAF TIRUAN

MAMMOGRAPHIC IMAGES CLASSIFICATION USING ARTIFICIAL NEURAL NETWORK

Indah Susilawati

Staf Pengajar Teknik Elektro Universitas Mercu Buana Yogyakarta
Jl. Wates Km. 10 Yogyakarta Telp. (0274) 6498211, 6498212 Fax. (0274) 6498213
Email: susilawati.indah@yahoo.co.id

ABSTRACT

There are abnormalities in breast tissue which can be detected by mammogram images analysis. One of those abnormalities is microcalcification. Microcalcifications are small calcium deposits in the breast tissue that can be seen only on a mammogram and can be an indicator of breast cancer. The main objective of this research is to automatically recognize the pattern of two types of breast tissues, i.e. normal tissue and breast tissue which contain microcalcifications in digital mammograms using Matlab software tools.

In this research, pattern recognition is carried out using Artificial Neural Network (ANN), i.e. LVQ (Learning Vector Quantization). The pattern recognition is formulated as a supervised-learning problem and classification was based on six-feature input given to the ANN. The system recognizes the pattern in three steps. Firstly, a tophat transformation is applied on the images, and then features of the images are extracted based on images pixel values. Finally, image classification is carried out in recognizing the pattern. The research uses 26 digital mammograms, consist of 16 normal mammograms and 10 mammograms which contain microcalcifications.

The results show that the LVQ best performance in recognizing the pattern is 97%, using learning rate and decrement of learning rate equal to 0.1.

Keywords: mammograms, microcalcification, pattern recognition, LVQ.

PENDAHULUAN

Seorang dokter atau ahli radiologi menggunakan citra mamografi untuk mengetahui adanya abnormalitas pada jaringan payudara. Citra mamografi dapat dihasilkan dengan pencitraan sinar X menggunakan mesin mamografi (*mammogram machine*). Analisis seperti ini membutuhkan keahlian dan pengalaman, dengan kata lain hasil analisis bersifat subjektif.

Analisis jenis lain, misalnya analisis berbantuan komputer diharapkan dapat bersifat lebih objektif. Analisis jenis yang terakhir ini diharapkan dapat dibangun sebagai alat bantu bagi dokter atau ahli radiologi dalam melakukan diagnosa dan bukan menggantikan peran dokter atau ahli radiologi sepenuhnya.

Diagnosis kanker payudara dapat dilakukan menggunakan pemrograman linear, dan diagnosis berdasarkan metode pembelajaran merupakan suatu obyek penelitian yang klasifikasi dan pengenalan pola. Metode ini menawarkan kemampuan untuk membedakan objek menjadi beberapa kelas berdasarkan ciri yang ada pada masing-masing kelas atau kategori obyek tersebut [Duda, 2000].

Pada penelitian ini dilakukan klasifikasi citra mamografi menjadi dua kelas, yaitu citra normal dan citra bermikrokalsifikasi. Mikrokalsifikasi merupakan deposit atau timbunan kalsium pada jaringan payudara dan biasanya menjadi tanda-tanda awal perubahan ke arah kanker [El-Naqa, 2002]. Ciri-ciri yang digunakan dalam proses klasifikasi adalah ciri-ciri statistik yang diperoleh dari nilai-nilai piksel citra.

METODOLOGI PENELITIAN

Bahan Penelitian

Bahan penelitian diperoleh dari basis data MIAS (*Mammographic Image Analysis Society*). Citra yang tersedia berupa citra aras keabuan 8 bit berukuran 1024 x 1024 piksel dengan ukuran piksel 200 mikron. Pada penelitian ini digunakan 16 citra mamografi normal dan 10 citra mamografi bermikrokalsifikasi.

Metodologi

Langkah-langkah yang dilakukan dalam penelitian ini diperlihatkan pada Gambar 1 [Duda, 2000].

Sampling dilakukan untuk mengambil sampel-sampel citra dari citra mamografi normal (selanjutnya disebut citra normal) dan citra mamografi yang mengandung mikrokalsifikasi (selanjutnya disebut dengan citra bermikrokalsifikasi). Dalam penelitian ini diambil 64 sampel citra normal dan 34 sampel citra bermikrokalsifikasi. Semua sampel berukuran 40 x 40 piksel.

sangat menjanjikan [Mangasarian, 1995]. Jaringan Syaraf Tiruan merupakan suatu metode pembelajaran yang dapat digunakan untuk



Gambar 1. Diagram blok langkah penelitian

Citra mamografi seringkali mempunyai kontras yang kurang baik. Untuk mengatasinya maka dalam penelitian ini dilakukan peningkatan citra menggunakan transformasi tophat. Untuk kepentingan transformasi tersebut digunakan persamaan berikut.

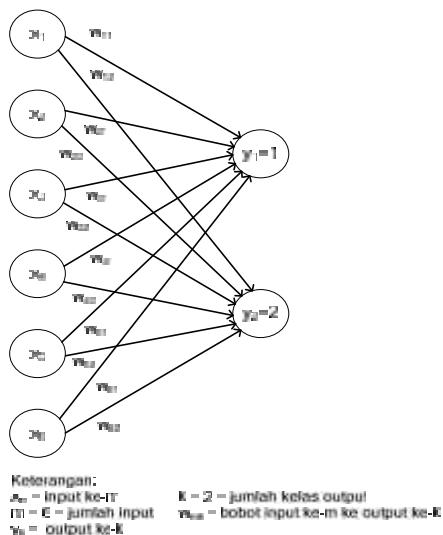
$$\text{TopHat}(A, B) = A - (A \circ B) = A - \max_B(\min_B(A))$$

Dengan A adalah objek yang akan ditransformasikan, B adalah elemen penstruktur (*structuring element*), notasi \circ menyatakan operasi pembukaan (*opening*) untuk objek terang dengan latar belakang gelap. Matlab memberikan beberapa pilihan bentuk elemen penstruktur, di antaranya berbentuk *disk*, *line*, dan lain-lain. Pada penelitian ini digunakan elemen penstruktur berbentuk *disk* karena secara visual titik-titik deposit kalsium atau mikrokalsifikasi biasanya cenderung berbentuk bulat. Secara umum transformasi bertujuan untuk meningkatkan kontras citra sehingga ciri-ciri yang membedakan antara citra normal dan citra dengan mikrokalsifikasi akan lebih menonjol.

Langkah selanjutnya adalah proses ekstraksi ciri citra yang sebelumnya telah melalui proses peningkatan citra. Dalam

penelitian ini diekstrak enam ciri citra berdasarkan nilai-nilai piksel citra sampel [Jain, 1989]. Keenam ciri tersebut adalah rerata, varians, standar deviasi (disingkat std), entropi, beda antara nilai piksel maksimum dan nilai minimum (selanjutnya disebut dengan istilah beda1), serta beda antara nilai piksel maksimum dan nilai reratanya (selanjutnya disebut dengan istilah beda2). Hasil ekstraksi ciri akan menjadi masukan pengklasifikasi (*classifier*).

Pada penelitian ini digunakan Jaringan Syaraf Tiruan, yaitu *Learning Vector Quantization* (LVQ), sebagai pengklasifikasi. LVQ merupakan jenis Jaringan Syaraf Tiruan yang bekerja berdasarkan pembelajaran kompetitif dan termasuk dalam kategori pembelajaran terbimbing atau *supervised* [Sri Widodo, 2005; Siang, 2005]. Arsitektur LVQ yang akan digunakan pada penelitian ini diperlihatkan pada Gambar 2.



Gambar 2. Arsitektur LVQ yang digunakan

Masukan jaringan LVQ, yaitu x_1 sampai dengan x_6 , adalah vektor ciri yang telah diekstrak pada langkah sebelumnya. Bobot w_{mk} adalah bobot masukan ciri ke- m ke keluaran ke- k . Keluaran jaringan LVQ berupa kelas citra (ditentukan kelas 1 untuk citra normal dan kelas 2 untuk citra bermikrokalsifikasi). Bobot awal jaringan

LVQ ditentukan secara acak dari hasil ekstraksi ciri sampel citra.

Berikut adalah algoritma pelatihan jaringan LVQ yang digunakan dalam penelitian ini [Kusumadewi, 2004]. Notasi-notasi yang digunakan adalah:

x	: vektor pelatihan (x_1, x_2, \dots, x_m)
T	: kelas atau kategori vektor pelatihan yang sebenarnya
w_j	: vektor bobot untuk unit output ke- j ($w_{1j}, w_{2j}, \dots, w_{mj}$)
C_j	: kelas atau kategori yang direpresentasikan oleh unit output ke- j
$\ x-w_j\ $	jarak Euclidean antara vektor input dan vektor bobot untuk unit output ke- j

- Langkah 0 Inisialisasi vektor-bobot awal dan laju pembelajaran $\alpha(0)$.
- Langkah 1 Jika kondisi berhenti salah, lakukan langkah 2 – 6.
- Langkah 2 Untuk setiap vektor input pelatihan x , lakukan langkah 3 – 4.
- Langkah 3 Tentukan J sedemikian rupa sehingga $\|x - w_j\|$ minimum.
- Langkah 4 Perbarui w_j dengan ketentuan sebagai berikut:
 Jika $T = C_j$ maka
 $w_j(b) = w_j(l) + \alpha [x - w_j(l)]$
 Jika $T \neq C_j$ maka
 $w_j(b) = w_j(l) - \alpha [x - w_j(l)]$
- Langkah 5 Kurangi laju pembelajaran.
- Langkah 6 Tes kondisi berhenti. Kondisi berhenti dapat berupa jumlah iterasi tertentu yang tetap (yaitu eksekusi langkah 1) atau laju pembelajaran mencapai nilai yang cukup kecil.

HASIL DAN PEMBAHASAN

Hasil Penelitian

Sampling citra baik citra normal maupun citra bermikrokalsifikasi dilakukan dari data yang diperoleh dari basis data MIAS. Pada Gambar 3 diperlihatkan satu contoh hasil *sampling* citra normal (kelas 1) yang akan digunakan dalam penelitian ini. Sedangkan pada Gambar 4 diperlihatkan

satu contoh hasil *sampling* untuk citra bermikrokalsifikasi (kelas 2).



Gambar 3. Contoh hasil *sampling* citra normal

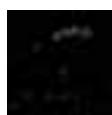


Gambar 4. Contoh hasil *sampling* citra bermikrokalsifikasi

Gambar 5 memperlihatkan hasil transformasi *tophat* untuk sampel citra normal (kelas 1) Gambar 3. Sedangkan pada Gambar 5 diperlihatkan hasil transformasi *tophat* untuk sampel citra bermikrokalsifikasi (kelas 2) pada Gambar 4.



Gambar 5. Hasil perentangan kontras citra normal pada Gambar 3



Gambar 6. Hasil perentangan kontras citra bermikrokalsifikasi pada Gambar 4

Jangkauan nilai hasil ekstraksi ciri pada semua sampel citra untuk citra normal dan citra bermikrokalsifikasi ditampilkan pada Tabel 1 dan Tabel 2.

Tabel 1. Jangkauan nilai ciri (tanpa transformasi *tophat*)

Ciri	Jangkauan Nilai	
	Citra Normal	Citra bermikrokalsifikasi
Rerata	0,0050 – 219,5988	96,6319 – 181,0606
Varians	0,0040 – 1779,8	39,8339 – 391,5422
Std	0,1999 – 42,1875	6,3114 – 19,7874
Entropi	0,0076 – 7,0703	4,5959 – 6,1755
Bedaan1	8 – 167	47 – 108

Bedaan2 6,4013 – 63,8131 26,4419 – 73,1188

Tabel 2. Jangkauan nilai ciri (dengan transformasi *tophat*)

Ciri	Jangkauan Nilai	
	Citra Normal	Citra bermikrokalsifikasi
Rerata	0,0050 – 2,8169	1,8425 – 3,8706
Varians	0,0040 – 10,3858	4,3215 – 69,7926
Std	0,1999 – 3,2227	2,0788 – 8,3542
Entropi	0,0076 – 7,0703	4,5707 – 6,1755
Bedaan1	3 – 20	16 – 72
Bedaan2	2,6981 – 17,6806	13,7125 – 68,1294

Jaringan LVQ yang dibangun akan dilatih menggunakan data ciri dari 98 sampel yang ada, kemudian jaringan yang telah terlatih diuji menggunakan data yang sama. Tabel 3 hingga Tabel 6 memperlihatkan hasil klasifikasi selengkapnya.

Pembahasan

Sampling citra bertujuan mengambil sampel-sampel citra yang akan digunakan untuk klasifikasi citra. Sampel citra normal yang digunakan adalah sebanyak 64 sampel, diambil secara acak dari citra mamografi normal. Sampel citra ini dikategorikan sebagai citra kelas 1.

Sampel citra bermikrokalsifikasi yang digunakan berjumlah 34 sampel, diambil dari citra bermikrokalsifikasi. Pengambilan sampel citra bermikrokalsifikasi dilakukan dengan memperhatikan letak atau posisi mikrokalsifikasi, informasi ini diperoleh dari basis data MIAS. Sampel citra bermikrokalsifikasi dikategorikan sebagai citra kelas 2.

Tabel 3. Hasil pengenalan pola (tanpa transformasi *tophat*, $\text{deca} = 0,1$, $\text{min}\alpha = 10^{-4}$, $\text{maxepoch} = 100$)

α	Tingkat Pengenalan Rata-rata (%)	Jumlah Epoch	α Minimum
0,1	50	66	$9,6 \times 10^{-5}$
0,2	50	73	$9,1 \times 10^{-5}$
0,3	50	76	10×10^{-5}
0,4	50	79	$9,7 \times 10^{-5}$
0,5	50	81	$9,8 \times 10^{-5}$
0,6	50	83	$9,6 \times 10^{-5}$
0,7	50	85	$9,0 \times 10^{-5}$
0,8	50	86	$9,3 \times 10^{-5}$

0,9	50	87	$9,4 \times 10^{-5}$
1	50	88	$9,4 \times 10^{-5}$

Tabel 4. Hasil pengenalan pola (tanpa transformasi *tophat*, $\text{deca} = 0,5$, $\text{min}\alpha = 10^{-4}$, $\text{maxepoch} = 100$)

α	Tingkat Pengenalan Rata-rata (%)	Jumlah Epoch	α Minimum
0,1	59	10	$9,8 \times 10^{-5}$
0,2	58	11	$9,8 \times 10^{-5}$
0,3	50	12	$7,3 \times 10^{-5}$
0,4	50	12	$9,8 \times 10^{-5}$
0,5	50	13	$6,1 \times 10^{-5}$
0,6	50	13	$7,3 \times 10^{-5}$
0,7	50	13	$8,5 \times 10^{-5}$
0,8	50	13	$9,8 \times 10^{-5}$
0,9	50	14	$5,5 \times 10^{-5}$
1	50	14	$6,1 \times 10^{-5}$

Tabel 5. Hasil pengenalan pola (dengan transformasi *tophat*, $\text{deca} = 0,1$, $\text{min}\alpha = 10^{-4}$, $\text{maxepoch} = 100$)

α	Tingkat Pengenalan Rata-rata (%)	Jumlah Epoch	α Minimum
0,1	97	66	$9,6 \times 10^{-5}$
0,2	97	73	$9,1 \times 10^{-5}$
0,3	97	76	10×10^{-5}
0,4	97	79	$9,7 \times 10^{-5}$
0,5	97	81	$9,8 \times 10^{-5}$
0,6	97	83	$9,6 \times 10^{-5}$
0,7	97	85	$9,0 \times 10^{-5}$
0,8	50	86	$9,3 \times 10^{-5}$
0,9	50	87	$9,4 \times 10^{-5}$
1	97	88	$9,4 \times 10^{-5}$

Tabel 6. Hasil pengenalan pola (dengan transformasi *tophat*, $\text{deca} = 0,5$, $\text{min}\alpha = 10^{-4}$, $\text{maxepoch} = 100$)

α	Tingkat Pengenalan Rata-rata (%)	Jumlah Epoch	α Minimum
0,1	97	10	$9,8 \times 10^{-5}$
0,2	97	11	$9,8 \times 10^{-5}$
0,3	97	12	$7,3 \times 10^{-5}$
0,4	97	12	$9,8 \times 10^{-5}$
0,5	97	13	$6,1 \times 10^{-5}$
0,6	97	13	$7,3 \times 10^{-5}$
0,7	97	13	$8,5 \times 10^{-5}$
0,8	97	13	$9,8 \times 10^{-5}$
0,9	97	14	$5,5 \times 10^{-5}$
1	97	14	$6,1 \times 10^{-5}$

Jumlah sampel citra normal diambil kira-kira dua kali lipat jumlah sampel citra bermikrokalsifikasi. Hal ini dilakukan dengan alasan bahwa citra mamografi normal jauh lebih bervariasi daripada citra bermikrokalsifikasi, misalnya oleh karena sifat jaringan, adanya saluran air susu ibu, pembuluh darah, dan lain-lain [Sheshadri, 2006; Liu, 1998].

Untuk kepentingan peningkatan citra digunakan transformasi *tophat*. Langkah ini dilakukan karena citra mamografi seringkali merupakan citra dengan kontras yang kurang baik. Kontras yang kurang baik ini dapat dipengaruhi oleh proses pencitraan itu sendiri misalnya karena penggunaan dosis sinar X yang kurang sesuai atau karena pengaruh sifat jaringan yang bersangkutan [Yaffe, 1995].

Pada Gambar 5 dan Gambar 6 diperlihatkan sampel citra yang telah dikenakan transformasi *tophat*, masing-masing untuk citra normal dan citra bermikrokalsifikasi. Perbaikan kontras citra ini juga akan lebih tampak jika dibandingkan histogram citranya, yaitu histogram citra sebelum dan sesudah proses transformasi perentangan kontras.

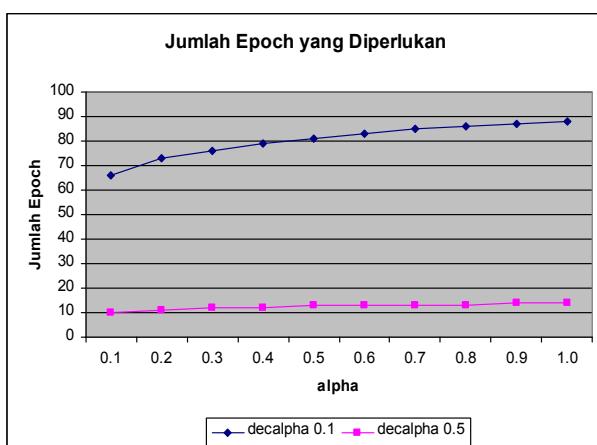
Ekstraksi ciri pada sampel-sampel citra yang telah dikenai transformasi *tophat* menghasilkan ciri-ciri yang jangkauannya masing-masing diperlihatkan pada Tabel 1 dan Tabel 2. Setiap sampel citra akan menghasilkan kombinasi enam ciri, yang akan membentuk satu vektor ciri sehingga secara keseluruhan terdapat 98 vektor ciri yang diekstrak dari 98 sampel citra yang digunakan. Vektor ciri inilah yang digunakan sebagai masukan jaringan pengklasifikasi LVQ.

Dalam penelitian ini dilakukan pelatihan dan pengujian jaringan pengklasifikasi dengan data yang sama. Klasifikasi dilakukan dengan berbagai kombinasi parameter jaringan, yaitu dengan berbagai nilai laju pelatihan (α) dan penurunan laju pelatihan (deca). Tanpa transformasi *tophat*, jaringan LVQ hampir tidak mengenali jaringan bermikrokalsifikasi sebagai kelas 2 (dalam hal ini jaringan bermikrokalsifikasi dikenali sebagai jaringan normal atau kelas 1), atau tingkat pengenalan rata-rata 50%. Jaringan mampu mengenali kedua jenis citra saat digunakan nilai $\alpha = 0,1$ dan $\alpha = 0,2$ (nilai $\text{deca} = 0,5$), yaitu setinggi 59%. Dengan demikian dapat disimpulkan bahwa jika menggunakan ciri-ciri yang diekstrak dari

sampel asli, jaringan LVQ hanya mampu menampilkan kinerja pengenalan pola tertinggi 59%.

Berdasarkan hasil pengenalan pola dengan masukan ciri-ciri sampel yang dikenai transformasi *tophat* pada Tabel 5 dan Tabel 6, diperoleh pengenalan tertinggi 97%. Kinerja pengenalan dapat dikatakan cukup stabil kecuali saat digunakan $deca = 0,1$ dengan nilai α sebesar 0,8 dan 0,9. Pada kedua nilai kombinasi $deca$ dan α ini hanya diperoleh kinerja pengenalan 50% yang berarti jaringan LVQ tidak mampu mengenali jaringan dengan mikrokalsifikasi; semua sampel dikenali sebagai jaringan normal.

Berdasarkan kedua tabel juga diketahui bahwa tingkat pengenalan setinggi 97% dicapai hampir pada seluruh kombinasi $deca$ dan α kecuali pada saat digunakan $deca = 0,1$ dengan nilai α sebesar 0,8 dan 0,9. Untuk menentukan kombinasi $deca$ dan α terbaik dapat ditentukan dengan memperhatikan jumlah *epoch* yang diperlukan untuk mencapai kinerja pengenalan tersebut. Jumlah *epoch* untuk keempat tabel di atas disajikan kembali dalam bentuk grafik pada Gambar 7.



Gambar 7. Grafis perbandingan hasil pengenalan pola

Jumlah *epoch* terkecil yang diperlukan untuk proses pengenalan pola pada penelitian ini adalah 10 *epoch*, dicapai saat

digunakan $deca = 0,1$ dan $\alpha = 0,1$. Pada kombinasi $deca$ dan α tersebut, jaringan LVQ menghasilkan bobot akhir jaringan sebagai berikut.

BobotAkhir =

1.7534	4.9208	2.1272	5.3610	12.8059	11.0525
2.8038	18.4257	4.1564	5.4032	38.1547	35.3509

Berdasarkan hasil-hasil di atas, maka jaringan LVQ yang direkomendasikan untuk digunakan untuk pengenalan pola jaringan normal dan jaringan dengan mikrokalsifikasi pada citra mamografi digital adalah jaringan LVQ yang telah dilatih menggunakan $deca = 0,1$ dan $\alpha = 0,1$. Kesimpulan ini ditentukan dengan memperhatikan jumlah *epoch* yang diperlukan untuk pelatihan jaringan LVQ, yaitu 10 *epoch* yang merupakan jumlah *epoch* terkecil dalam penelitian ini. Jumlah *epoch* yang kecil berarti waktu yang lebih singkat dan juga memungkinkan terhindarnya *overlearning* (akibat *overfitting*) selama proses pelatihan jaringan LVQ.

SIMPULAN DAN SARAN

Simpulan

Berdasarkan hasil penelitian dan pembahasan pada bab sebelumnya, dapat ditarik beberapa kesimpulan sebagai berikut.

1. Jaringan LVQ dapat digunakan untuk proses pengenalan pola jaringan normal dan jaringan dengan mikrokalsifikasi pada citra mamografi digital, dengan masukan berupa ciri-ciri yang diekstrak berdasarkan nilai piksel citra yaitu rerata, varians, standar deviasi, entropi, beda nilai piksel minimum dan maksimum, serta beda nilai piksel maksimum dengan reratanya.
2. Transformasi *tophat* pada citra mampu meningkatkan kinerja pengenalan pola oleh jaringan LVQ. Kinerja pengenalan pola tertinggi tanpa transformasi *tophat* hanya mencapai 59%, sedangkan

dengan pra-pengolahan berupa transformasi *tophat* kinerja pengenalan pola oleh jaringan LVQ mencapai 97%.

Saran

Berdasarkan hasil penelitian dan pembahasan serta simpulan, maka dapat disarankan untuk pengembangan penelitian ini. Mengupayakan kinerja pengenalan pola oleh jaringan LVQ yang lebih tinggi lagi dengan cara mengekstrak lebih banyak ciri dari citra mamografi untuk selanjutnya digunakan sebagai masukan jaringan LVQ.

1. Mengupayakan kinerja pengenalan pola yang lebih tinggi lagi menggunakan metode klasifikasi yang lain, misalnya menggunakan SVM (*Support Vector Machines*).
2. Menggunakan jaringan LVQ terlatih yang telah dihasilkan pada penelitian ini untuk mendeteksi letak jaringan yang mengandung mikrokalsifikasi pada citra mamografi digital.

DAFTAR PUSTAKA

- El-Naqa, Issam, dkk, 2002, *Support Vector Machine Learning for Detection of Microcalcifications in Mammograms*, Dept. Of Electrical and Computer Engineering, Illinois Institute of Technology.
- Duda, R.O., Harl, P.E., Stork, D.G., 2000, *Pattern Classification*, Second Edition, John Wiley & Sons, Inc.
- Haykin, Simon., 1994, *Neural Network a Comprehensive Foundation*, Macmillan College Publishing Company.
- Jain, Anil K., 1989, *Fundamental of Digital Image Processing*, Prentice Hall International, Inc. Singapore.
- Kusumadewi, Sri., 2004, Membangun Jaringan Syaraf Tiruan Menggunakan Matlab dan Excel Link, Graha Ilmu, Yogyakarta.
- Liu, Sheng., Babbs, Charles F., dan Delp, Edward J., 1998, *Normal Mammogram Analysis and Recognition*, Purdue University, Indiana.
- Mangasarian, O.L., 1995, *Breast Cancer Diagnosis and Prognosis via Linear Programming*, Oper. Res., 43: 570-577.
- Munir, R., 2004, Pengolahan Citra Digital dengan Pendekatan Algoritmik, Informatika Bandung.
- Sheshadri, H.S. dan Kandaswamy, A., 2006, *Computer Aided Decision System for Early Detection of Breast Cancer*, Indian J Med Res 124, pp 149 – 154.
- Siang, J.J., 2005, Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab, Penerbit Andi, Yogyakarta.
- Sri Widodo, Thomas, 2005, Sistem Neuro Fuzzy untuk Pengolahan Informasi, Pemodelan, dan Kendali, Graha Ilmu, Yogyakarta.
- Yaffe, Martin J., 1995, *Mammography, Biomedical Engineering Handbook*, IEEE Press.
-
- http://www.imaginis.com/breasthealth/statistics.asp, download tanggal 15 Mei 2008 pukul 13.42 WIB.
-
- http://peipa.essex.ac.uk/ipa/pix/mias, download tanggal 27 Desember 2007 pukul 12.22 WIB.
-
- http://www.ph.tn.tudelft.nl/Courses/FIP/noframes/fip download tanggal 24 April 2008 pukul 19.39 WIB.