

## TRANSFORMASI WAVELET DAN ADAPTIVE NEIGHBORHOOD BASED MODIFIED BACKPROPAGATION (ANMBP) UNTUK KLASIFIKASI DATA MAMMOGRAM

Indah Werdiningsih

Program Studi Sistem Informasi , Fakultas Sains dan Teknologi  
Universitas Airlangga Surabaya

Email : [indah\\_werdiningsih@yahoo.co.id](mailto:indah_werdiningsih@yahoo.co.id)

**Abstrak.** *Adaptive Neighborhood Based Modified Backpropagation* (ANMBP) merupakan salah satu metode untuk klasifikasi. Tujuan penelitian ini adalah untuk mengklasifikasikan data mammogram menggunakan ANMBP. Klasifikasi dibagi menjadi tiga kategori, yaitu normal dan tidak normal, *massa* dan *mikrokalsifikasi*, jinak dan ganas. Klasifikasi data mammogram meliputi *preprocessing*, ekstraksi fitur dan klasifikasi. *Preprocessing* menggunakan *thresholding* dan *histogram equalization*. Ekstraksi Fitur menggunakan transformasi wavelet dan klasifikasi menggunakan ANMBP.

Hasil dari transformasi wavelet berupa koefisien energi. Koefisien energi yang digunakan 100, 500, 1000 dan 5000. Hasil klasifikasi menunjukkan bahwa *massa* dapat dikenali dengan baik menggunakan koefisien energi 100 dan *mikrokalsifikasi* dapat dikenali dengan baik menggunakan koefisien energi 5000. Hasil *training* dengan *artificial neural network* untuk *mikrokalsifikasi jinak* dan *mikrokalsifikasi ganas* iterasi berhenti pada epoch ke-666 dengan error sebesar 0.00096204 sedangkan hasil *training* dengan *neural network* belum konvergen sampai iterasi 1000000 dengan error 0.0546007.

**Kata Kunci :** *Klasifikasi, ANMBP, massa, mikrokalsifikasi.*

Kanker payudara sebagai jenis kanker yang paling banyak ditemui pada wanita. Menurut WHO, persentase wanita yang mengalami kanker payudara sekitar 8 – 9 % [1]. Salah satu cara yang harus dilakukan wanita agar terhindar dari kanker payudara adalah dengan deteksi dini, misalnya dengan SADARI, yaitu pemeriksaan payudara sendiri atau dengan melakukan mammografi (payudara X-ray) [2]

Kanker atau tumor ganas disebabkan adanya *massa* atau *mikrokalsifikasi* pada payudara [3]. *Massa* adalah gumpalan yang pertumbuhan sel yang berlebihan. *Mikrokalsifikasi* adalah bintik kecil kalsium di payudara. Mammogram (payudara X-ray) dianggap sebagai gambar medis yang paling dapat digunakan untuk mendeteksi kanker payudara secara dini [4].

Proses klasifikasi data yang diperoleh dari data *history* merupakan salah satu mata pelajaran yang paling intensif dipelajari dalam ilmu keputusan dan ilmu komputer. Proses klasifikasi data telah diterapkan dalam masalah kedokteran, ilmu manajemen dan sosial serta ilmu rekayasa. Masalah yang sering terjadi dalam penggunaan teknik klasifikasi adalah

diagnosa penyakit, pengenalan gambar, dan evaluasi kredit [5].

Transformasi wavelet dapat digunakan untuk mengekstraksi data mammogram. Tingkat klasifikasi mammogram dapat mencapai performa yang terbaik dengan menggunakan fitur *mikrokalsifikasi*. Transformasi wavelet menggunakan detail informasi frekuensi tinggi sehingga fitur *mikrokalsifikasi* dapat dikenali dengan baik. Transformasi wavelet menggunakan dekomposisi wavelet sehingga dapat mengurangi noise [6]. Klasifikasi data mammogram menggunakan *Adaptive Neighborhood Based Modified Backpropagation* (ANMBP). ANMBP menggunakan adaptive learning rate, random neighborhood pada hidden layer and adaptive weight dengan menjumlahkan error linier dan non linier. ANMBP dapat menghindari lokal minima sehingga dapat mempercepat konvergensi [7]

Berdasarkan uraian diatas maka tujuan penelitian ini adalah untuk mengklasifikasi data mammogram dengan menggunakan transformasi wavelet dan ANMBP. Dengan menggabungkan metode transformasi wavelet dan ANMBP diharapkan dapat mempercepat

konvergensi dalam mengklasifikasi data mammogram.


## I. METODOLOGI

### Kanker payudara

Kanker payudara dimulai pada daerah payudara (*breast*) kemudian menyebar ke kelenjar getah bening (*lymph node*) ketiak. Jika pada payudara ditemukan gumpalan kanker dan belum menyebar ke kelenjar getah bening ketiak maka kanker harus segera dioperasi agar tidak menyebar melalui aliran darah ke seluruh tubuh [8]. Bila terjadi gejala tersebut biasanya dokter akan menyarankan untuk dilakukan pemeriksaan mammografi dengan mammogram.

### Massa

*Massa* adalah gumpalan dari pertumbuhan sel yang berlebihan. *Massa* terdiri dari jinak dan ganas. *Massa* jinak dan ganas dapat dibedakan dari atributnya seperti margin, kepadatan dan lokasi [3]. Jika memiliki kepadatannya rendah, bentuk bulat, margin yang halus dan tajam maka dikategorikan *massa* jinak. Jika memiliki kepadatan tinggi, berbentuk seperti bintang, bercabang dan margin yang kurang baik dikategorikan *massa* ganas. Gambar 1 menunjukkan dua contoh *massa* (a) *massa* jinak dan (b) *massa* ganas.




Gambar 1. *Massa* (a) *massa* jinak. (b) *massa* ganas.

### Mikrokalsifikasi

*Mikrokalsifikasi* adalah bintik kecil kalsium di payudara. *Mikrokalsifikasi* muncul sendiri atau dalam kelompok. *Mikrokalsifikasi* terdiri dari jinak dan ganas. *Mikrokalsifikasi* jinak dan ganas dapat dibedakan dari atributnya seperti ukuran, bentuk, kepadatan, pola distribusi panyebaran dan jumlah *mikrokalsifikasi* [3]. *Mikrokalsifikasi* jinak biasanya berukuran besar, kasar, bulat atau oval, dan memiliki ukuran dan bentuk yang sama dan biasanya tersebar atau menyebar. *Mikrokalsifikasi* ganas biasanya ukurannya kecil, bercabang, berbentuk seperti bintang,

ukuran dan bentuk bervariasi, berkelompok atau mengelompok, dan jumlahnya tak terhitung banyaknya. Gambar 2 menunjukkan (a) *mikrokalsifikasi* jinak dan (b) *mikrokalsifikasi* ganas.



Gambar 2. *Mikrokalsifikasi* (a) *Mikrokalsifikasi* jinak (b) *Mikrokalsifikasi* ganas.

### Transformasi wavelet

Transformasi merupakan suatu proses pengubahan data menjadi bentuk lain sehingga mudah dianalisa. Transformasi wavelet merupakan generalisasi dari transformasi Fourier [9]. Transformasi wavelet merupakan proses mengubah sinyal ke dalam berbagai gelombang wavelet asli (*mother wavelet*) dengan berbagai pergeseran dan penyekalaan.

Transformasi wavelet terdapat istilah dekomposisi. Dekomposisi wavelet didapatkan melalui penapisan subbidang berkanal dua dengan dua tapis, yaitu tapis pererata atau penyekala atau disebut tapis lolos-rendah ( $H_0$ ) dan tapis detil atau tapis lolos-tinggi ( $H_1$ ) [9]. Konvolusi citra tapis lolos-rendah menghasilkan sinyal yang biasa disebut dengan citra pendekatan (*approximation image*) dan konvolusi dengan tapis lolos-tinggi pada arah spesifik menghasilkan citra detil (*details images*). Tipe *wavelet* yang akan digunakan adalah *Daubechies*. *Output* dekomposisi wavelet adalah vektor dekomposisi  $C$  dan matriks  $S$  [ $C, S$ ]. Vektor dekomposisi terdiri dari tiga vektor koefisien detail, vektor koefisien detail horizontal  $H$ , vektor koefisien detail vertikal dan vektor koefisien detail diagonal, dan satu approximasasi adalah vektor baris.

### Adaptif *neighborhood modified backpropagation* (anmbp)

*ANMBP* merupakan modifikasi *backpropagasi* yang menggunakan *adaptive learning rate*, *random neighborhood* pada *hidden layer* serta *adaptive weight*. Algoritma yang digunakan pelatihan dan pengujian yang

digunakan sebagai berikut [7]. Nilai *Net* digunakan dapat dilihat pada persamaan 1.

$$u_j^s = \sum_{i=1}^n w_{ji}^s y_i^{s-1} \tag{1}$$

dengan fungsi aktivasi sigmoid biner, maka outputnya dapat dilihat pada persamaan 2.

$$f(u_j^s) = \frac{1}{(1 + e^{-u_j^s})} = y_j^s \tag{2}$$

dengan *n* menunjukkan jumlah neuron dan  $w_{ij}^s$  adalah bobot dari neuron ke *i* dari layer (*s*-1) ke neuron ke *j* dari layer *s*. Pada algoritma modifikasi *neural network* digunakan  $E_p$  yang merupakan penjumlahan dari kuadrat error linier dan non linier dari *output*.

$$E_p = \sum_{j=1}^n \frac{1}{2} (e_{1j}^s)^2 + \sum_{j=1}^n \frac{1}{2} \lambda (e_{2j}^s)^2 \tag{3}$$

dimana  $\lambda$  adalah koefisien bobot dan error nonlinier ( $e_1$ ).

Error nonlinier ( $e_1$ ) adalah selisih antara *output* yang diharapkan (*d*) dan *output* yang dihasilkan (*y*).

$$e_{1j}^s = d_j^s - y_j^s \tag{4}$$

dan error linier ( $e_2$ ) adalah

$$e_{2j}^s = ld_j^s - u_j^s \tag{5}$$

$$ld_j^s = f^{-1}(d_j^s) \tag{6}$$

Sehingga perubahan bobot pada layer *output* adalah :

$$\Delta w_{ji}^s = -\mu \frac{\partial E}{\partial w_{ji}^s} \tag{7}$$

$$\Delta w_{ji}^s = \mu e_{1j}^s \frac{\partial y_j^s}{\partial w_{ji}^s} + \mu \lambda e_{2j}^s \frac{\partial u_j^s}{\partial w_{ji}^s}$$

$$\Delta w_{ji}^s = \mu e_{1j}^s \frac{\partial y_j^s}{\partial u_j^s} \frac{\partial u_j^s}{\partial w_{ji}^s} + \mu \lambda e_{2j}^s y_i^{s-1}$$

$$\Delta w_{ji}^s = \mu e_{1j}^s f'(u_j^s) y_i^{s-1} + \mu \lambda e_{2j}^s y_i^{s-1} \tag{8}$$

Error linier dan non linier pada hidden layer (*L*) [7] adalah :

$$e_{1j}^L = \sum_{r=1}^{n_{L+1}} f'(u_r^{L+1}) e_{ir}^{L+1} w_{rj}^{L+1} \tag{9}$$

$$e_{2j}^L = f^{-1}(u_j^L) \sum_{r=1}^{n_{L+1}} e_{2r}^{L+1} w_{rj}^{L+1} \tag{10}$$

sehingga perubahan bobot pada hidden layer adalah :

$$\Delta w_{ji}^L = \mu e_{1j}^L y_i^{L-1} f'(u_j^L) + \mu \lambda e_{2j}^L y_i^{L-1} \tag{11}$$

Parameter learning  $\mu$  dan  $\mu\lambda$  diganti dengan parameter adaptive(9) yaitu :

$$\eta' = \frac{\mu \|y\|^2}{\|J_p y\|^2 + \varepsilon} \tag{12}$$

$$\mu' = \frac{\mu \|y\|^2}{\|J_p y\|^2 + \varepsilon} \tag{13}$$

dimana  $e_{1j}^s = d_j^s - y_j^s$  dan  $J_p^T = \frac{\partial y_p}{\partial w_{ji}}$

sehingga parameter adaptive learning menjadi persamaan 14 dan 15.

$$\eta' = \frac{\mu \|e_{1j}\|^2}{\|f'(u_j) y_i^{s-1} e_{1j}\|^2 + \varepsilon} \tag{14}$$

$$\mu' = \frac{\lambda \|e_{1j}\|^2}{\|f'(u_j) y_i^{s-1} e_{1j}\|^2 + \varepsilon} \tag{15}$$

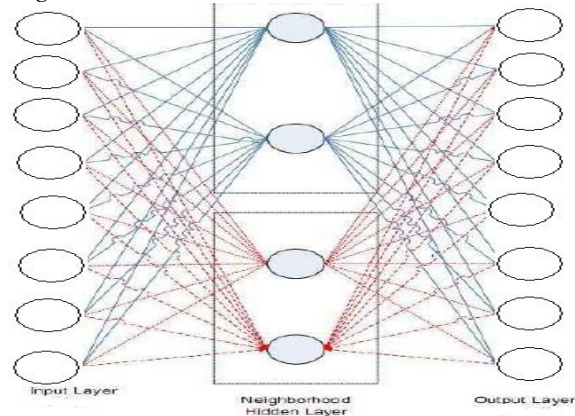
dimana  $\mu, \lambda$  adalah konstanta dengan nilai kecil positif dan  $\varepsilon$  konstanta dengan nilai kecil positif untuk menjamin ketidakstabilan ketika error menuju 0. Pemilihan nilai  $\mu, \lambda$  dan  $\varepsilon$  dilakukan secara bertahap untuk mendapatkan hasil yang optimal. Sehingga perubahan bobot pada layer *output* dan layer hidden menjadi

$$\Delta w_{ji}^s = \eta' e_{1j}^s f'(u_j^s) y_i^{s-1} + \mu' e_{2j}^s y_i^{s-1} \tag{16}$$

dengan perubahan bobot tersebut, maka bobot baru dihitung berdasarkan persamaan

$$w(t+1) = w(t) + \Delta w(t) \tag{17}$$

Arsitektur ANMBP terlihat pada Gambar 3. *Neighborhood* akan dibentuk secara acak pada hidden layer dengan jumlah neuron yang sama sehingga membutuhkan operasi dan memori yang minimum saat digunakan. *Neighborhood* untuk meminimalkan waktu dan bobot selama pelatihan. Node yang memiliki garis putus-putus ke output maupun input merupakan *Neighborhood*.



Gambar 3. Neighborhood.

**Rancangan sistem**

Rancangan sistem untuk diagnosis kanker payudara ditunjukkan dengan diagram blok sistem pada Gambar 4. Sistem yang dibangun meliputi *preprocessing*, fitur ekstraksi dan proses klasifikasi. Preprocessing terdiri dari *thresholding* dan *histogram equalization*. Fitur ekstraksi terdiri dari dekomposisi image, ekstraksi koefisien, normalisasi, energi komputasi, dan reduksi koefisien [6].

Data yang digunakan dalam penelitian ini diambil dari *Mammographic Image Analisis Society (MIAS)*. *Database* tersebut terdapat 204 gambar, yang terdiri dari menjadi normal sebanyak 140 gambar dan 64 tidak normal. Kategori tidak normal terdiri dari *massa* sebanyak 40 dan *mikrokalsifikasi* sebanyak 24. *Massa* terdiri dari *massa* jinak sebanyak 24 dan ganas sebanyak 16 sedangkan *mikrokalsifikasi* jinak sebanyak 12 dan ganas sebanyak 12.

Ekstraksi koefisien merupakan pengembalian vektor detail koefisien horizontal H, vertikal V, dan diagonal D pada level N dengan mengabaikan level 1. Hal tersebut dilakukan karena dekomposisi wavelet level 1 mempunyai detail frekuensi dan noise yang banyak.

Normalisasi adalah dengan membagi masing-masing vektor dengan nilai maksimum masing-masing vektor. Langkah selanjutnya adalah memperoleh energi komputasi. Energi diperoleh dengan mengkuadratkan setiap elemen dalam vektor. Segmen program untuk menghasilkan energi komputasi sebagai berikut :Setelah diperoleh energi komputasi, langkah selanjutnya adalah reduksi fitur. Reduksi fitur dilakukan dengan menjumlahkan nilai energi yang telah didefinisikan sebelumnya. Dalam hal

ini diusulkan suatu pendekatan reduksi fitur, yaitu :

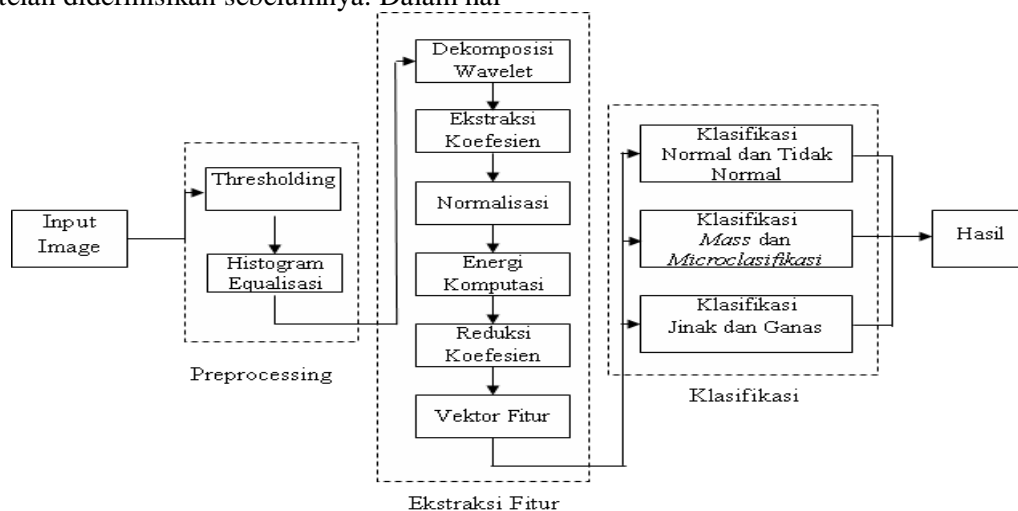
1. Menjumlahkan 5000 nilai energi per fitur.
2. Menjumlahkan 1000 nilai energi per fitur.
3. Menjumlahkan 500 nilai energi per fitur.
4. Menjumlahkan 100 nilai energi per fitur.

**II. HASIL UJI COBA DAN ANALISIS**

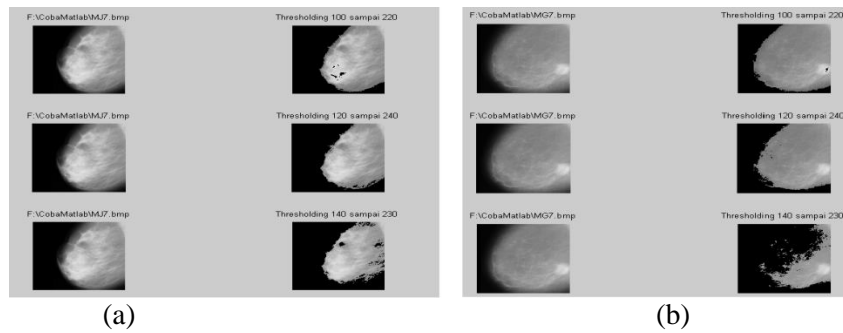
Ukuran gambar yang digunakan yaitu 800x800 piksel. Langkah pertama adalah *thresholding*, yaitu mengubah batas bawah dan batas atas menjadi nol [6]. Hasil *thresholding* dari *massa* jinak dan ganas dapat dilihat pada Gambar 5 dan hasil *thresholding* dari *mikrokalsifikasi* jinak dan ganas dapat dilihat pada Gambar 6. Berdasarkan Gambar 4 dan 5, *massa* dan *mikrokalsifikasi* dikenali dengan baik dengan menggunakan batas bawah 120 dan batas atas 240.

Langkah berikutnya adalah *histogram equalization*. *Histogram equalization* yaitu memetakan gambar *input* ke gambar *output* sehingga nilai-nilai abu-abu pada gambar *output* merata [9]. Hasil *Histogram Equalization* ditunjukkan pada Gambar 7.

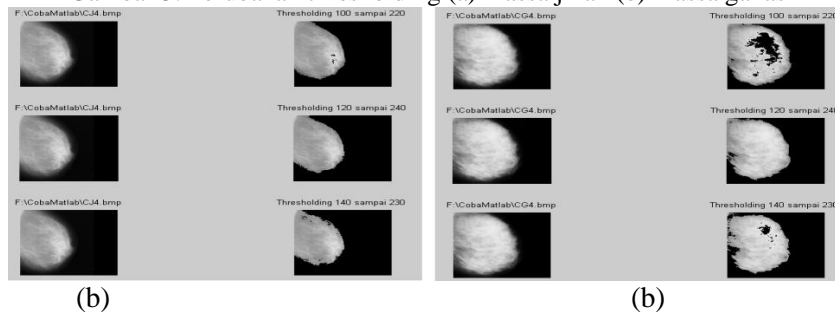
Setelah *preprocessing*, langkah selanjutnya adalah fitur ekstraksi. Hasil ekstraksi fitur, yaitu koefisien energi 5000 menghasilkan 36 energi, koefisien energi 1000 menghasilkan 165 energi, koefisien energi 500 menghasilkan 324 energi, dan koefisien energi 100 menghasilkan 1602 energi. Energi tersebut yang akan digunakan untuk input dalam ANMBP. *Arsitektur ANMBP* menggunakan input layer sebanyak energi yang dihasilkan, hidden layer yang digunakan sebanyak 80 node, dan output layer yang digunakan sebanyak 2 node.



Gambar 4 Diagram blok sistem.



Gambar 5. Perubahan thresholding (a) massa jinak (b) massa ganas



Gambar 6. Perubahan thresholding (a) mikrokalsifikasi jinak (b) mikrokalsifikasi ganas


Skenario uji coba yang dilakukan, yaitu uji coba pengaruh koefisien energi untuk kategori normal dan tidak normal, kategori massa dan mikrokalsifikasi, kategori jinak dan ganas pada massa dan mikrokalsifikasi, dan uji coba neural network berdasarkan energi komputasi yang terbaik dari masing-masing kategori.

**Kategori normal dan tidak normal**

Uji coba menggunakan berbagai macam energi, yaitu 5000, 1000, 500 dan 100. Hasil klasifikasi dapat dilihat pada Tabel 1. Berdasarkan Tabel 1, menunjukkan bahwa hasil terbaik diperoleh dengan menggunakan 100 energi dengan error 0.00097133 pada epoch ke 199.

**Kategori massa dan mikrokalsifikasi**

Uji coba menggunakan berbagai macam energi, yaitu 5000, 1000, 500 dan 100. Hasil klasifikasi dapat dilihat pada Tabel 2. Berdasarkan Tabel 2, menunjukkan bahwa hasil terbaik diperoleh dengan menggunakan 1000 energi dengan error 0.00099677 pada epoch ke 574.



Gambar 7. Perubahan histogram equalization

Tabel 1. Hasil klasifikasi kategori normal dan tidak normal

Koefisien	Error	Epoch	Normal	Tidak Normal
			(%)	(%)
100	0.00097133	199	70	75
500	0.00098277	330	62.5	75
1000	0.00099889	818	62.5	70.8333
5000	0.00098482	1624	55	66.6667

Tabel 2. Hasil klasifikasi kategori massa dan mikrokalsifikasi

Koefisien	Error	Epoch	Massa (%)	Mikrokalsifikasi (%)
100	0.00099062	148	68.75	62.5
500	0.0009405	254	68.75	62.5
1000	0.00099677	574	62.5	75
5000	0.00099346	1358	43.75	75

Tabel 3. Hasil klasifikasi kategori massa jinak dan massa ganas

Koefisien	Error	Epoch	Mikrokalsifikasi Jinak (%)	Mikrokalsifikasi Ganas (%)
100	0.00098501	82	75	75
500	0.00099339	218	75	75
1000	0.00099992	424	75	75
5000	0.00096204	666	100	75

Tabel 4. Hasil klasifikasi kategori massa jinak dan massa ganas

Koefisien	Error	Epoch	Massa Jinak (%)	Massa Ganas (%)
100	0.00092874	117	70	83.3333
500	0.00069893	269	70	66.6667
1000	0.00097936	560	70	66.6667
5000	0.00099873	1433	50	66.6667

Tabel 5 Hasil perbandingan ANMBP dan neural network

	Kategori Normal dan tidak Normal			
	Epoch	Error	Akurasi	
			Normal (%)	Tidak Normal (%)
ANMBP	199	0.00097133	70	75
Neural Network	1067	0.000998519	75	20
	Kategori Massa dan Mikrokalsifikasi			
	Epoch	Error	Akurasi	
			Massa (%)	Mikrokalsifikasi (%)
ANMBP	574	0.00099677	62.5	75
Neural Network	2891	0.00099902	62.5	25
	Kategori Massa Jinak dan Massa Ganas			
	Epoch	Error	Akurasi	
			Jinak (%)	Ganas (%)
ANMBP	117	0.00092874	70	83
Neural Network	796	0.000996964	50	83
	Kategori Mikrokalsifikasi Jinak dan Mikrokalsifikasi Ganas			
	Epoch	Error	Akurasi	
			Jinak (%)	Ganas (%)
ANMBP	666	0.00096204	100	75
Neural Network	1000000	0.0546007	25	75

### Kategori massa jinak dan massa ganas

Uji coba menggunakan berbagai macam energi, yaitu 5000, 1000, 500 dan 100. Hasil klasifikasi dapat dilihat pada Tabel 3. Berdasarkan Tabel 3, menunjukkan bahwa hasil terbaik diperoleh dengan menggunakan 5000 energi dengan error 0.00096204 pada epoch ke 666.

### Kategori mikrokalsifikasi jinak dan ganas

Uji coba menggunakan berbagai macam energi, yaitu 5000, 1000, 500 dan 100. Hasil klasifikasi dapat dilihat pada Tabel 4. Berdasarkan Tabel 4, menunjukkan bahwa hasil terbaik diperoleh dengan menggunakan 100

energi dengan error 0.00099873 pada epoch ke 1433.

### Perbandingan dengan neural network

Berdasarkan uraian diatas, ujicoba dengan menggunakan neural network untuk tiap-tiap kategori adalah kategori normal dan tidak normal menggunakan 100 koefisien per fitur, massa menggunakan 100 koefisien per fitur, mikrokalsifikasi menggunakan 5000 koefisien per fitur. Berdasarkan hasil uji coba, diperoleh epoch dan error yang dihasilkan antara ANMBP lebih kecil dari pada epoch pada *neural network* sehingga untuk mencapai konvergen ANMBP lebih cepat dibandingkan *neural network*.

Akurasi dari masing-masing kategori ANMBP lebih besar daripada *neural network*. ANMBP dapat mempercepat konvergen dan meningkatkan akurasi untuk mengklasifikasi data mammogram. Tabel 5 merepresentasikan dari hasil ujicoba perbandingan *neural network* dan ANMBP.

### III. SIMPULAN

Berdasarkan hasil uji coba yang dilakukan dapat disimpulkan bahwa : Ekstraksi fitur yang digunakan untuk klasifikasi data mammogram menggunakan transformasi wavelet. Ekstraksi fitur menghasilkan vektor fitur yang akan digunakan untuk proses klasifikasi. Vektor fitur yang dihasilkan untuk koefisien energi 5000 sebanyak 36 energi, koefisien energi 1000 sebanyak 165 energi, koefisien energi 500 sebanyak 324 energi dan koefisien energi 100 sebanyak 1602 energi. Koefisien energi 100 dapat digunakan untuk mengenali massa dengan baik karena ukuran massa yang besar dan berbentuk halus sehingga sulit untuk dikenali dengan koefisien energi yang besar. Koefisien energi 5000 dapat digunakan untuk mengenali *mikrokalsifikasi* dengan baik karena ukuran *mikrokalsifikasi* yang kecil-kecil dan berbentuk cabang-cabang sehingga mudah dikenali dengan menggunakan koefisien energi yang besar .

Klasifikasi dengan menggunakan ANMBP. Hasil *Training* untuk massa menggunakan data sebanyak 24 gambar *massa*, iterasi berhenti pada epoch ke-117 dengan error sebesar 0.00092874 dan untuk *mikrokalsifikasi* menggunakan 16 gambar *mikrokalsifikasi*, iterasi berhenti pada epoch ke-666 dengan error sebesar 0.00096204. Hasil *testing* menggunakan 10 gambar *massa* jinak dengan 6 gambar *massa* ganas, diperoleh akurasi sebesar 70% untuk *massa* jinak dan 83.3% untuk *massa* ganas sedangkan dengan menggunakan 4 gambar *mikrokalsifikasi* jinak dengan 4 gambar *mikrokalsifikasi* ganas, diperoleh akurasi sebesar 100% untuk *mikrokalsifikasi* jinak dan 75% untuk *mikrokalsifikasi* ganas. ANMBP menggunakan learning data yang adaptif dan penjumlahan error linier dan error non linier sehingga dapat mempercepat konvergen dan dapat meningkatkan akurasi dalam mengklasifikasikan data mammogram.

### IV. DAFTAR PUSTAKA

- [1] Anonim 1, 2008, *Female Breast-Cancer Pictures & Images (Cancer - Breast)*, <http://www.AllRefer.Health.com>, akses Maret 2008.
- [2] Benhrehbruch, C.P., Petroudi, S., Bond, S., 2002, Image Filtering techniques for medical image post-processing, Medical Vision Laboratory, Engineering Science, Oxford University, USA.
- [3] Roberts, M., Kahn E., & Haddawy, P. (1995). Development of a Bayesian network for diagnosis of breast cancer. IJCAI-95 workshop on building probabilistic networks.
- [4]. Arun, K. (2001). Computer vision fuzzy-neural systems. Englewood Cliffs, NJ: Prentice-Hall.
- [5] Michie, Spiegelhalter, & Taylor. (1994). Automatic detection of clustered microcalcifications using wavelet. The third international workshop on digital mammography, Chicago.
- [6] Rafayah mousa, Qutaishat Munib, Abdallah Mousa. (2005), Breast Cancer Diagnosis System Based on Wavelet Analysis and Fuzzy Neural, Jordan, pp. 713–723.
- [7] Kathirvalavakumar T, dan Subavathi S. J. (2009) Neighborhood based modified backpropagation algorithm using adaptive learning parameters for training feedforward neural networks. Jurnal Neurocomputing 72 3915–3921 Elsevier Science Ltd.
- [8] Pane, M., 2000, *Aspek Klinis dan Epidemiologi Penyakit Kanker Payudara*, Program Pasca Sarjana Ilmu Kesehatan Masyarakat Universitas Indonesia, Tinjauan Pustaka, Jakarta.
- [9] Gonzalez R. C, Richard E.Woods.(2002).Digital Image Processing, second edition, Paerson education, Boston.