

KLASIFIKASI MRI OTAK MENGGUNAKAN JARINGAN SYARAF TIRUAN BERDASARKAN DATA WAVELET YANG DIREDUKSI DENGAN NCMF

Lastri Widya Astuti¹⁾, Handayani T²⁾

^{1, 2)} Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember
Kampus ITS Keputih Sukolilo Surabaya 60111
e-mail: lastriwidya@yahoo.com

Abstrak

Magnetic Resonance Imaging (MRI) merupakan salah satu cara pemeriksaan diagnostik dalam ilmu kedokteran, khususnya radiologi yang menghasilkan gambaran potongan tubuh manusia secara transversal, koronal, sagital dan paraaksial. Keuntungan yang paling penting dari pencitraan magnetic resonance adalah menerapkan teknik non invasif, yang digunakan untuk memvisualisasikan struktur internal dan fungsi terbatas tubuh secara rinci. Namun pada kenyataannya hasil citra yang dihasilkan oleh MRI memiliki dimensi tinggi, sehingga menyebabkan kesulitan pada proses pengklasifikasian gangguan atau kerusakan jaringan otak. Pendekatan yang mungkin dilakukan adalah dengan mengurangi dimensi data sebelum proses klasifikasi tanpa mengurangi arti dari data. Oleh karena itu, dalam makalah ini diajukan penerapan metode gabungan yaitu: Wavelet yang akan digunakan pada proses ekstraksi fitur dan untuk proses reduksi dimensi akan digunakan metode Normalized Compression Non-Negative Matrix Factorization (NCMF). Matrik kompresi yang dihasilkan dari proses reduksi selanjutnya akan menjadi input bagi proses klasifikasi menggunakan metode Adaptive Neighborhood Modified Backpropagation (ANMBP). Penelitian ini mampu mengintegrasikan antara teknik ekstraksi fitur, reduksi dimensi serta teknik klasifikasi yang diusulkan, pengujian dengan menggunakan dataset MRI otak yang telah ditetapkan menghasilkan nilai rata – rata 91,25% untuk tingkat keakurasiannya.

Kata kunci: *Magnetic Resonance Imaging (MRI), Normalized Compression Non-Negative Matrix Factorization (NCMF), Klasifikasi, Wavelet, Adaptive Neighborhood Modified Backpropagation*

1. PENDAHULUAN

Magnetic Resonance Imaging (MRI) merupakan metode pencitraan medis yang sering menjadi pilihan ketika deliniasi jaringan lunak diperlukan. MRI merupakan salah satu kemajuan yang sangat penting dalam bidang penelitian yang bersifat klinis [1]. Hasil pencitraan yang dihasilkan oleh MRI memberikan kontras yang lebih baik dibandingkan dengan Computed Tomography (CT) [2], sehingga dapat digunakan untuk proses pengklasifikasian jaringan otak manusia [3].

*Klasifikasi adalah proses untuk menemukan model atau fungsi yang menjelaskan atau membedakan konsep atau kelas data, dengan tujuan untuk dapat memperkirakan kelas dari suatu objek yang labelnya tidak diketahui. Klasifikasi melibatkan model pembelajaran yang memetakan data percobaan ke dalam satu atau beberapa kelas yang telah didefinisikan. Pada penelitian MRI terdahulu menunjukkan bahwa klasifikasi pada otak manusia telah dilakukan dengan menggunakan teknik terawasi seperti jaringan syaraf tiruan dan *support vector machine* (SVM) [4], serta teknik tidak terawasi seperti *self organization map* (SOM) dan *fuzzy c means* [5]. Selain itu penggunaan metode gabungan untuk klasifikasi gangguan atau kerusakan otak juga telah banyak dikembangkan [6,7].*

*Rendahnya tingkat akurasi proses klasifikasi seringkali disebabkan karena tingginya dimensi data. Pendekatan yang mungkin untuk mengatasi masalah ini adalah dengan mengurangi dimensi data sebelum proses klasifikasi tanpa mengurangi arti dari data. Makalah ini mengusulkan penerapan metode gabungan untuk klasifikasi gangguan atau kerusakan pada otak manusia dengan menggunakan Metode *Discrete Wavelet Transformation* (DWT) untuk proses ekstraksi fitur, Metode *Normalized Compression Non-Negative Matrix Factorization* (NCMF) untuk proses reduksi dimensi dan Metode *Adaptive Neighborhood Modified Backpropagation* (ANMBP) untuk proses klasifikasi. Penerapan metode gabungan ini terbukti dapat mereduksi dimensi data MRI otak dengan tetap memperhatikan semua informasi berkaitan dengan kelas yang ada serta mampu mengklasifikasikan kelainan / kerusakan pada otak manusia menggunakan data MRI dengan kategori Normal, Alzheimer, Carcinoma dan Glioma dengan hasil akurasi klasifikasi yang signifikan.*

2. TINJAUAN PUSTAKA

2.1 Wavelet

Wavelet adalah sebuah fungsi matematik yang digunakan untuk membagi sebuah fungsi waktu sinyal berkelanjutan menjadi beberapa komponen frekuensi yang berbeda dan mempelajari setiap komponen dengan resolusi yang cocok dengan skala. [8]. Wavelet memproses data dalam skala atau resolusi yang berbeda. Jika

sinyal diperspektifkan sebagai sebuah 'jendela' yang lebar maka akan memiliki banyak sekali informasi di dalamnya. Sebaliknya jika kita melihat sinyal sebagai 'jendela' yang kecil, maka akan didapatkan fitur yang lebih kecil.

Transformasi merupakan suatu proses pengubahan data menjadi bentuk lain sehingga mudah dianalisa. Salah satu contoh transformasi adalah transformasi *wavelet*. Transformasi *wavelet* merupakan generalisasi dari transformasi Fourier [8]. Transformasi *wavelet* merupakan proses mengubah sinyal ke dalam berbagai gelombang *wavelet* asli (*mother wavelet*) dengan berbagai pergeseran dan penyekalaan. Dengan demikian faktor skala memegang peranan yang sangat penting.

Setiap *wavelet* dengan simbol Ψ_{ab} didefinisikan oleh fungsi skala dan fungsi translansi dari *wavelet* induk Ψ seperti pada persamaan 2.1 berikut:

$$\Psi_{ab}(x) = \frac{1}{\sqrt{a}} \Psi \left(\frac{x-b}{a} \right), \quad (1)$$

Dimana a dan b adalah integer yang merepresentasikan skala (level) dan translasi (lokasi). Untuk mendefinisikan transformasi *wavelet*, maka digunakan *wavelet* yang didefinisikan pada (2.1) diatas sebagai fungsi dasar dan dinotasikan sebagai berikut:

$$w_{\frac{b}{a}} = \frac{1}{\sqrt{a}} \int f(x) \Psi \left(\frac{x-b}{a} \right) dx, \quad (2)$$

Dimana $w_{\frac{b}{a}}$ disebut sebagai *wavelet* koefisien. Proses pemanfaatan persamaan ini disebut dengan dekomposisi *wavelet* dengan menggunakan *wavelet* Ψ_{ab} . Sedangkan Fungsi skala ditunjukkan pada persamaan dibawah ini

$$\varphi_{j,k}(X) = 2^{2^j} \varphi(2^j x - k), \quad (3)$$

2.2 Normalized Compression Non Negative Matrix Factorization (NCMF)

Metode *Non Negative Matrix Factorization* (NMF) merupakan metode reduksi dimensi yang dapat digunakan untuk mereduksi dimensi data dengan pendekatan faktorisasi matrik non negatif. Pada metode NMF, matrik data X akan diuraikan menjadi perkalian matrik non negatif C dan M . Metode ini mampu mereduksi dimensi data dengan memperhitungkan informasi kelas. Akan tetapi metode NMF memiliki kelemahan yaitu aturan perubahan matrik C dan M merupakan fungsi dari C dan M sehingga pada algoritmanya harus menginisialisasi kedua matrik itu secara simultan. Metode *Normalized Compression Non Negative Matrix Factorization* (NCMF) merupakan metode pengembangan dari NMF [9].

Normalized Compression Non Negative Matrix Factorization (NCMF) akan memfaktorisasi matriks X_{ij} yang akan diuraikan menjadi perkalian matrik C_{ik} dan M_{kj} . Matriks X_{ij} merupakan matrik data dengan kolom merupakan dimensi feature sedangkan baris merupakan dimensi obyek. Matriks X ternormalisasi pada setiap kolomnya. Hasil faktorisasi akan menghasilkan C yang merupakan matrik kompresi dan M merupakan matrik proyeksi.

Pada metode ini, batasan normalisasi dimasukkan kedalam fungsi obyektif untuk menjamin bahwa matrik C dan M yang dihasilkan merupakan matrik yang ternormalisasi Fungsi obyektif adalah sebagaimana berikut

$$F(C, M) = \min_{C \geq 0, M \geq 0} \sum_{ij} (X_{ij} \log \frac{X_{ij}}{(CM)_{ij}} - X_{ij} + (CM)_{ij}) + u(\sum_i C_{ik} - 1) + v(\sum_k M_{kj} - 1) \quad (4)$$

Dimana $\sum_i X_{ij} = 1$, dengan u dan v merupakan dua parameter yang bernilai positif. Sedangkan, aturan perubahan matrik C dan M adalah sebagaimana berikut

$$C_{ik} = \frac{\sum_j X_{ij} M_{kj}}{\sum_j M_{kj}}, \quad (5)$$

$$M_{kj} = \sum_i \left(\frac{x_{ij}}{\sum_k c_{ik} M_{kj}} \right) c_{ik} M_{kj} \quad (6)$$

2.3 Adaptive Neighborhood Modified Backpropagation (ANMBP)

Untuk mempercepat pembelajaran dan menjamin tercapainya global maksimum Kathivalvakumar dkk. [10] memperkenalkan algoritma ANMBP. Prinsip dari ANMBP adalah penggunaan linier dan non linier error untuk optimalisasi, parameter pembelajaran yang adaptif, dan perubahan bobot berdasarkan neighborhood. Algoritma tersebut mampu mempercepat konvergensi dengan mengurangi iterasi, terhindar dari lokal minimum, dan pengurangan memori.

Pada algoritma ANMBP output linier dan non linier pada masing masing neuron dihasilkan dengan rumus yang sama dengan algoritma backpropagation yaitu :

$$u_j^s = \sum_{i=1}^n w_{ji}^s y_i^{s-1} \quad (7)$$

$$f(u_j^s) = \frac{1}{(1 + e^{-u_j^s})} = y_j^s \quad (8)$$

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. Yang berbeda dari ANMBP adalah perhitungan error (E) yang merupakan penjumlahan dari kuadrat error linier dan non linier dari output.

$$E_p = \sum_{j=1}^n \frac{1}{2} (e_{1j}^s)^2 + \sum_{j=1}^n \frac{1}{2} \lambda (e_{2j}^s)^2 \quad (9)$$

dimana λ adalah koefisien bobot , error nonlinier e_2 dan error linier e_1 diperoleh dari :

$$e_{1j}^s = d_j^s - y_j^s \quad (10)$$

$$e_{2j}^s = ld_j^s - u_j^s \quad (11)$$

$$ld_j^s = f^{-1}(d_j^s) \quad (12)$$

Dimana d adalah output yang diharapkan dan y adalah output yang dihasilkan. Sehingga perubahan bobot pada layer output adalah:

$$\Delta w_{ji}^s = -\mu \frac{\partial E}{\partial w_{ji}^s} \quad (13)$$

$$\begin{aligned} \Delta w_{ji}^s &= \mu e_{1j}^s \frac{\partial y_j^s}{\partial w_{ji}^s} + \mu \lambda e_{2j}^s \frac{\partial u_j^s}{\partial w_{ji}^s} \\ \Delta w_{ji}^s &= \mu e_{1j}^s \frac{\partial y_j^s}{\partial u_j^s} \frac{\partial u_j^s}{\partial w_{ji}^s} + \mu \lambda e_{2j}^s y_i^{s-1} \\ \Delta w_{ji}^s &= \mu e_{1j}^s f'(u_j^s) y_i^{s-1} + \mu \lambda e_{2j}^s y_i^{s-1} \end{aligned} \quad (14)$$

Error linier dan non linier pada hidden layer (L) adalah:

$$e_{1j}^L = \sum_{r=1}^{n_{L+1}} f'(u_r^{L+1}) e_{ir}^{L+1} w_{rj}^{L+1} \quad (15)$$

$$e_{2j}^L = f^1(u_j^L) \sum_{r=1}^{n_{L+1}} e_{2r}^{L+1} w_{rj}^{L+1} \quad (16)$$

Sehingga perubahan bobot pada hidden layer adalah :

$$\Delta w_{ji}^L = \mu e_{1j}^L y_i^{L-1} f'(u_j^L) + \mu \lambda e_{2j}^L y_i^{L-1} \quad (17)$$

Parameter learning μ dan $\mu\lambda$ diganti dengan parameter adaptive η' dan μ'

$$\eta' = \frac{\mu \|e_{1j}\|^2}{\|f'(u_j) y_i^{s-1} e_{1j}\|^2 + \varepsilon} \quad (18)$$

$$\mu' = \frac{\lambda \|e_{1j}\|^2}{\|f'(u_j)y_i^{s-1}e_{1j}\|^2 + \varepsilon} \quad (19)$$

Dimana μ , λ adalah konstanta dengan nilai kecil positif dan ε konstanta dengan nilai kecil positif untuk menjaga ketidakstabilan ketika error menuju 0. Sehingga perubahan bobot pada layer output dan layer hidden menjadi :

$$\Delta w_{ji}^s = \eta' e_{1j}^s f'(u_j^s) y_i^{s-1} + \mu' e_{2j}^s y_i^{s-1} \quad (20)$$

$$\Delta w_{ji}^L = \eta' e_{1j}^L f'(u_j^L) y_i^{L-1} + \mu' e_{2j}^L y_i^{L-1} \quad (21)$$

2.4 Akurasi

Perhitungan akurasi sebagai tolak ukur evaluasi dalam sistem dapat diperoleh dengan persamaan 22. Akurasi adalah probabilitas bahwa tes diagnostik dilakukan dengan benar.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (22)$$


3. METODE PENELITIAN

3.1 Dataset

Dataset yang digunakan bersumber dari *Harvard Medical School (Repository <http://med.harvard.edu/AANLIB/>)*. Dengan jumlah data sebanyak 32 yang terdiri dari 24 data citra abnormal dan 8 data citra normal.

3.2 Desain Model Sistem

Pada bagian ini akan dipaparkan mengenai alur proses yang terjadi dalam sistem untuk menghasilkan output. Penentuan desain model sistem ini akan memberikan gambaran mengenai bagaimana penelitian ini dilaksanakan.



Gambar 1. Model Klasifikasi MRI Otak

3.3 Ekstraksi Fitur

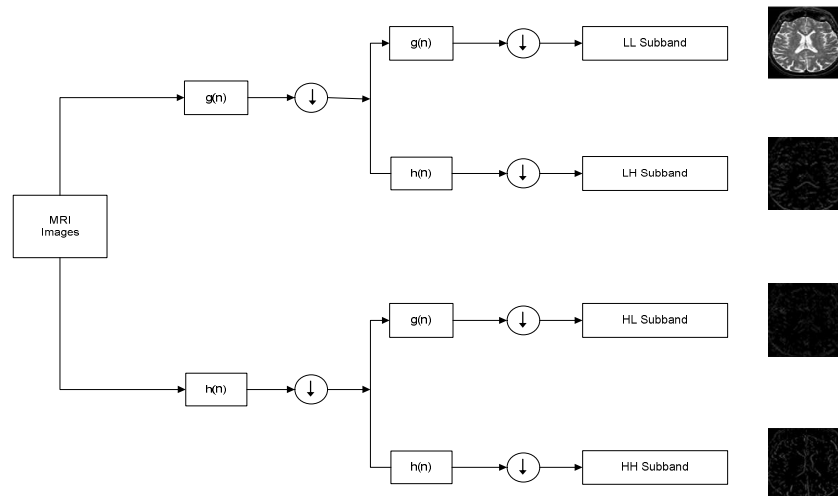
Model algorithma yang diusulkan untuk ekstraksi fitur dalam penelitian ini menggunakan *Transformasi Wavelet Diskrit (DWT)* yang merubah koefisien sebagai vektor fitur. Citra asli adalah proses sepanjang arah x dan y, dengan $h(n)$ dan $g(n)$ filter yang merupakan representasi baris dari gambar asli. Sebagai hasil dari transformasi ini ada gambar 4 sub-band (LL, LH, HH, HL) pada setiap skala. Sub-band LL gambar hanya digunakan untuk perhitungan DWT pada skala berikutnya. Untuk menghitung fitur *wavelet* dalam tahap pertama, koefisien *wavelet* dihitung untuk LL sub-band menggunakan fungsi haar wavelet. Berikut adalah algorithma dari proses *wavelet*:

- | | |
|---|--|
| 1 | Perulangan $i = 1$ sampai N |
| 2 | Pembacaan citra input |
| 3 | Mengubah ukuran citra |
| 4 | Input koefisien wavelet dalam matriks X dengan ukuran $[M \times N]$ |
| 5 | Lakukan iterasi untuk step 2,3,4 |
| 6 | Menggabungkan koefisien fitur |

Gambar 2. Algoritma Wavelet

Proses transformasi dilakukan pada baris terlebih dahulu, kemudian dilanjutkan transformasi pada kolom. Koefisien – koefisien yang dihasilkan melalui transformasi *wavelet* dapat dipilih untuk menjadi fitur suatu citra. Pada penelitian ini proses transformasi dilakukan sebanyak 3 tingkatan. Data citra asli yang berukuran 256×256

di ekstraksi menggunakan *wavelet* menjadi citra berukuran 32 x 32. Data citra MRI yang berukuran 32 x 32 selanjutnya akan dijadikan citra input pada proses reduksi fitur.



Gambar 3. Transformasi Wavelet MRI Otak

3.4 Reduksi Fitur

Model algoritma yang diusulkan dalam melakukan reduksi dimensi data dalam penelitian ini adalah Algoritma *Normalized Compression Non Negative Matrix Factorization* (NCMF). Adapun algoritma proses reduksi dimensi adalah sebagaimana berikut: Baris 1 membaca ukuran matrik X dengan jumlah baris menunjukkan jumlah obyek dan jumlah kolom menunjukkan jumlah feature. Pada baris 2 normalisasi setiap kolom pada matrik X. Baris 3 inialisasi matrik M secara acak dengan masing-masing kolom ternormalisasi. Baris 7 dan 8 melakukan perubahan pada matrik C dan M secara interaktif.

-
- | | |
|---|--|
| 1 | Input : matrik data set X, ukuran dimensi r dan jumlah iterasi l. |
| 2 | Output: matrik kompresi C dan matrik proyeksi M. |
| 3 | Input n: jumlah obyek, dan m : dimensi feature, [n,m] = size(X) |
| 4 | Normalisasi X, $X_{ij} \leftarrow \frac{x_{ij}}{\sum_i x_{ij}}$ |
| 5 | Inialisasi M dengan ukuran r x m |
| 6 | Perulangan 1 sampai l |
| 7 | Perbaharui C, $C_{ik} \leftarrow \frac{\sum_j X_{ij} M_{kj}}{\sum_j M_{kj}}$ |
| 8 | Perbaharui M, $M_{kj} \leftarrow \sum_i (\frac{X_{ij}}{\sum_k M_{kj} C_{ik}} C_{ik}) M_{kj}$ |
| 9 | Akhiri Perulangan |
-

Gambar 4. Algoritma NCMF

Matriks X akan difaktorisasi menjadi matrik C dan M. Data citra MRI hasil ekstraksi fitur yang berukuran 32 x 32 akan direduksi dengan menggunakan NCMF sehingga menghasilkan matriks berukuran 7 x 32. Hasil reduksi fitur akan digunakan sebagai input pada proses klasifikasi.

3.5 Klasifikasi

Model algoritma pengklasifikasian yang digunakan dalam penelitian ini adalah *Adaptive Neighborhood Modified Backpropagation* (ANMBP). Arsitektur *Adaptive Neighborhood Modified Backpropagation* (ANMBP) yang akan digunakan dalam penelitian ini adalah terdiri dari satu layer input, satu layer hidden dan satu layer output. Adapun algoritma *Adaptive Neighborhood Modified Backpropagation* (ANMBP), adalah :

-
- | | |
|---|--|
| 1 | Input: jumlah neuron layer input, hidden, output, dan ketetanggaan |
| 2 | Output : bobot |
| 3 | Inialisasi bobot di layer input dan layer hidden secara acak |
| 4 | While kondisi belum berhenti do |
| 5 | Pilih ketetanggaan secara acak |
| 6 | Perulangan =1 to jumlah pola do |
-

7	Hitung setiap neuron di layer hidden dan layer output
8	Hitung error dan perubahan bobot pada layer output
9	Hitung error dan perubahan bobot pada layer hidden
10	Ubah bobot neuron di layer output dan layer hidden dari ketetapan yang dipilih
11	Akhiri perulangan
12	Evaluasi error dengan bobot yang baru
13	Akhiri While

Gambar 5. Algoritma *Adaptive Neighborhood Modified Backpropagation* (ANMBP).

4. HASIL DAN PEMBAHASAN

Berdasarkan rangkaian proses diatas dilakukan uji coba mulai dari proses ekstraksi fitur, proses reduksi dimensi, dan proses klasifikasi untuk menghasilkan hasil klasifikasi yang valid. Uji coba pertama menguji pengaruh *learning rate* yang dilakukan secara heuristik untuk mendapatkan hasil yang optimal. Uji coba *learning rate* dimaksudkan untuk melihat waktu yang dibutuhkan untuk mencapai konvergensi. Tabel 1 memberikan rangkuman hasil uji coba yang dilakukan pada *learning rate*. Nilai optimal diperoleh pada $\mu = 0.1$, $\lambda = 0.00001$ dan $\varepsilon = 0.1$ dengan nilai akurasi 100% untuk *testing* menggunakan data *testing*.

Tabel 1 Evaluasi hasil uji coba pengaruh *learning rate*

<i>Learning rate</i>	Akurasi (%)	Waktu (menit)
0.1	100	14.5
0.5	75	9
0.8	75	8.5

Semakin besar *learning rate* maka rentang untuk menentukan perubahan bobot semakin besar sehingga sering terjebak pada kondisi lokal minimum.

Uji coba kedua mencari komposisi jumlah *hidden node* yang optimal dengan menggunakan nilai μ , λ , ε yang diperoleh pada pengujian pertama. Uji coba komposisi *hidden node* diperlukan karena *hidden node* mengombinasikan semua masukan berdasarkan bobot dari relasi yang terhubung, melakukan kalkulasi dan memberikan keluaran untuk layer berikutnya. Tabel 2 memberikan rangkuman hasil uji coba yang dilakukan untuk mencari *single hidden layer* yang paling optimum. Komposisi *hidden layer* terbaik diperoleh pada *hidden node* = 351 dengan nilai akurasi 100% untuk *testing* menggunakan data *testing*.

Tabel 2. Evaluasi hasil uji coba komposisi *hidden node*

Jumlah node	Akurasi (%)	Waktu (menit)
[224-100-4]	75	14.5
[224-200-4]	87	39
[224-351-4]	100	14.5

Pada uji coba ketiga akan dilihat pengaruh L terhadap nilai akurasi dengan nilai $r = 7$. Uji coba L diperlukan untuk melihat banyaknya iterasi (L) yang dibutuhkan untuk update matriks M, hingga mencapai nilai M yang optimum. Uji coba akan dilakukan pada nilai L = 1, L = 2, L = 3. Tabel 3 memberikan rangkuman hasil uji coba pengaruh L pada $r = 7$. Nilai L = 2 menghasilkan nilai rata – rata 91.25 % untuk akurasi.

Tabel 3. Evaluasi hasil uji coba pengaruh L pada $r = 7$

Nilai L	Akurasi (%)	Waktu (detik)
L = 1, $r = 7$	83.75	7253.11
L = 2, $r = 7$	91.25	7169.70
L = 3, $r = 7$	75	6391.06

Nilai akurasi dan waktu merupakan nilai rata – rata dari training yang dilakukan sebanyak 10 kali pada masing – masing L dengan $r = 7$. Dari hasil uji coba menunjukkan nilai L sangat berpengaruh pada hasil akurasi dan lamanya waktu training.

Nilai L juga berpengaruh pada waktu eksekusi untuk proses ekstrasi fitur dan waktu eksekusi untuk proses reduksi fitur. Tabel 4 menyajikan perbandingan waktu eksekusi untuk proses ekstrasi fitur dan reduksi fitur untuk L = 1, L = 2, L = 3 dengan $r = 7$

Tabel 4. Perbandingan waktu eksekusi ekstraksi f L pada $r = 7$

Nilai L	Waktu Eksekusi	Waktu Eksekusi
	Proses Ekstraksi Fitur (detik)	Proses Reduksi Fitur (detik)
L = 1, r = 7	2.91	2.44
L = 2, r = 7	2.90	2.61
L = 3, r = 7	2.90	2.80

5. KESIMPULAN

Dari hasil rangkaian uji coba dan analisa penelitian yang dilakukan terhadap metode yang diusulkan. Kesimpulan tersebut adalah sebagai berikut :

1. Metode gabungan yang diusulkan mampu mengklasifikasikan gangguan / kerusakan pada jaringan otak dengan menggunakan metode wavelet untuk ekstraksi fitur, *Normalized Compression Non Negative Matrix Factorization* (NCMF) untuk proses reduksi dimensi serta *Adaptive Neighborhood Modified Backpropagation* (ANMBP) untuk proses klasifikasi dengan nilai akurasi tertinggi sebesar 100 %
2. Pada proses *training* ANMBP sangat dipengaruhi nilai μ , λ , dan ε . Pada penelitian ini nilai yang optimal adalah $\mu = 0.1$, $\lambda = 0.00001$, dan $\varepsilon = 0.1$.
3. Pada percobaan terhadap jumlah unit pada *hidden layer*, akurasi terbesar 100% diperoleh dengan jumlah unit sebanyak 351 buah.
4. Jumlah L (iterasi) memiliki pengaruh yang signifikan terhadap proses ekstraksi fitur dan reduksi fitur.
5. Nilai $r = 7$ dengan L = 2 memiliki rata – rata nilai akurasi terbaik sebesar 91.25%.

DAFTAR PUSTAKA

- [1] F. Gorunescu. (2007), "Data mining techniques in computer-aided diagnosis: Non-invasive cancer detection", *PWASET* 25, hal 427–430.
- [2] Hynynen, K. (2010), "MRI-guided focused ultrasound treatments", *Ultrasonics*, Vol. 50, No. 2, hal 221-229.
- [3] L.M. Fletcher-Heath, L.O. Hall, D.B. Goldgof, F.R. Murtagh. (2001), "Automatic segmentation of non-enhancing brain tumors in magnetic resonance images", *Artif. Intell. Med.* 21, hal 43–63.
- [4] S. Chaplot, L.M. Patnaik, N.R. Jagannathan. (2006), "Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network", *Biomed. Signal Process*, Control 1, hal 86–92.
- [5] M. Maitra, A. Chatterje. (2007), "Hybrid multiresolution slanted transform and fuzzy c means clustering approach for normal-pathological brain MR image segregation", *Med. Eng. Phys.*
- [6] El-Dahshan, E.-S. A., T. Hosny, and A.-B. M. Salem. (2010), "Hybrid intelligent techniques for MRI brain images classification," *DigitalSignal Processing*, Vol. 20, No. 2, hal 433-441.
- [7] Y. Zhang, Z. Dong, L. Wu, S. Wang. (2011), " A hybrid method for MRI brain image classification", *Experts System with Application*, 38, hal 10049-10053
- [8] Gonzalez R. C, Richard E.Woods. (2002), *Digital Image Processing*, second edition, *Paerson education*, Boston.
- [9] Zhu, Z., Guo, Y.F., Zhu, X., Xue, X. (2010), "Normalized dimensionality reduction using nonnegative matrix factorization", *Journal of Neurocomputing*, Elsevier.
- [10] T. Kathirvalavakumar, T., Subavathi, S.J. (2009), "Neighborhood based modified backpropagation algorithm using adaptive learning parameters for training feedforward neural networks", *Journal of Neurocomputing*, Elsevier

Harvard Medical School, Web, data available at <http://med.harvard.edu/AANLIB>