

## PERBANDINGAN METODE SOM (SELF ORGANIZING MAP) DENGAN PEMBOBOTAN BERBASIS RBF (RADIAL BASIS FUNCTION)

Andharini Dwi Cahyani<sup>1</sup>, Bain Khusnul Khotimah<sup>2</sup>, Rafil Tania Rizkillah<sup>3</sup>

<sup>1,2,3</sup> Program Studi Teknik Informatika, Universitas Trunojoyo, Madura

Masuk: 16 April 2014, revisi masuk : 12 Juni 2014, diterima: 8 Juli 2014

### ABSTRACT

*In many clustering systems many methods was used to cluter-ization, one of which is the SOM (Self Organizing Maps). In our study we used two approaches. The first approach was a lawyer-cluster's using SOM-RBF used in the training data and could be expected to result in better cluster. And the second approach clustering was used of SOM. Comparison of both methods is based on the application of the data derived from the dataset movielens.org site. Comparative assessment using three scenarios, namely the MSE as a stop condition on the running time, the MSE as the stop condition of the epoch and the learning rate, and MSE as the stop condition of the actual value of the MSE. With this running time is detected which is more rapid approach to the time span for extracting training data. Based on the results of experiments performed using 500 data, which is applied to clusters 3 and 4 lead to the conclusion that the first approach has the value of MSE is actually closer to the absolute value of MSE as compared to the second approach.*

**Keywords:** SOM, Running Time, Clustering, SOM-RBF

### INTISARI

Pada sistem *clustering* banyak metode yang digunakan untuk *cluter*-isasi, salah satunya adalah SOM (*Self Organizing Maps*). Dalam penelitian ini kami menggunakan 2 pendekatan. Pendekatan yang pertama adalah *peng-cluster-an* menggunakan SOM-RBF yang digunakan pada pelatihan data dan diduga dapat menghasilkan *cluster* yang lebih baik. Dan pendekatan kedua *peng-cluster-an* menggunakan SOM. Perbandingan kedua metode didasarkan pada penerapan pada data yang berasal dari dataset situs *movielens.org*. Penilaian perbandingan menggunakan 3 skenario, yaitu MSE sebagai kondisi stop terhadap *running time*, MSE sebagai kondisi stop terhadap *epoch* dan *learning rate*, dan MSE sebagai kondisi stop terhadap nilai MSE yang sebenarnya. Dengan *running time* tersebut terdeteksi pendekatan yang lebih cepat rentang waktunya untuk mengekstraksi data latih. Berdasarkan hasil uji coba yang dilakukan menggunakan 500 data, yang diterapkan pada 3 dan 4 *cluster* menghasilkan kesimpulan bahwa pendekatan pertama mempunyai nilai MSE sebenarnya yang lebih mendekati nilai absolut MSE dibandingkan dengan pendekatan kedua.

**Kata Kunci :** SOM, Running Time, Clustering, SOM-RBF.

### PENDAHULUAN

Sebagai sumber ilmu yang mudah didapatkan, buku tidaklah asing lagi bagi kehidupan kita. Kita dapat mengetahui segala pengetahuan dar membaca buku. Namun kesadaran terhadap minat baca di masyarakat

Indonesia masih kurang. Dapat dilihat dari perpustakaan, atau  $\text{p}$  peminjaman buku lainnya. Hanya beberapa orang yang membaca buku, serta meminjamnya. Para ahli yang melakukan penelitian, berpendapat bahwa hanya sekitar 10% masyarakat

Indonesia yang dapat mengakrabkan dirinya dengan kebiasaan membaca. Sisanya mereka sangat jarang sekali membaca.

Dalam upaya meningkatkan kesadaran minat untuk membaca buku, diperlukan adanya teknik khusus dalam hal membaca dan peminjaman buku. Yakni dengan adanya sistem yang dapat membantu seseorang mempermudah menemukan buku yang lain, yang disebut dengan sistem rekomendasi. Pada sistem perkomendasi terdapat metode yang dapat menghasilkan sebuah rekomendasi, salah satunya adalah *clustering*. Banyak metode yang digunakan untuk *clustering*, salah satunya adalah SOM (*Self Organizing Maps*).

Dalam penelitian menggunakan 2 pendekatan. Pendekatan yang pertama adalah *peng-cluster-an* menggunakan SOM-RBF yang digunakan pada pelatihan data dan diduga dapat menghasilkan *cluster* yang lebih baik. Dalam pendekatan kedua, menggunakan metode SOM, dengan interaksi fitur didalamnya menggunakan *unsupervised learning*. Perbandingan kedua metode didasarkan pada penerapan pada data latih yang berasal dari database. Penilaian perbandingan menggunakan *running time*. Dimana dengan *running time* tersebut terdeteksi pendekatan manakah yang lebih cepat rentang waktunya untuk mengekstraksi data latih.

Perumusan masalah dalam penelitian ini adalah : (1). Cara mencari *centroid* pada metode *Self Organizing Map*. (2). Bagaimana cara menerapkan pendekatan metode SOM-RBF dan pendekatan metode SOM untuk pola *Clustering* pada sistem.(3). Bagaimana cara membandingkan 2 pendekatan dengan menggunakan *running time*. Penelitian ini bertujuan untuk : (1). Mencari *centroid* pada metode *Self Organizing Map*.(2). Penerapan pendekatan metode SOM-RBF dan pendekatan metode SOM pada sistem.(3). Membandingkan 2 pendekatan dengan *running time*.

Beberapa pembatasan dalam

penelitian ini adalah : (1). Menggunakan 2 pendekatan, yakni pendekatan pertama dengan metode SOM-RBF dan pendekatan kedua dengan menggunakan metode SOM. (2).Sistem menggunakan *PHP Web*. (3). Data yang digunakan merupakan sample dataset yang berasal dari situs internet, yaitu *movielens.org*. (4). Data yang digunakan sebanyak 500 data, dengan 3 kriteria. Yaitu, frekuensi peminjaman buku, tahun penerbitan buku, serta harga sewa tiap buku.

Dalam Kaira [Kahira,2012], menggunakan metode SOM dan *K-Means* untuk memperoleh karakteristik data ketahanan pangan kabupaten di wilayah Provinsi Bali, Nusa Tenggara Barat, dan Nusa Tenggara Timur. Dari hasil percobaan menggunakan SOM, ditemukan bahwa *clustering* data ketahanan pangan yang memiliki *index davies bouldin* minimal adalah ukuran *cluster* 3, *learning rate* 0.5, penurunan *learning rate* 1, *epoch* 100 menghasilkan *index davies bouldin* sebesar 2.696. Dari hasil percobaan yang ada, dapat disimpulkan bahwa Provinsi Nusa Tenggara Timur berada pada *cluster* yang memiliki status rawan pangan. Provinsi Nusa Tenggara Barat termasuk dalam *cluster* dengan kondisi yang agak rawan pangan. Provinsi Bali berada pada *cluster* dengan kondisi ketahanan pangan terjamin. Riyandwayana, 2012 mengatakan dalam penelitiannya menggunakan metode SOM untuk mengklaster data pada Badan Perpustakaan Dan Kearsipan (BAPERSIP) Provinsi Jawa Timur. Dari hasil implementasi, data dapat ter-*cluster* dengan 3 kriteria, yaitu PNS, Mahasiswa, Swasta.

Damayanti dalam penelitiannya menggunakan metode SOM berbasis RBF untuk mengolah data penyakit jantung yang terjadi pada frekuensi, keteraturan, tempat asal denyut atau konduksi impuls listrik jantung. Metode yang digunakan jaringan saraf *Radial Basis Function (RBF)* dan *Kohonen Self Organizing Maps (SOM)* sebagai salah satu metode diagnosis kelainan jantung dari rekaman ECG. Dalam berisi fitur

yang diambil dari teknik *preprocessing*. Penilaiannya terletak pada akurasi pengenalan rata-rata dan jumlah pelatihan sampel yang diperlukan. Dalam Penelitian ini juga melakukan analisis kesalahan untuk menentukan benar tidaknya menggabungkan pengklasifikasi.

## METODE

*Radial Basis Function (RBF)* ini pertama kali diteliti oleh Powell pada tahun 1985 yang dikenalkan sebagai solusi dari masalah '*real multivariate interpolan sistem*'. Konstruksi bentuk dasar dari *Radial Basis Function (RBF)* mempunyai 3 layer dengan aturan yang berbeda. Layer pertama disebut *input layer* yang disusun sebagai *source nodes (sensory unit)*. Layer kedua hanya berisi *hidden layer* pada jaringan, melakukan perpindahan *input space* ke *hidden space*. Pada kebanyakan aplikasi *hidden space* mempunyai dimensi yang tinggi. Layer ketiga adalah *output layer* yang merupakan *linear layer* [Damayanti, 2012]. Algoritma *Radial Basis Function (RBF)* [Jarrah, 2011], adalah :  
Langkah 1 : Inialisasi center dan Lebar (standar deviasi) secara random  
Langkah 2 : Hitung Nilai Fungsi Gauss, seperti pada persamaan:

$$\phi_{ij}(\|x - c_i\|) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_j^2}\right)$$

Dengan  $x$  adalah input,  $c_i$  pusat data ke- $i$ ,  $i = 1, 2, 3, \dots, n$  dan  $\sigma_j^2$  adalah standar deviasi ke- $j$ ,  $j = 1, 2, 3, \dots, n$  dengan  $n$  adalah banyak pusat data [Heriyanto, 2013].

Selain fungsi *Gaussian*, fungsi aktivasi lain yang berbasis radial dan yang biasa diterapkan sebagai berikut [Riyandwayana, 2012] :

### 1. Multi-Quadric Function

$$\varphi(r) = (r^2 + \sigma^2)^{1/2}$$

parameter  $\sigma > 0$

### 2. Generalized Multi-Quadric Function

$$\varphi(r) = (r^2 + \sigma^2)^\beta$$

parameter  $\sigma > 0, 1 > \beta > 0$

### 3. Inverse Multi-Quadric Function

$$\varphi(r) = (r^2 + \sigma^2)^{-1/2}$$

parameter  $\sigma > 0$

### 4. Generalized Inverse Multi-Quadric Function

$$\varphi(r) = (r^2 + \sigma^2)^\alpha$$

parameter  $\sigma > 0, 1 > \alpha > 0$

### 5. Thin Plate Spline Function

$$\varphi(r) = r^2 \ln(r)$$

### 6. Cubic Function

$$\varphi(r) = r^3$$

### 7. Linier Function

$$\varphi(r) = r$$

Langkah 3 : Nyatakan ke dalam matriks  $G$  dengan baris dan kolom.

Langkah 4 : Hitung keluaran bobot dengan rumus berikut.:

$$W = G^+ d = (G^T G)^{-1} G^T d$$

Dengan  $\bar{w}$  adalah matriks bobot pelatihan,  $\Phi^+$  adalah pseudo invers matriks Gaussian, dan  $d$  adalah vektor target (center).

Langkah 5 : Menghitung output RBF dengan menggunakan persamaan.:

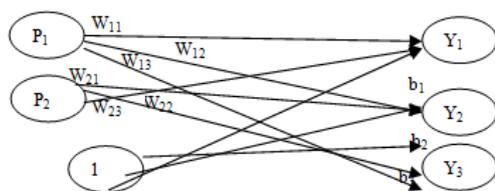
$$y(x) = \sum_{i=1}^j w_i G(\|x - c_i\|) + b$$

Self Organizing Map (SOM) merupakan perluasan dari jaringan kompetitif yang sering disebut dengan jaringan kohonen. Jaringan ini menggunakan metode *unsupervised learning*, yang artinya suatu lapisan yang berisi neuron-neuron akan menyusun dirinya sendiri berdasarkan input nilai tertentu dalam suatu kelompok. Selama proses tersebut, *cluster* yang memiliki jarak paling dekat dengan pola input akan terpilih sebagai pemenang dan beserta neuron tetangganya akan memperbaiki bobotnya. SOM memperlihatkan karakteristik :

1. Kompetisi, yaitu setiap vektor bobot saling berlomba untuk menjadi simpul pemenang.

2. Kooperasi, yaitu setiap simpul pemenang bekerjasama dengan lingkungannya.
3. Adaptasi, yaitu perubahan simpul pemenang dan lingkungannya

Metode SOM bertujuan untuk mengkluster suatu vektor-vektor input berdasarkan bagaimana mereka mengelompok sesuai dengan karakteristik inputnya. *Learning SOM* bekerja dengan cara menggabungkan proses *competitive layers* dengan topologi vektor-vektor input yang dimasukkan dalam proses iterasi. Jaringan SOM terdiri dari 2 lapisan (*layer*), yaitu lapisan input dan lapisan output. Setiap *neuron* dalam lapisan *input* terhubung dengan setiap *neuron* pada lapisan *output*. Setiap *neuron* dalam lapisan *output* merepresentasikan kelas dari *input* yang diberikan. Selama proses penyusunan diri, *cluster* yang memiliki vektor bobot paling cocok dengan pola *input* (memiliki jarak paling dekat) akan terpilih sebagai pemenang. *Neuron* menjadi pemenang beserta *neuron-neuron* tetangganya akan memperbaiki bobot-bobotnya. Apabila kita ingin membagi data-data menjadi *k-cluster*, maka lapisan kompetitif akan terdiri atas k buah neuron (Gambar 1).



Gambar 1. Jaringan Kohonen SOM

Seperti yang diperlihatkan dalam gambar 1, dimisalkan bahwa terdapat 2 unit *input* (P1 dan P2), yang akan dibentuk kedalam 3 *cluster neuron* lapisan *output* (Y<sub>1</sub>, Y<sub>2</sub>, Y<sub>3</sub>). Selanjutnya *neuron-neuron* tersebut akan memperbaiki bobotnya masing-masing, sebagai bobot W<sub>ij</sub>. Dalam hal ini, bobot W<sub>ij</sub> mengandung pengertian bobot yang menghubungkan neuron ke-j pada

lapisan input menuju neuron ke-i lapisan *output* [Faza, 2012].

Berikut algoritma SOM yang akan diterapkan pada program adalah [Faza, 2012] :

Step-0 Inisialisasi bobot W<sub>ij</sub>. Tetapkan parameter cluster (m) dan parameter laju peatihan (α).

Step-1 Selama syarat berhenti salah, lakukan langkah-langkah dibawah ini :

Langkah (i). Untuk setiap vektor masukan X, lakukan beberapa langkah dibawah ini :

Langkah (a). Untuk Setiap j, hitung *Euclidean Distance* dengan persamaan (5):

$$D(j) = \sum_i (w_{ij} - x_i)^2 \dots\dots\dots(5)$$

Langkah (b). Cari indeks j sedemikian sehingga D(j) minimum

Langkah (c). Untuk semua unit j didalam ketetanggan j, dan untuk semua l, hitunglah:

$$w_{ij(\text{baru})} = w_{ij(\text{lama})} + \alpha [x_i - w_{ij(\text{lama})}] \dots\dots(6)$$

Rumus (6) merupakan rumus untuk memperbarui bobot.

Langkah (ii). Perbarui laju belajar.

Langkah (iii). Kurangi jari-jari ketetanggan topologis dengan pencacahan tertentu.

Langkah (iv). Uji syarat berhenti. Bila benar, maka berhenti.

*MSE (Mean Squared Error)* adalah metode lain untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan. Kemudian dijumlahkan dan dibagi dengan jumlah observasi. Pendekatan ini mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan. Suatu teknik yang menghasilkan kesalahan moderat mungkin lebih baik untuk salah satu yang memiliki kesalahan kecil tapi kadang-kadang menghasilkan sesuatu yang sangat besar. Berikutini rumus untuk menghitung MSE [FMIPA UNS, 2012] :

$$MSE = \sum_{t=1}^n \frac{(y - y')^2}{n} \dots\dots\dots(7)$$

Perhitungan *Mean Squared Error (MSE)* berfungsi sebagai pengukur kesalahan pembentukan bobot akibat

keacakan data selama proses *training*, dimana keacakan data ini akan mempengaruhi akurasi data yang dihasilkan. Selain itu *MSE* juga berfungsi sebagai ambang batas pada proses komputasi. Dengan menggunakan fungsi akar kuadrat dari *Euclidean Distance* antara bobot awal *epoch* dengan *epoch* sampai memenuhi nilai optimal yang telah ditentukan (Wahyuningrum, 2012).

### PEMBAHASAN

Pada uji coba ini, peneliti menggunakan 500 data untuk mengetahui perbandingan antara dua pendekatan, yaitu pendekatan pertama dengan metode *SOM-RBF* dan pendekatan kedua dengan metode *SOM* saja. Serta dengan kondisi stop yaitu  $MSE \leq 0.001$ .

Uji coba ini dilakukan bertujuan untuk mengetahui pendekatan manakah yang lebih baik. Uji coba dilakukan pada 3 skenario, yaitu : (1). Menggunakan parameter *MSE* sebagai kondisi stop terhadap *running time*. (2). Menggunakan parameter *MSE* sebagai kondisi stop terhadap *epoch* dan *learning rate*. (3). Menggunakan parameter *MSE* sebagai kondisi stop terhadap *MSE* yang sebenarnya.

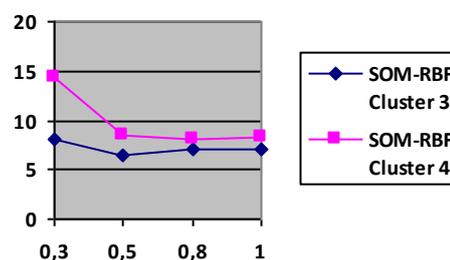
Pada uji coba ini data yang digunakan adalah data yang sama sebanyak 500 data. Dan akan dilakukan pada 3 skenario. Kriteria yang digunakan sama seperti pada sistem, yaitu frekuensi peminjaman buku, tahun penerbit buku, dan harga sewa buku. Jumlah *cluster* dan bobot awal yang sama dengan batasan jumlah *cluster* yang digunakan adalah 3 dan 4 *cluster*. Kondisi stopnya adalah  $MSE = 0.001$ . Dan *learning rate* dibatasi antara 0.3, 0.5, 0.8, dan 1.

Pada Tabel 1 menunjukkan tentang hasil uji coba skenario pertama dengan parameter *MSE* sebagai kondisi stop terhadap *running time*. Jadi pada skenario ini membandingkan antara pendekatan pertama dan kedua berdasarkan *running time*.

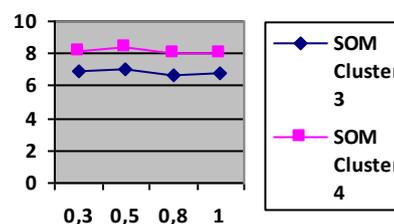
Skenario 1, Proses menggunakan parameter *MSE* sebagai kondisi stop terhadap *running time*.

Tabel 1. Hasil uji coba skenario 1

Learning rate	Cluster			
	SOM-RBF		SOM	
	3	4	3	4
0.3	8.1707 s	14.371 s	6.8605 s	8.1407 s
0.5	6.5311 s	8.3941 s	7.0558 s	8.3855 s
0.8	7.1383 s	8.1351 s	6.6406 s	8.0376 s
1	7.0149 s	8.3505 s	6.8438 s	7.9801 s
Average	7.2138 s	9.8128 s	6.8501 s	8.1359 s



Gambar 2. Hasil uji coba skenario 1 SOM-RBF



Gambar 3. Uji coba skenario 1 SOM

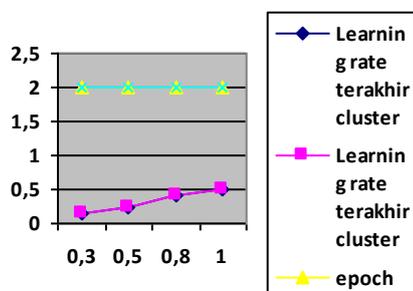
Pada Gambar 2 menunjukkan dari hasil uji coba skenario 1 pada pendekatan pertama dan Gambar 3 menunjukkan dari hasil uji coba skenario 1 pada pendekatan kedua. Menurut grafik pada pendekatan pertama dan kedua terlihat bahwa semakin banyak *cluster* yang dihasilkan, maka waktu yang dibutuhkan juga semakin lama. Jika dirata-rata dan dibandingkan antara kedua pendekatan tersebut maka dapat ditarik kesimpulan bahwa untuk *running time* pendekatan pertama membutuhkan waktu yang lebih lama daripada pendekatan kedua. Dikarenakan pada pendekatan pertama membutuhkan proses yang lebih banyak dari pendekatan kedua.

Skenario 2, diuji coba proses menggunakan parameter MSE sebagai kondisi stop terhadap *epoch* dan *learning rate*.

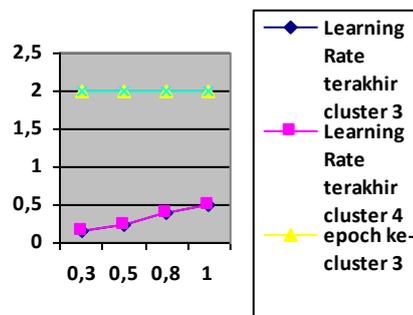
Tabel 2 Hasil uji coba skenario 2

Learning Rate	Cluster	Learning Rate terakhir		Jatuh pada epoch ke-	
		SOM-RBF	SOM	SOM-RBF	SOM
0.3	3	0.15	0.15	2	2
	4	0.15	0.15	2	2
0.5	3	0.25	0.25	2	2
	4	0.25	0.25	2	2
0.8	3	0.4	0.4	2	2
	4	0.4	0.4	2	2
1	3	0.5	0.5	2	2
	4	0.5	0.5	2	2

Pada Tabel 2 menunjukkan tentang hasil uji coba skenario kedua dengan parameter *MSE* sebagai kondisi stop terhadap *epoch* dan *learning rate*. Jadi pada skenario ini membandingkan antara pendekatan pertama dan kedua berdasarkan jatuh pada *epoch* keberapakah ketika kondisi stop terpenuhi, dan berapa *learning rate* terakhir ketika kondisi stop terpenuhi.



Gambar 4. Hasil uji coba skenario 2 pendekatan SOM-RBF



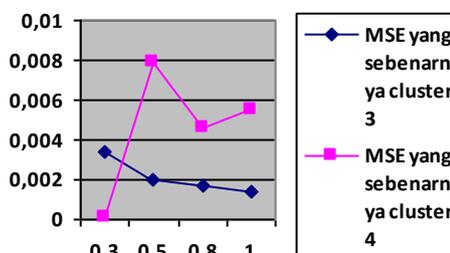
Gambar 5 Uji coba skenario 2 pendekatan SOM

Pada Gambar 4 menunjukkan grafik hasil uji coba skenario 2 pendekatan pertama, dan Gambar 5 menunjukkan grafik hasil uji coba skenario 2 pendekatan kedua. Menurut grafik pada pendekatan pertama dan kedua tidak terlihat perbedaan antar cluster. Pada tiap *cluster* masing-masing pendekatan *learning rate* terakhir saat kondisi stop terpenuhi tidak ada perbedaan. Pada semua *cluster* berakhir pada *learning rate* kedua dan *epoch* kedua. Jika ditarik kesimpulan, untuk skenario 2, antara pendekatan pertama dan kedua berbanding lurus.

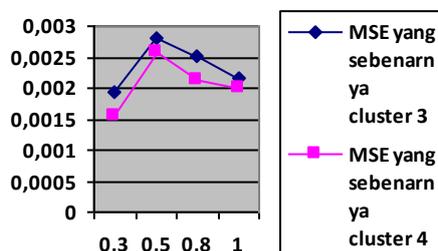
Tabel 3 Hasil uji coba skenario 3

Learning Rate	Cluster	MSE yang sebenarnya	
		SOM-RBF	SOM
0.3	3	0.003371	0.0019
	4	0.000105	0.0015
0.5	3	0.002024	0.0028
	4	0.007938	0.0025
0.8	3	0.001698	0.0020
	4	0.004627	0.0021
1	3	0.001376	0.0021
	4	0.005487	0.0019
Average	-	0.003328	0.0021

Pada Tabel 3 menunjukkan hasil uji coba skenario 3 dengan parameter *MSE* sebagai kondisi stop terhadap nilai *MSE* yang sebenarnya. Pada pendekatan pertama dan kedua. Jadi, pada skenario ini pada pendekatan pertama dibandingkan dengan pendekatan kedua berdasarkan nilai *MSE* yang sebenarnya.



Gambar 6. Hasil uji coba skenario SOM-RBF



Gambar 7. Hasil uji coba skenario 3 SOM

Pada Gambar 6 menunjukkan grafik hasil uji coba skenario 3 pada pendekatan pertama, dan Gambar 7 menunjukkan grafik hasil uji coba skenario 3 pendekatan kedua. Menurut grafik pendekatan pertama dan kedua menunjukkan perbedaan yang cukup banyak. Nilai MSE yang sebenarnya pada pendekatan pertama antar cluster terdapat perbedaan yang cukup banyak pula. Begitu juga dengan pendekatan kedua. Jika dirata-rata dan dibandingkan, pendekatan pertama mempunyai nilai MSE yang lebih besar dari pendekatan kedua.

### KESIMPULAN

Kesimpulan yang dapat diambil dari pembuatan penelitian ini adalah pada sistem ini, menggunakan 2 pendekatan dimana pada pendekatan pertama menggunakan perpaduan metode SOM-RBF, sedangkan pada pendekatan kedua menggunakan metode SOM saja. Penentuan nilai *centroid* dengan 2 kali iterasi, yang menghasilkan nilai yang optimal pada cluster. Pendekatan pertama pada sistem ternyata tidak lebih efisien dari pendekatan kedua jika dilihat dari segi *running time*-nya. Dikarenakan adanya perbedaan proses pada kedua pendekatan tersebut. Yakni, pada pendekatan pertama mengalami proses yang cukup panjang jika dibandingkan dengan pendekatan kedua. Ketika ujicoba dilakukan, dengan parameter *learning rate* 1, 0.8, 0.5, dan 0.3. Dan dengan 3,4, 5 cluster, serta kondisi stop MSE 0.001. Terlihat perbedaan yang cukup signifikan dr kedua perbedaan tersebut. Dilihat dari segi kenaikan

*running time* pada tiap *learning rate*, pendekatan kedua menaikkan *running time*-nya lebih stabil. Dibandingkan dengan pendekatan kedua, yang perbedaan antar cluster di tiap *learning rate* perbedaan *running time*-nya cukup jauh.

Aplikasi yang dibuat pada Tugas Akhir ini masih dapat dikembangkan lebih lanjut dengan diharapkan ada penambahan parameter untuk lebih meningkatkan fungsi pada kedua pendekatan. Diharapkan ada penelitian dengan metode lain yang lebih baik dari penelitian ini.

### DAFTAR PUSTAKA

- Kahira, Ulfa. *Integrasi Self Organizing Maps dan Algoritma K-Means Untuk Clustering Data Ketahanan Pangan Kabupaten di Wilayah Provinsi Bali, Nusa Tenggara Timur, dan Nusa Tenggara Barat*. Institut Pertanian Bogor. 2012
- Riyandwayana, Ananda dkk. *Pengembangan Sistem Rekomendasi Peminjaman Buku Berbasis Web Menggunakan Metode Self Organizing Maps Clustering Pada Badan Perpustakaan Dan Kearsipan (BAPERSIP) Provinsi Jawa Timur*. Institut Teknologi Sepuluh November Surabaya. 2012
- Damayanti, Auli. *Pendekatan ARRYTHMIA Hasil ECG Menggunakan Radial Basis Function Dan Kohonen Self Organizing Maps*. Universitas Airlangga. 2012
- Baboo, S. Santosh. *Combining Self Organizing Maps and Radial Basis Function Network for Tamil handwritten Character Recognition*. University for women, Coimbatore, India. 2009
- Faza, Ahmad. *Klasterisasi Teks Informasi Beasiswa Menggunakan Self Organizing Maps (SOM)*. Universitas Trunojoyo Madura. 2012.
- [http://www.proweb.co.id/articles/web\\_application/PHP\\_adalah.html](http://www.proweb.co.id/articles/web_application/PHP_adalah.html), diakses pada tanggal 03 Juni 2013

<http://kc99lounge.blogspot.com/2010/07/data-mining.html>, diakses pada tanggal 10 Juli 2013

Kelompok 2. *Metode Peramalan 2011*. Jurusan Matematika FMIPA UNS.2011

Wahyuningrum, Rima Tri, dkk. *Pengenalan Pola Senyum Menggunakan Self Organizing Maps (SOM) Berbasis Ekstraksi Fitur Two-Dimensional Principal Component Analysis (2DPCA)*. Universitas Trunojoyo.2012

Jariah, Ainun, dkk. *Pengenalan Pola Tanda Tangan Menggunakan Metode Moment Invariant Dan Jaringan Syaraf Radial Basis Function (RBF)*. Universitas Yogyakarta.2011

Heriyanto, Dwi N. *Penerapan Metode Radial Basis Function Dengan K-Means Cluster Untuk Peramalan Kebutuhan Straw*. Universitas Trunojoyo.2013

<http://movielens.org>