

PENERAPAN *SELF ORGANIZING MAP* UNTUK PERHITUNGAN KORELASI ANTARA PENALARAN MATEMATIKA DENGAN IPK KELULUSAN MAHASISWA (Studi Kasus : Program Studi Ilmu Komputer)

(¹)Annisa Putri Novalianti, (²)Anindita Septiarini

Program Studi Ilmu Komputer, FMIPA Universitas Mulawarman
Email : annisaputrinov@gmail.com¹⁾

ABSTRAK

Program Studi Ilmu Komputer yang mempelajari dasar-dasar pengetahuan komputasi, berbanding terbalik kenyataan di perkuliahan dengan adanya 8 mata kuliah penalaran matematika antara lain, Matematika Dasar, Logika Matematika, Kalkulus I, Kalkulus II, Aljabar Linier Matriks, Matematika Diskrit, Statistika, dan Metode Numerik. Hal ini menimbulkan pertanyaan bagaimana dan apa hubungan antara program studi Ilmu Komputer dengan mata kuliah penalaran matematika. Analisis korelasi dilakukan untuk menganalisis hubungan antara nilai penalaran matematika dengan IPK kelulusan mahasiswa. Metode *Self Organizing Maps* (SOM) digunakan dalam penelitian ini karena mampu mempelajari dan mengorganisir informasi serta efektif untuk masalah yang kompleks dengan pembagian berdasar tingkat korelasinya. Penelitian ini diharapkan dapat membantu mahasiswa maupun akademik untuk mengetahui korelasi antara mata kuliah penalaran matematika dengan IPK dan menjadikannya sebagai acuan dalam peningkatan indeks prestasi kelulusan mahasiswa.

Kata Kunci : *Self Organizing Maps*, Analisis Korelasi, Mata Kuliah Penalaran Matematika, Indeks Prestasi Kelulusan.

PENDAHULUAN

Program studi Ilmu Komputer menghasilkan lulusan yang mampu menciptakan, mengembangkan, mengaplikasikan ilmu komputer dan teknologi informasi serta menguasai metode dan teknik perbaikan masalah yang berbasis komputer dan teknologi informasi.

Pada kegiatan perkuliahan para mahasiswa dikejutkan dengan adanya 8 mata kuliah ilmu hitung matematika, seperti Matematika Dasar, Logika Matematika, Kalkulus I, Kalkulus II, Aljabar Linier Matriks, Matematika Diskrit, Statistika, Metode Numerik, dan beberapa mata kuliah lain yang juga memerlukan daya nalar matematika. Hal ini berbanding terbalik dengan pengetahuan secara awam dimana jurusan Ilmu Komputer hanyalah pada ilmu-ilmu yang berkenaan langsung dengan komputer seperti desain, *coding*, proyek *software* atau *hardware* tanpa adanya penalaran ilmu matematis.

Dalam penelitian analisis korelasi ini, parameter yang digunakan yaitu nilai mata kuliah penalaran matematika dan IPK mahasiswa yang dinyatakan telah lulus S-1. Penilaian didasarkan pada hasil perhitungan parameter-parameter dengan proses perhitungan analisis korelasi dengan menerapkan metode *Self Organizing Map* (SOM)

dengan input berupa variabel x dan variabel y . Hasil korelasi ini dapat digunakan untuk pengembangan dan pembaharuan dalam metode pengajaran mata kuliah penalaran matematika untuk peningkatan prestasi mahasiswa Ilmu Komputer FMIPA Universitas Mulawarman sesuai dengan nilai korelasi yang dihasilkan dalam penelitian.

LANDASAN TEORI

Analisis Korelasi

Analisis korelasi merupakan teknik analisis statistika yang termasuk dalam salah satu teknik pengukuran asosiasi/hubungan (*measures of association*). Korelasi bermanfaat untuk mengukur kekuatan hubungan atau relasi antara dua variabel atau lebih dengan skala-skala tertentu. (Sarwono, 2006).

Kuat lemah hubungan korelasi diukur diantara jarak (range) 0 sampai dengan 1. Korelasi mempunyai kemungkinan pengujian hipotesis dua arah (*two tailed*). Semakin mendekati nilai range 1, maka variabel dinyatakan berkorelasi. Korelasi searah jika nilai koefisien korelasi ditemukan positif, sebaliknya jika nilai koefisien korelasi negatif, korelasi disebut tidak searah (Yusuf,

2009). Koefisien korelasi (r) dapat ditentukan dengan menganalogikan persamaan 1 :

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

Interpretasi dari besarnya nilai korelasi sampel antara variabel dapat diklasifikasikan dalam tabel 1.

Tabel 1 Koefisien Korelasi dan Interpretasinya.

(Sumber: Usman dan Purnomo, 2000)

| Nilai Korelasi | Interpretasi |
|----------------|-------------------------------|
| 0.00 – 0.09 | Hubungan korelasi diabaikan |
| 0.10 – 0.29 | Hubungan korelasi rendah |
| 0.30 – 0.49 | Hubungan korelasi moderat |
| 0.50 – 0.70 | Hubungan korelasi kuat |
| > 0.70 | Hubungan korelasi sangat kuat |

Jaringan Syaraf Tiruan

Jaringan syaraf tiruan merupakan cabang ilmu multidisiplin yang pada dasarnya mencoba meniru cara kerja otak makhluk hidup. Salah satu struktur yang ingin ditiru adalah bentuk neuron-nya (sel syaraf) dengan kemampuan *fault-tolerance* dan kemampuan untuk belajar (Kristanto, 2004).

Jaringan syaraf tiruan dapat belajar dari pelatihan, melakukan generalisasi dari contoh-contoh yang diperoleh dan menyesuaikan karakteristik input. Berbeda dengan metode lain, algoritma untuk jaringan syaraf tiruan beroperasi secara langsung dengan angka, sehingga data yang tidak numerik harus diubah menjadi data numerik. Dibandingkan dengan perhitungan konvensional, jaringan syaraf tiruan tidak memerlukan suatu model matematis permasalahan yang dihadapi (Fausett 1994).

Menurut John (2004), dengan tingkat kemampuan yang sangat baik dan koordinasi yang baik antara jaringan, beberapa aplikasinya sangat cocok untuk diterapkan pada:

1. Klasifikasi, memilih suatu input data kedalam satu katagori tertentu yang diterapkan.
2. Asosiasi, menggambarkan suatu objek secara keseluruhan hanya dengan sebuah bagian dari objek lain.
3. *Self Organizing*, kemampuan untuk mengelola data-data input tanpa harus memiliki data sebagai target.
4. Optimasi, menemukan suatu jawaban atau solusi yang paling baik sehingga seringkali dengan meminimalisasikan suatu fungsi biaya (*optimizer*).

Karakteristik jaringan syaraf tiruan dapat ditentukan oleh :

1. Pola hubungan antar neuron (disebut dengan arsitektur jaringan)

2. Metode penentuan bobot-bobot penghubung (disebut dengan pelatihan)
3. Fungsi aktivasi.

Self Organizing Map (SOM)

Self Organizing Map (SOM) adalah belajar tanpa pengawasan (*Unsupervised Learning*), dimana perubahan bobot-bobot interkoneksinya sebagai tanggapan terhadap masukan dan tanpa memerlukan jawaban targetnya. SOM dikenalkan oleh Teuvo Kohonen, terdiri dari dua lapisan yang terhubung penuh, yaitu lapisan masukan dan lapisan kompetitif yang biasanya terbentuk dua dimensi (Seiffert, 2002). Dengan bobot awal diberikan secara acak dan akan disesuaikan selama proses pembelajaran. Titik atau *nodes* akan mengumpul berkelompok kedalam suatu *cluster* atau kelas pembagian berdasarkan kemiripan diantaranya. Dalam iterasinya di Matlab dengan aturan Kohonen terjadi pengubahan bobot-bobot (Jong, 2005). Dan neuron dengan bobot paling mendekati vektor masukan akan diperbaiki dan dibuat lebih dekat lagi. Pertambahan dan berubahnya vektor masukan yang diberikan, maka lama kelamaan vektor masukan akan terbagi menjadi beberapa kelompok.

METODE PENELITIAN

Pada dasarnya algoritma SOM, untuk setiap vektor *input X* (Kohonen dkk, 2004):

Step 0 : Inisialisasi bobot w_{ij} , parameter *learning rate* (α), bentuk dan jari-jari topologi sekitarnya, dan maksimum epoch.

$$w_{ij} = \frac{Minx_j + Maxx_j}{2}$$

Inisialisasi bobot bias (b_i) dengan b_i adalah bobot bias ke neuron ke-I dan K adalah jumlah kelas

$$b_i = e^{[1 - \ln(\frac{1}{K})]}$$

Step 1 : Lakukan langkah 2 - 7 untuk kondisi batas berhenti belum tercapai.

Step 2 : Untuk setiap vektor input x , lakukan langkah 3 – 5, hingga tercapai epoch maksimum

Step 3 : Pilih data secara acak, misal data X_i . Untuk setiap j , hitung jarak :

$$D_{(j)} = \sqrt{\sum_i (w_{ij} - x_i)^2}$$

Step 4 : Temukan neuron pemenang, yaitu indeks J yang membuat $D_{(j)}$ minimum

$$a_i = -D_i + b_i$$

Cari a_i terbesar dengan syarat:

$$Max A = \max(a) \text{ dengan } i=1,2,3,\dots,K$$

$Idx = I$ sehingga $a_i = Max A$

Step 5 : Untuk setiap unit j di sekitar J , lakukan modifikasi bobot input:

$$W_{ij}(\text{baru}) = W_{ij}(\text{lama}) + \alpha[x_j - W_{ij}(\text{lama})]$$

Update bobot bias:

$$(i) C_i = (1 - \alpha)e^{(1 - \ln(b_i))} + \alpha \cdot \text{Max } A$$

$$(ii) B_i = e^{(1 - \ln(r_i))}$$

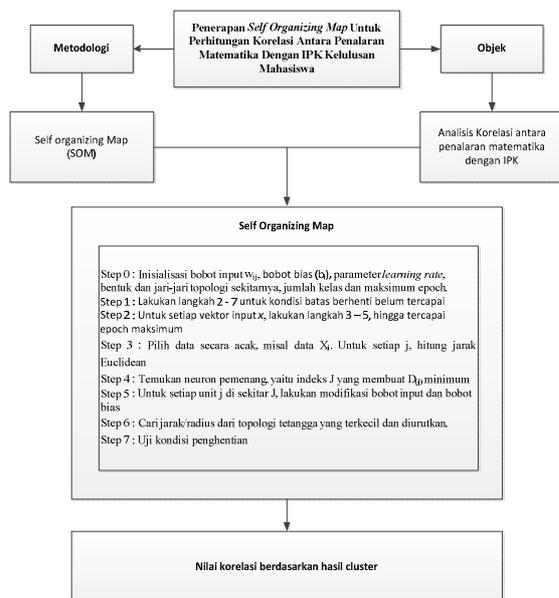
Step 6 : Cari jarak/radius dari topologi tetangga yang terkecil dan diurutkan.

Step 7 : Uji kondisi penghentian

Keterangan :

1. Inisialisasi nilai bobot awal biasanya menggunakan nilai tengah (*middle point*) atau menggunakan nilai acak.
2. Fungsi jarak menggunakan jarak Euclid (*Euclidean Distance*)
3. Kondisi penghentian iterasi adalah selisih antara W_{ij} saat itu dengan W_{ij} pada iterasi sebelumnya hanya berubah sedikit, yang artinya iterasi sudah mencapai konvergen.

Kerangka Teoritik Penelitian



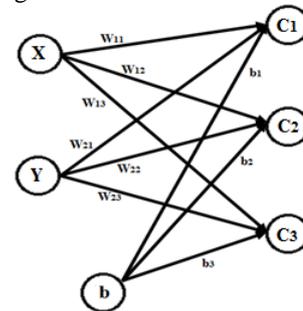
Gambar 1. Kerangka Teoritik Penelitian

HASIL DAN PEMBAHASAN

Tahap awal dalam proses pembangunan sistem ini adalah pengumpulan data dan identifikasi permasalahan analisis korelasi kedalam sistem yang akan dibangun. Pada analisis korelasi ini dilakukan uji hipotesa. Data yang digunakan adalah nilai 8 mata kuliah penalaran matematika sebagai variabel X dan IPK kelulusan mahasiswa yang diambil secara acak sebagai variabel Y, dengan 100 koresponden untuk data pelatihan dan 100 koresponden untuk data pengujian.

Alur proses sistem disesuaikan menurut arsitektur dari jaringan *Self Organizing Maps* yakni, sistem menerima *input* berupa data pelatihan, data pengujian, dan *outputnya* berupa nilai korelasi, grafik, dan kelas korelasi. Hasil tersebut diperoleh

dengan menghitung nilai bobot, konstanta belajar, melakukan epoch maksimum, dan mengubah nilai bobot input dan bobot bias. Arsitektur dari proses ini diorientasikan untuk penelitian analisis korelasi seperti pada gambar 2.



Gambar 2. Arsitektur SOM Analisis Korelasi

Langkah pertama adalah perhitungan analisis korelasi pada sistem dilakukan perhitungan koefisien korelasi (r), yakni dengan persamaan 1:

$$r = \frac{100(1049.378) - (312.5)(333.54)}{\sqrt{100(1021.75) - (312.5)^2} \cdot \sqrt{100(1119.104) - (333.54)^2}}$$

$$r = \frac{67.22165}{67.22165 \times 25.71925}$$

$$r = 0.402875 \approx 0.403$$

Langkah perhitungan ini dilanjutkan hingga data variabel X mata kuliah lainnya seperti Logika Matematika (Logmat), Kalkulus I dan II (Kalk), Aljabar Linier Matriks (Alm), Matematika Diskrit (Matdis), Statistika (Stat), dan Metode Numerik (Metnum) diolah dengan variabel Y yaitu IPK.

Proses berikutnya adalah perhitungan pada sistem Matlab dengan proses pelatihan dan pengujian yang dilakukan pada mata kuliah Matematika Dasar dengan IPK, dengan informasi :

1. Jumlah data (n) = 100
2. Jumlah variabel input (m) = 2
3. Jumlah cluster (K) = 3
4. MaxEpoch = 500
5. Learning rate (α) = 0.001
6. Data terkecil dan data terbesar variabel pertama (p_1) yaitu variabel X matematika dasar adalah 2 dan 4. Sedangkan pada variabel input kedua (p_2) yaitu variabel Y IPK adalah 2.61 dan 3.89.

Informasi tersebut akan diolah sesuai aturan atau rule yang dibuat pada sistem Matlab. Langkah-langkah yang terjadi dalam sistem Matlab dapat dijelaskan sebagai berikut:

(Pada epoch 1)

1. Langkah inisialisasi:
 - a. Inisialisasi bobot input (w_{ij}) maka didapat $w_{p1} = \frac{2+4}{2} = 3$ dan pada $w_{p2} = \frac{2.61 + 3.89}{2} = 3.25$
 - b. Inisialisasi bobot bias (b_i) maka didapat $b_i = e^{[1 - \ln(\frac{1}{3})]} = 8.154845485 \approx 8.1548$

- c. Set parameter *learning rate* sebesar 0.05
- d. Set maksimum epoch sebesar 500
- 2. Lakukan perubahan data sampai max epoch tercapai:
 - a. Hitung jarak data, misal vektor input terpilih data ke-2 : $X = 3$ dan $Y = 3.54$

$$D_{(ij)} = \sqrt{(3 - 3)^2 + (3.25 - 3.54)^2} = 0.29$$
 - b. Hitung $a_i = -D_i + b_i$

$$= -0.29 + 8.1548$$

$$= 7.8648$$
- 3. Lakukan modifikasi bobot:
 - untuk var $X = 3 + 0.05(3 - 3) = 3$
 - untuk var $Y = 3.25 + 0.05(3.54 - 3.25) = 3.26$
 - Maka matriks bobot baru =

| | | |
|------|------|------|
| 3 | 3 | 3 |
| 3.26 | 3.25 | 3.25 |
- 4. Update bobot bias:
 - (i) $C_i = (1 - 0.05) e^{(1 - \ln(2.1548))} + 0.05 \times 7.8648$

$$= 0.95 \times 0.333 + 0.39324$$

$$= 0.70959$$
 - (ii) $B_i = e^{(1 - \ln(0.2))} = 3.83$
 - Maka matriks bobot bias baru =

| | | |
|------|------|------|
| 3.83 | 3.83 | 3.83 |
|------|------|------|

Langkah ini dilanjutkan terus hingga mencapai MaxEpoch = 500, dan dilanjutkan dengan mata kuliah yang lainnya. Selanjutnya akan dilakukan proses pengenalan data yaitu proses pengujian. Dilakukan pengenalan pola data yang terlatih untuk mengetahui bahwa sistem berfungsi. Tidak ada perbedaan perhitungan pada tahap pengujian ini pada perhitungan tahap pelatihan, karena pada tahap ini adalah menyimulasikan input baru atau input yang sama untuk mengetahui bagaimana sistem mengenali data input tersebut.

Pengujian ini terus dilanjutkan pada mata kuliah lainnya, dan kemudian dicocokkan untuk mengetahui besar kesamaan pengenalan pola. Hasil pengujian dan kesamaan data antara mata kuliah dengan IPK dihitung dengan persamaan persentase (Mutia, 2012).

$$P = \frac{f}{N} \times 100\%$$

Persamaan persentase dapat dihitung dengan menggunakan hasil pengenalan data pada mata kuliah Matematika Dasar. Hasil data yang dikenali adalah sebanyak 47 data dari total keseluruhan 100 data pengujian, terlampir pada lampiran V.

$$P = \frac{47}{100} \times 100\%$$

$$P = 47\%$$

Perhitungan ini dilakukan pula terhadap 7 data mata kuliah lainnya dengan cara yang sama yaitu hanya menggunakan data yang dikenali mirip *cluster*-nya oleh sistem.

Tabel 4.4 Pengenalan Pola Data Hasil Pengujian

| Mata Kuliah | Pengenalan |
|------------------|------------|
| Matematika Dasar | 47% |

| | |
|------------------------|-----|
| Logika Matematika | 55% |
| Kalkulus I | 89% |
| Kalkulus II | 92% |
| Aljabar Linier Matriks | 61% |
| Statistika | 95% |
| Matematika Diskrit | 63% |
| Metode Numerik | 30% |

KESIMPULAN

Berdasarkan hasil penelitian dapat diambil kesimpulan bahwa mata kuliah penalaran matematika berkorelasi positif terhadap IPK kelulusan mahasiswa dan penelitian ini menemukan 3 mata kuliah yang berkorelasi paling kuat yaitu Statistika dengan korelasi sebesar 95%, Kalkulus II dengan korelasi sebesar 92%, dan Kalkulus I dengan korelasi sebesar 89%.

DAFTAR PUSTAKA

- [1] Fausett, L. 1994. *Fundamentals of Neural Networks*. New Jersey: Prentice Hall.
- [2] John, A. B. 2004. *Self Organizing Maps: Fundamentals*. Diakses 2 April 2013, dari www.cs.bham.ac.uk/~jxb/NN/116/
- [3] Kohonen, T. 2004. *Self-Organizing Maps*. Germany: Springer-Verlag Company.
- [4] Kristanto, A. 2004. *Jaringan Syaraf Tiruan (Konsep Dasar, Algoritma, dan Aplikasinya)*. Yogyakarta: Gava Media.
- [5] Sarwono, J. 2006. *Metode Penelitian Kuantitatif dan Kualitatif*. Yogyakarta : Graha Ilmu.
- [6] Seiffert, U. 2002. *Self-Organizing Neural Networks (Recent Advances and Applications)*. Germany: Springer-Verlag Company.
- [7] Usman, H. dan Purnomo. 2000. *Pengantar Statistika*. Jakarta : Bumi Aksara.
- [8] Yusuf, W. 2009. *Metode Statistik*. Yogyakarta : Gadjah Mada University Press.
- [9] Mutia, B. 2012. *Cara Menghitung Persentase*. Jakarta : Bumi Aksara.