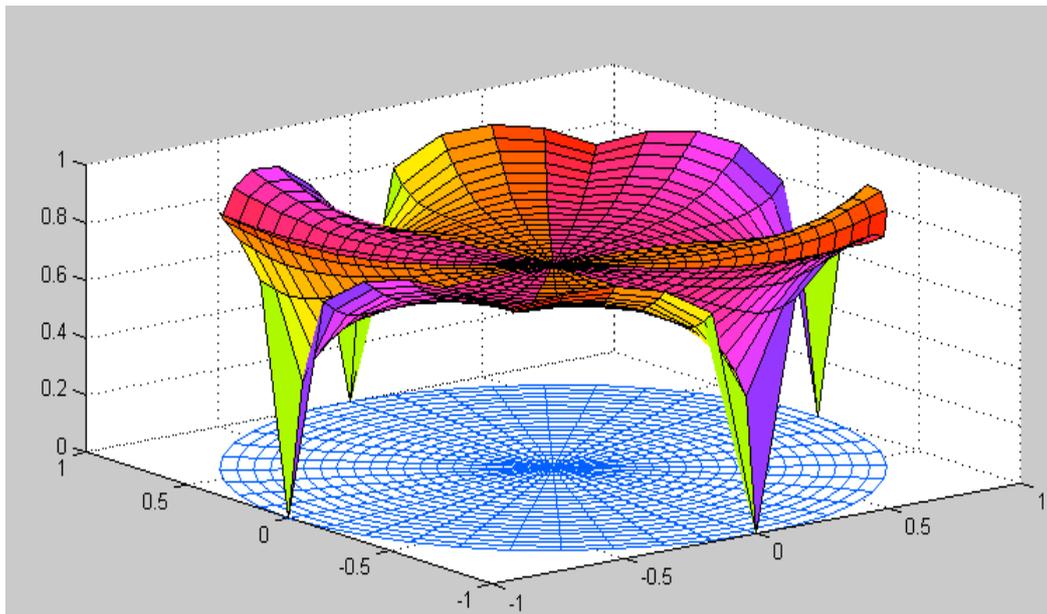


Volume 1, Nomor 1, Juni 2007

8 arekeng

jurnal ilmu matematika dan terapan



ISSN: 1978-7227

JURUSAN MATEMATIKA FMIPA UNIVERSITAS PATTIMURA

ISSN 1978 - 7227



9 771978 722737

**PREDIKSI JENIS PENYAKIT *ERYTHEMATO-SQUAMOUS*
MENGUNAKAN JARINGAN SYARAF TIRUAN DENGAN *K-MEANS* SEBAGAI PRAPROSES**

AZIZ KUSTIYO¹, IRMAN HERMADI¹, MUSLIKHAH FAJRIYATI²

¹ *Departemen Ilmu Komputer, FMIPA, IPB*

² *Alumni Departemen Ilmu Komputer, FMIPA, IPB*

Jl. Raya Padjadjaran, Bogor

ABSTRAK

Diagnosa untuk membedakan penyakit-penyakit *erythemato-squamous* merupakan masalah dalam dermatologi. Penyakit-penyakit yang termasuk ke dalam kelompok tersebut adalah: *psoriasis, seboreic dermatitis, lichen planus, pityriasis rosea, cronic dermatitis dan pityriasis rubra pilaris*. Pada pengamatan awal, penyakit-penyakit tersebut memiliki ciri-ciri klinis *erythema* dan *scaling* dengan perbedaan-perbedaan yang sangat kecil. Di samping itu, satu penyakit dapat menunjukkan ciri-ciri histopatologis penyakit lain pada tahap permulaan dan baru menunjukkan karakteristik yang sebenarnya pada tahap berikutnya.

Penelitian ini mengembangkan dua model jaringan syaraf tiruan (JST) dengan algoritma pelatihan propagasi balik untuk memprediksi penyakit tersebut. Model I menggunakan inisialisasi pembobot Nguyen-Widrow, sedangkan Model II menggunakan inisialisasi pembobot acak. Jumlah *neuron* pada lapisan tersembunyi sebanyak 6, 12 dan 17 *neuron*. Toleransi galat 0.001, dengan laju pembelajaran dibuat tetap sebesar 0.1. Fungsi aktivasi yang digunakan ialah sigmoid biner.

Berdasarkan hasil penelitian, pada model JST dengan inisialisasi pembobot awal Nguyen-Widrow dan acak, rata-rata ketepatan prediksi tertinggi terjadi ketika digunakan 12 *neuron* pada lapisan tersembunyi, yaitu pada Model I sebesar 94.42% dan pada Model II sebesar 96.65%. Pada penelitian ini, model JST dengan inisialisasi pembobot awal acak selalu menghasilkan nilai ketepatan prediksi yang lebih tinggi daripada model JST dengan inisialisasi Nguyen-Widrow. Kedua model JST yang digunakan mampu menghasilkan nilai ketepatan yang lebih tinggi dibandingkan dengan penelitian sejenis yang dilakukan sebelumnya.

PENDAHULUAN

Diagnosa untuk membedakan penyakit-penyakit *erythemato-squamous* merupakan masalah dalam dermatologi. Penyakit-penyakit yang termasuk ke dalam kelompok tersebut adalah: *psoriasis, seboreic dermatitis, lichen planus, pityriasis rosea, cronic dermatitis dan pityriasis rubra pilaris*. Pada pengamatan awal, penyakit-penyakit tersebut memiliki ciri-ciri klinis *erythema* dan *scaling* dengan perbedaan-perbedaan yang sangat kecil (Merz dan Murphy 1996 dalam Kustiyo 2004).

Dalam dunia kedokteran, langkah-langkah yang dilakukan untuk menentukan jenis penyakit tersebut terdiri dari dua tahap yaitu pemeriksaan secara klinis dan histopatologis. Kesulitan yang timbul pada evaluasi tersebut adalah bahwa satu penyakit dapat menunjukkan ciri-ciri histopatologis penyakit lain pada tahap permulaan dan baru menunjukkan karakteristik yang sebenarnya pada tahap berikutnya (Merz dan Murphy 1996 dalam Kustiyo 2004).

Beberapa penelitian telah dilakukan untuk memprediksi jenis penyakit tersebut, antara lain menggunakan algoritma *nearest neighbor classifier, naïve bayesian classifier, voting feature intervals-5*, algoritma genetika, jaringan syaraf tiruan (JST) dengan algoritma propagasi balik dan algoritma apriori, dan algoritma JST propagasi balik menggunakan inisialisasi pembobot awal metode regresi logistik biner dan acak.

Ketepatan prediksi menggunakan model JST masih lebih rendah dibandingkan dengan ketepatan prediksi menggunakan algoritma yang lain. Oleh karena itu pada penelitian ini akan dikembangkan model JST dengan menggunakan algoritma propagasi balik untuk membandingkan apakah model algoritma propagasi balik yang akan dibuat memiliki ketepatan lebih tinggi dibandingkan dengan model yang sudah dikembangkan sebelumnya.

Tujuan Penelitian

Tujuan dari penelitian ini ialah:

1. Mengembangkan model JST untuk memprediksi jenis penyakit *erythemato-squamous* menggunakan algoritma pembelajaran propagasi balik dengan metode inisialisasi pembobot Nguyen-Widrow dan acak. Lalu membandingkan ketepatan prediksi dari kedua model tersebut.
2. Menentukan jumlah *neuron* tersembunyi yang menghasilkan ketepatan prediksi tertinggi pada masing-masing model.
3. Membandingkan kinerja model yang dikembangkan dengan model JST yang telah ada.

Ruang Lingkup

Penelitian ini mengembangkan model JST dengan menggunakan data dari hasil diagnosa terhadap pasien. Teknik pembelajaran yang digunakan ialah propagasi balik (*backpropagation*). Metode inisialisasi untuk pembobot awal pada lapisan input dan lapisan tersembunyi ialah metode Nguyen-Widrow dan acak. Jumlah *neuron* pada lapisan tersembunyi ditentukan sebanyak 6, 12 dan 17 *neuron*, kemudian dicari jumlah *neuron* yang memberikan ketepatan prediksi paling optimal. Laju pembelajaran yang digunakan dibuat tetap dengan nilai 0.1.

Manfaat Penelitian

Manfaat dari penelitian ini ialah mengetahui pengaruh inisialisasi pembobot awal menggunakan metode Nguyen-Widrow dan acak terhadap ketepatan prediksi JST pada penyakit *erythematous-squamous*.

TINJAUAN PUSTAKA

Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan suatu sistem pemroses informasi yang memiliki persamaan secara umum dengan cara kerja jaringan syaraf biologi (Fausett 1994). Setiap syaraf tiruan menerima satu set input. Setiap input dikalikan dengan sebuah pembobot (*weight*) yang bersesuaian dengan kekuatan *synapsis*. Jumlah seluruh pembobot tersebut menentukan kemungkinan syaraf untuk menembakkan sinyal. Nilai ini disebut tingkat aktivasi (*activation level*). Secara matematis, untuk suatu syaraf, setiap input X_i dimodulasikan oleh sebuah pembobot W_i sehingga jumlah total input dinyatakan sebagai:

$$\sum_i X_i W_i \dots\dots\dots (1)$$

atau dalam bentuk vektor, $X.W$, dimana $X = [X_1, X_2, \dots, X_n]$ dan $W = [W_1, W_2, \dots, W_n]$. Sinyal input selanjutnya diproses oleh fungsi aktivasi untuk menghasilkan sinyal output, yang jika tidak nol, akan ditransmisikan sebagai output (Fu 1994).

Menurut Fausett (1994), suatu JST dicirikan oleh tiga hal sebagai berikut:

1. **Arsitektur jaringan syaraf tiruan**
 Arsitektur jaringan ialah pengaturan *neuron* dalam suatu lapisan, pola hubungan dalam lapisan dan di antara lapisan. Dalam JST, *neuron-neuron* diatur dalam sebuah lapisan (*layer*). Ada 3 tipe lapisan, yaitu lapisan input, lapisan tersembunyi dan lapisan output. Jaringan *neuron* dikelompokkan sebagai lapis tunggal dan lapis banyak.
2. **Metode pembelajaran untuk penentuan pembobot koneksi.**
 Metode pembelajaran digunakan untuk menentukan nilai pembobot yang akan digunakan pada saat pengujian.
3. **Fungsi aktivasi yang digunakan.**
 Fungsi aktivasi merupakan fungsi yang menentukan level aktivasi, yaitu keadaan internal sebuah *neuron*

dalam JST. Keluaran aktivasi ini biasanya dikirim sebagai sinyal ke *neuron* lainnya.

JST Propagasi Balik Standar

Menurut Fu (1994), jaringan propagasi balik merupakan jaringan umpan maju berlapis banyak. Aturan pembelajaran propagasi balik disebut *backpropagation* yang merupakan jenis dari teknik *gradient descent* dengan *backward error (gradient) propagation*.

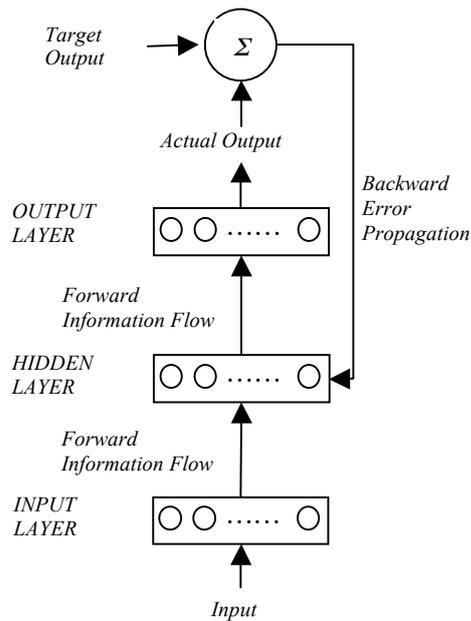
Fungsi aktivasi yang digunakan dalam propagasi balik ialah fungsi sigmoid. Hal ini disebabkan karena dalam jaringan propagasi balik fungsi aktivasi yang digunakan harus kontinu, dapat didiferensialkan, dan monoton naik (Fausett 1994). Salah satu fungsi aktivasi yang paling banyak digunakan ialah sigmoid biner, yang memiliki selang [0, 1] dan didefinisikan sebagai:

$$f_1(x) = \frac{1}{1 + \exp(-x)} \dots\dots\dots (2)$$

Fungsi aktivasi lain yang biasa digunakan ialah sigmoid bipolar, yang memiliki selang nilai [-1, 1], dan didefinisikan sebagai:

$$f_2(x) = \frac{2}{1 + \exp(-x)} - 1 \dots\dots\dots (3)$$

Jaringan ini menggunakan metode pembelajaran dengan pengarahannya (*supervised learning*). Pemilihan metode inisialisasi pembobot dan bias berpengaruh pada kecepatan JST dalam mencapai kekonvergenan. (Fausett, 1994). Jaringan propagasi balik ditunjukkan dalam Gambar 4.



Gambar 1 Arsitektur jaringan propagasi balik (Fu 1994).

Pada pelatihan JST propagasi balik terdapat tiga tahapan, yaitu pelatihan input yang bersifat umpan maju, penghitungan galat, dan penyesuaian pembobot. Secara umum cara kerja JST propagasi balik ada beberapa langkah. Pertama, pola input dan target dimasukkan ke dalam jaringan. Selanjutnya pola input ini akan berubah sesuai dengan propagasi pola tersebut ke lapisan-lapisan berikutnya hingga menghasilkan output. Output ini akan dibandingkan dengan target. Apabila dari hasil

perbandingan ini dihasilkan nilai yang sama, proses pembelajaran akan berhenti. Tetapi apabila berbeda, maka jaringan mengubah pembobot yang ada pada hubungan antar *neuron* dengan suatu aturan tertentu agar nilai output lebih mendekati nilai target. Proses pengubahan pembobot adalah dengan cara mempropagasikan kembali nilai korelasi galat output jaringan ke lapisan-lapisan sebelumnya (propagasi balik). Kemudian dari lapisan input, pola akan diproses lagi untuk mengubah nilai pembobot, hingga akhirnya memperoleh output jaringan baru. Proses ini dilakukan berulang-ulang sampai diperoleh nilai yang sama atau minimal sesuai dengan galat yang diinginkan. Proses perubahan pembobot inilah yang disebut proses pembelajaran.

Algoritma propagasi balik ialah sebagai berikut (Fu 1994):

- Inisialisasi pembobot.
Tentukan semua pembobot dan *threshold* untuk tiap *node* dengan nilai yang kecil. *Threshold* untuk *node* ialah negatif dari pembobot dari unit bias (yang level aktivasinya ditetapkan 1).
- Penghitungan fungsi aktivasi.
 1. Tingkat aktivasi unit input ditentukan oleh contoh yang telah diberikan pada *network*.
 2. Tingkat aktivasi O_j unit tersembunyi dan output ditentukan oleh:

$$O_j = F\left(\sum W_{ji} O_i - \theta_j\right) \dots\dots (4)$$

Dimana W_{ji} adalah pembobot dari unit O_i , θ_j ialah *threshold* dari *node*, dan F adalah fungsi sigmoid:

$$F(\alpha) = \frac{1}{1 + e^{-\alpha}} \dots\dots\dots (5)$$

- Pelatihan bobot.
 1. Dimulai dari unit-unit output dan dilakukan *backward* menuju lapisan tersembunyi secara rekursif. Perubahan pembobot sebagai berikut:

$$W_{ji}(t + 1) = w_{ji}(t) + \Delta w_{ji} \dots\dots (6)$$

Dengan $W_{ji}(t)$ adalah pembobot dari unit i ke unit j pada saat t iterasi ke- t dan ΔW_{ji} adalah koreksi pembobot.

2. Perubahan pembobot dihitung dengan:

$$\Delta W_{ji} = \eta \delta_j O_i \dots\dots\dots (7)$$

Dengan η adalah *trial independent learning rate* dan δ_j adalah *error gradient* pada unit j .

3. *Error gradient* dihitung sebagai berikut:

- untuk unit output:
 $\delta_j = O_j(1-O_j)(T_j-O_j) \dots\dots\dots (8)$

Dengan T_j adalah aktivasi output (target yang diharapkan dan O_j adalah aktivasi output aktual pada unit output j).

- untuk lapisan tersembunyi:
 $\delta_j = O_j(1-O_j) \sum \delta_k W_{kj} \dots\dots\dots (9)$

Dengan δ_j adalah *error gradient* pada unit k yang memiliki koneksi dari unit tersembunyi j .

3. Iterasi diulangi sampai konvergen terhadap kriteria *error* yang ditentukan. Satu iterasi meliputi pemberian contoh, penghitungan aktivasi dan modifikasi pembobot.

Inisialisasi Pembobot Acak

Pemilihan pembobot awal sangat mempengaruhi jaringan syaraf tiruan dalam mencapai minimum global (atau lokal saja) terhadap nilai *error*, serta cepat tidaknya proses pelatihan menuju kekonvergenan. Biasanya pembobot awal diinisialisasi secara acak dengan nilai antara -0.5 sampai 0.5 (atau -1 sampai 1, atau interval yang lainnya) (Fausett 1994).

Inisialisasi Pembobot Nguyen-Widrow

Inisialisasi pembobot dari *neuron* input ke *neuron* tersembunyi bertujuan untuk meningkatkan kemampuan *neuron-neuron* tersembunyi untuk melakukan pembelajaran. Inisialisasi Nguyen-Widrow didefinisikan sebagai persamaan berikut (Fausett 1994):

- Hitung harga faktor penskalaan β
 $\beta = 0.7 p^{1/n} \dots\dots\dots (10)$

dimana:

- β = faktor penskalaan
- n = jumlah *neuron* lapisan input
- p = jumlah *neuron* lapisan tersembunyi

- Untuk setiap unit tersembunyi ($j=1, 2, \dots, p$):
 - Hitung v_{ij} (lama) yaitu bilangan acak diantara -0.5 dan 0.5 (atau diantara $-\gamma$ dan $+\gamma$). Pembaharuan pembobot v_{ij} (lama) menjadi v_{ij} baru yaitu:

$$v_{ij}(\text{baru}) = \frac{\beta v_{ij}(\text{lama})}{\|v_j(\text{lama})\|} \dots\dots\dots (11)$$

- Tetapkan Bias.
 v_{ij} = Pembobot pada bias bernilai antara $-\beta$ dan β .

K-means Clustering

K-means clustering, yang juga dikenal sebagai *C-means clustering*, telah diterapkan dalam berbagai bidang, termasuk kompresi data citra dan suara, praproses data untuk pemodelan sistem menggunakan jaringan *radial basis function*, dan *task decomposition* pada arsitektur jaringan syaraf tiruan yang heterogen. Algoritma *K-means* membagi sekumpulan n vektor ke dalam beberapa kelompok, dan mencari pusat dari setiap kelompok sehingga fungsi biaya dari jarak dapat diminimalkan. (Jang, Sun dan Mizutani 1997).

Misalkan ada n individu dan p variabel. Ditunjukkan oleh $X(i, j)$, nilai individu ke- i pada variabel ke- j ; $i = 1, 2, \dots, n, j = 1, 2, \dots, p$. Asumsikan bahwa ukuran-ukuran yang dikumpulkan memiliki sifat yang memungkinkan jarak Euclid antara individu-individu tersebut dapat dihitung. Misalkan $P(n, K)$ ialah pembagian yang menunjukkan masing-masing individu n dialokasikan ke dalam salah satu kelompok $1, 2, \dots, K$. Rataan dari variabel ke- j pada kelompok ke- l akan dinotasikan dengan $\bar{X}(l, j)$ dan banyaknya individu yang termasuk ke dalam kelompok ke- l ialah $n(l)$. Pada notasi ini dapat dinyatakan bahwa jarak antara individu ke- i dengan kelompok ke- l ialah:

$$D(i, l) = \left(\sum_{j=1}^p [X(i, j) - \bar{X}(l, j)]^2 \right)^{1/2} \dots\dots (12)$$

Ditentukan:

$$E[P(n, K)] = \sum_{i=1}^n D[i, l(i)]^2 \dots\dots\dots (13)$$

adalah komponen kesalahan dari pembagian tersebut, dengan $l(i)$ ialah kelompok yang mengandung individu ke- i , dan $D[i, l(i)]$ ialah jarak Euclid antara individu i dengan rata-rata kelompok tempat individu tersebut berada. Prosedur untuk pengelompokan ialah sebagai berikut: mencari bagian yang memiliki komponen kesalahan kecil E dengan cara memindahkan individu-individu dari kelompok satu ke kelompok lain sampai tidak terjadi perpindahan individu yang mengakibatkan penurunan E .

Validasi Silang

Sejumlah teknik telah dikembangkan untuk validasi sistem cerdas. Salah satu teknik yang dikembangkan ialah *cross validation*. *Cross validation* (validasi silang) merupakan salah satu teknik pendugaan *error rate*. *K-fold cross validation* melakukan pengulangan sebanyak k kali untuk sample yang dibagi secara acak ke dalam k himpunan bagian yang terpisah. Setiap pengulangan terdapat satu bagian untuk proses pengujian dan sisanya ($k-1$ bagian) sebagai data pelatihan, sehingga terdapat sebanyak k pengulangan. Alasan penggunaan teknik validasi silang karena teknik ini sesuai diterapkan untuk data yang berukuran kecil maupun besar (Fu 1994).

METODE PENELITIAN

Data

Data yang digunakan dalam penelitian ini berasal dari (Merz dan Murphy 1996 dalam Kustiyo 2004) yang merupakan hasil pemeriksaan terhadap 366 pasien penderita penyakit *erythemat-squamous*. Namun, dari 366 data tersebut, terdapat 8 pasien yang tidak tercatat umurnya, sehingga data yang digunakan hanya data yang lengkap, yaitu sebanyak 358. Jumlah tersebut tersebar dalam 6 kelas jenis penyakit seperti yang terlihat dalam Tabel 1.

Tabel 1 Persebaran kelas penyakit *erythemat-squamous*

Kelas	Kelas penyakit	Jumlah
1	<i>psoriasis</i>	111
2	<i>seboreic dermatitis</i>	60
3	<i>lichen planus</i>	71
4	<i>pityriasis rosea</i>	48
5	<i>chronic dermatitis</i>	48
6	<i>pityriasis rubra pilaris</i>	20

Data tersebut berasal dari pemeriksaan klinis dan histopatologis. Pemeriksaan klinis meliputi dua belas ciri-ciri klinis, antara lain umur, *erythema* dan *scaling*. Sedangkan pada pemeriksaan histopatologis terdapat dua puluh dua ciri, antara lain *melanin incontinence*, *hyperkeratosis* dan *spongiosis*.

Secara keseluruhan terdapat 34 ciri-ciri klinis dan histopatologis yang digunakan untuk menentukan jenis penyakit *erythemat-squamous*. Setiap ciri-ciri, baik klinis maupun histopatologis diberi nilai antara 0 sampai 3 kecuali ciri *family history* dan umur. Nilai 0 menunjukkan tidak terdapat ciri tersebut, nilai 3 menunjukkan kemungkinan terbesar adanya ciri,

sedangkan nilai 1 dan 2 menunjukkan nilai pertengahan. *Family history* memiliki nilai 1 jika terdapat riwayat jenis penyakit tersebut pada keluarga pasien yang didiagnosis dan nilai 0 jika tidak ditemukan.

Pada penelitian ini, umur pasien dikelompokkan menjadi empat kelompok menggunakan *k-means clustering*. Umur pasien memiliki rentang nilai dari 0 sampai 75 tahun. Setelah diolah menggunakan *k-means clustering*, terdapat empat kelompok usia dengan skala nominal, yaitu 1, 2, 3 dan 4. Namun, pada pengelompokan ini, nilai yang lebih besar menunjukkan kelompok umur yang lebih besar pula. Dengan demikian, ciri umur merupakan variabel berskala ordinal. Hasil pengelompokan umur tersebut ditunjukkan dalam Tabel 2.

Tabel 2 Hasil pengelompokan umur menggunakan metode *k-means clustering*

Kelompok	Pusat Kelompok	Kelas umur	Jumlah Anggota
1	16	00-23 tahun	82
2	31	24-38 tahun	119
3	46	39-52 tahun	102
4	60	53-75 tahun	55

Validasi Silang

Teknik validasi silang yang digunakan dalam penelitian ini ialah *3-fold cross validation*. Teknik ini membagi data menjadi 3 *sub sample* terpisah. Dua *sub sample* akan digunakan sebagai data pelatihan dan satu *sub sample* akan digunakan sebagai data pengujian, sehingga akan terdapat tiga pasang data pelatihan-pengujian. Dalam membagi data menjadi tiga *sub sample*, langkah-langkah yang dilakukan ialah sebagai berikut:

1. Data dikelompokkan berdasarkan kelas penyakit. Penyakit *erythemat-squamous* terbagi ke dalam enam kelas penyakit yang dikodekan menjadi 1, 2, 3, 4, 5 dan 6, sehingga terdapat 6 kelas. Contoh hasil langkah ini dapat dilihat dalam Tabel 3.

Tabel 3 Pengelompokan data berdasarkan kelas penyakit

X1	X2	X3	...	X34	Kelas
1	2	3	...	2	1
2	1	1	...	1	1
1	0	3	...	4	2
3	2	2	...	2	2
2	2	0	...	3	3
0	2	1	...	3	3

2. Untuk setiap kelas, data dibagi menjadi tiga *sub sample* dengan cara diberi kode 1, 2 dan 3 secara terurut. Kode tersebut diulangi sampai pada data terakhir dari setiap kelas. Contoh hasil langkah ini dapat dilihat dalam Tabel 4.

Tabel 4 Pemberian kode terhadap data

X1	X2	X3	...	X34	Kelas	Kode
1	2	3	...	2	1	1
2	1	1	...	1	1	2

X1	X2	X3	...	X34	Kelas	Kode
0	1	2	...	1	1	3
2	1	3	...	3	1	1
1	3	0	...	2	1	2
3	3	1	...	4	1	3

3. Kode 1,2 dan 3 diacak, sehingga terdapat pasangan data-kode acak *sub sample* untuk setiap kelas. Contoh hasil langkah ini dapat dilihat dalam Tabel 5.

Tabel 5 Pengacakan kode

X1	X2	...	X34	Kelas	Kode	Kode acak
1	2	...	2	1	1	3
2	1	...	1	1	2	1
0	1	...	4	1	3	1
2	1	...	4	1	1	2
1	3	...	3	1	2	3
3	3	...	1	1	3	2

4. Data dari setiap kelas yang memiliki kode acak yang sama dikelompokkan, sehingga terdapat 3 *sub sample* yang masing-masing *sub sample* terdiri atas 6 kelas penyakit. Contoh hasil langkah ini dapat dilihat dalam Tabel 6.

Tabel 6 Contoh data *sub sample* 1

X1	X2	X3	...	X34	Kelas	Kode acak
2	1	1	...	1	1	1
0	1	2	...	3	1	1
1	2	2	...	2	2	1
3	0	1	...	3	2	1
0	0	2	...	4	3	1
1	1	1	...	4	3	1

Hasil dari proses tersebut terdapat tiga bagian data yang merupakan pasangan data pelatihan dan data pengujian seperti yang terlihat dalam Tabel 7.

Tabel 7 Pasangan data pelatihan dan data pengujian

Data	Pelatihan	Pengujian
1	<i>Sub sample</i> 1 dan 2	<i>Sub sample</i> 3
2	<i>Sub sample</i> 1 dan 3	<i>Sub sample</i> 2
3	<i>Sub sample</i> 2 dan 3	<i>Sub sample</i> 1

Perancangan Model JST

Model JST yang akan dikembangkan merupakan *multilayer perceptron* dengan pelatihan menggunakan algoritma propagasi balik. Struktur JST dapat dilihat dalam Tabel 8.

Tabel 8 Struktur JST yang dikembangkan

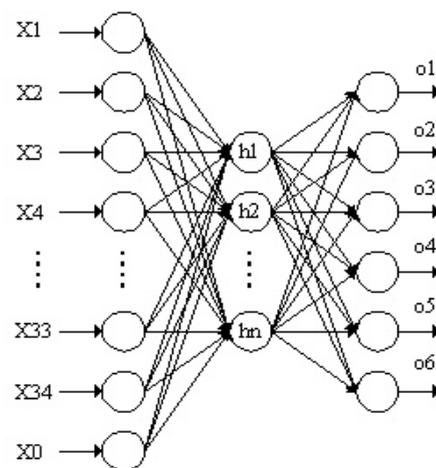
KARAKTERISTIK	SPESIFIKASI
Arsitektur	1 lapisan tersembunyi
Neuron Input	34 (ciri-ciri klinis dan histopatologis)
Neuron lapis tersembunyi	6, 12, 17
Neuron Output	6 (target 6 kelas penyakit)
Fungsi Aktivasi lapis tersembunyi	Sigmoid biner
Fungsi Aktivasi lapis output	Sigmoid biner
Inisialisasi Pembobot	Nguyen-Widrow dan Acak
Toleransi galat	0.001
Maksimal epoh	18000 epoh
Laju Pembelajaran	0.1

Target didefinisikan pada Tabel 9. Nilai 1 merepresentasikan kelas penyakit. Misalnya untuk target dengan nilai elemen pertama satu dan yang lainnya bernilai nol (100000) maka target tersebut menunjukkan target pertama.

Tabel 9 Definisi target jaringan

Kelas	Jenis penyakit	Target
1	<i>psoriasis</i>	100000
2	<i>seboreic dermatitis</i>	010000
3	<i>lichen planus</i>	001000
4	<i>pityriasis rosea</i>	000100
5	<i>cronic dermatitis</i>	000010
6	<i>pityriasis rubra pilaris</i>	000001

Gambar arsitektur JST yang akan dikembangkan terlihat pada Gambar 5.



Gambar 2 Arsitektur JST.

Pengujian Model

Pengujian model dilakukan dengan menguji model menggunakan data pengujian setelah dilakukan pelatihan. Ketepatan model diukur dari ketepatan model dalam memprediksi dan *mean square error (mse/galat)*. Dengan metode validasi silang, ketepatan model ialah jumlah klasifikasi yang tepat dibagi dengan banyaknya contoh pada himpunan data tersebut (Arana *et al.* 1999). Sedangkan *mse* dihitung dengan rumus sebagai berikut:

$$mse = \frac{\sum (Y_i - Y_i')^2}{n} \dots\dots\dots (16)$$

dengan:

- Y_i = klasifikasi sebenarnya
- Y_i' = hasil prediksi klasifikasi model
- n = jumlah data yang diklasifikasi

Spesifikasi Perangkat Lunak dan Perangkat Keras

Program diimplementasikan menggunakan perangkat lunak Matlab 6.5. Untuk mengolah data digunakan perangkat lunak Microsoft Office Excel 2003, Minitab 13.3 dan SPSS 11.5. Sistem operasi yang digunakan ialah Microsoft Windows XP Professional.

Perangkat keras yang digunakan dalam penelitian ini ialah komputer dengan processor AMD Athlon XP 1800+, RAM DDR 512 MB, dan harddisk dengan kapasitas 40 GB.

HASIL DAN PEMBAHASAN

Tahap Praproses

Percobaan yang dilakukan merupakan kombinasi dari dua faktor, yaitu metode inisialisasi dan jumlah *neuron* tersembunyi. Metode inisialisasi memiliki dua tingkatan, yaitu Nguyen-Widrow (Model I) dan acak (Model II). Jumlah *neuron* tersembunyi memiliki tiga tingkatan, yaitu 6 *neuron*, 12 *neuron* dan 17 *neuron* tersembunyi. Dengan demikian terdapat 2 x 3 = 6 perlakuan. Masing-masing perlakuan dicobakan pada tiga bagian data, sehingga terdapat 2 x 3 x 3 = 18 unit percobaan.

Pada kedua model JST, dilakukan percobaan awal untuk mencari bobot terbaik yang akan digunakan untuk menentukan ketepatan prediksi pada langkah selanjutnya. Langkah yang dilakukan pertama kali ialah mengadakan pelatihan dan pengujian untuk setiap jumlah *neuron* tersembunyi dan setiap bagian data sebanyak sepuluh kali ulangan. Dari sepuluh kali ulangan tersebut, diambil model yang memiliki pembobot yang menghasilkan ketepatan tertinggi. Kemudian dilakukan pelatihan dan pengujian untuk data tersebut pada beberapa epoh. Dalam penelitian ini, epoh terkecil dibatasi sejumlah 1000 epoh, sedangkan yang terbesar ialah 18000 epoh dengan kenaikan setiap 1000 epoh.

Pelatihan dan pengujian dilakukan mulai dari epoh terkecil sampai epoh terbesar. Nilai ketepatan prediksi yang diambil adalah nilai ketepatan prediksi tertinggi yang muncul dalam tiga kali secara berurutan, atau nilai ketepatan prediksi untuk pelatihan dan pengujian dengan epoh tertinggi.

Perbandingan Ketepatan Prediksi Menggunakan Metode Inisialisasi Nguyen-Widrow

Pada metode Nguyen-Widrow (Model I), untuk 6 *neuron* tersembunyi, ketepatan yang diperoleh untuk data bagian pertama sebesar 90.6% pada saat epoh 15000 dan galat sebesar 0.01953, untuk data bagian kedua 93.28% pada saat epoh 16000 dan galat sebesar 0,015213 dan untuk data bagian ketiga 90.83% pada saat epoh 16000 dan galat 0,023708. Sehingga diperoleh rata-rata 91.62% dengan simpangan baku sebesar 1.435. Pada 12 *neuron* tersembunyi, ketepatan prediksi data bagian pertama, kedua dan ketiga berturut-turut ialah 94.12% dengan epoh 14000 dan galat 0.015615, 94.96% dengan epoh 17000 dan galat 0.014033, dan 94.17% dengan epoh 18000 dan galat 0.013078. Sehingga diperoleh rata-rata 94.42% dan simpangan baku 0.471. Sedangkan pada 17 *neuron* tersembunyi ketepatan prediksi yang dihasilkan untuk data bagian pertama, kedua dan ketiga berturut-turut ialah 89.92% pada saat epoh 12000 dan galat 0.022117, 94.12% pada saat epoh 14000 dan galat 0.010866 dan 95.83% pada saat epoh 18000 dan galat 0.0096408. dari hasil tersebut rata-ratanya sebesar 93.29% dan simpangan baku 3.041. Hasil ketepatan prediksi selengkapnya dapat dilihat dalam Tabel 10.

Berdasarkan data dalam Tabel 10 terlihat bahwa ketika jumlah *neuron* ditambah dari 6 *neuron* menjadi 12 *neuron*, ketepatan prediksi meningkat. Namun, ketika jumlah *neuron* dinaikkan dari 12 menjadi 17, ketepatan prediksi justru menurun, kecuali untuk data ke-3. Dengan demikian, kenaikan jumlah *neuron* dalam lapisan tersembunyi tidak selalu menyebabkan kenaikan ketepatan. Ketepatan rata-rata tertinggi terjadi pada model yang menggunakan 12 *neuron* tersembunyi.

Tabel 10 Ketepatan prediksi Model I

Data	Ketepatan (%)		
	6 <i>neuron</i>	12 <i>neuron</i>	17 <i>neuron</i>
1	90.76	94.12	89.92
2	93.28	94.96	94.12
3	90.83	94.17	95.83
Rataan	91.62	94.42	93.29
Simpangan baku	1.435	0.471	3.041

Perbandingan Ketepatan Prediksi Menggunakan Metode Inisialisasi Acak

Pada metode acak (Model II), untuk 6 *neuron* tersembunyi, ketepatan yang diperoleh untuk data pertama sebesar 91.60% pada saat epoh 12000 dan galat 0.025114, untuk data kedua 98.32% pada saat epoh 16000 dan galat 0.015597 dan untuk data ketiga 96.67% pada saat epoh 16000 dan galat 0.019307. Sehingga diperoleh rata-rata 95.53% dengan simpangan baku sebesar 3.502. Pada 12 *neuron* tersembunyi, ketepatan yang diperoleh untuk data pertama sebesar 94.96% pada saat epoh 12000 dan galat 0.01683, untuk data kedua 97.48% pada saat epoh 18000 dan galat 0.0094548 dan untuk data ketiga 97.50% pada saat epoh 18000 dan galat 0.010477. Sehingga diperoleh rata-rata 96.65% dengan simpangan

baku sebesar 1.461. Sedangkan untuk 17 *neuron* tersembunyi ketepatan prediksi yang dihasilkan untuk data bagian pertama, kedua dan ketiga berturut-turut ialah 94.12% dengan epoh 15000 dan galat 0.014333, 96.64% dengan epoh 9000 dan galat 0.012464 dan 97.50% pada saat epoh 17000 dan galat 0.010687, dengan rata-rata sebesar 96.09% dan simpangan baku 1.757. Ketepatan prediksi Model II disajikan dalam Tabel 11.

Tabel 11 Ketepatan prediksi Model II

Data	Ketepatan (%)		
	6 <i>neuron</i>	12 <i>neuron</i>	17 <i>neuron</i>
1	91.60	94.96	94.12
2	98.32	97.48	96.64
3	96.67	97.50	97.50
Rataan	95.53	96.65	96.09
Simpangan baku	3.502	1.461	1.757

Berdasarkan data dalam Tabel 11 juga terlihat bahwa kenaikan jumlah *neuron* dalam lapisan tersembunyi tidak selalu menyebabkan kenaikan ketepatan. Ketepatan rata-rata tertinggi terjadi pada model yang menggunakan 12 *neuron* tersembunyi.

Perbandingan Metode Inisialisasi Nguyen-Widrow dan Acak

Perbandingan ketepatan prediksi rata-rata antara Model I (Nguyen-Widrow) dan Model II (acak) dapat dilihat dalam Tabel 12.

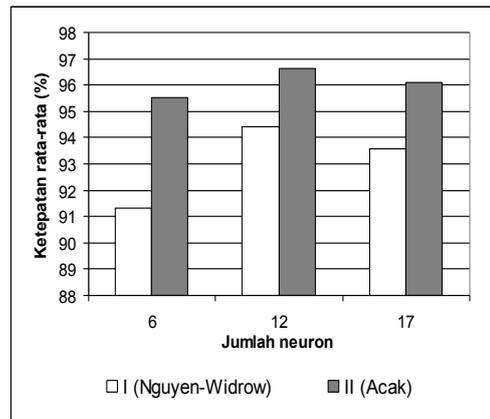
Tabel 12 Perbandingan Ketepatan Model I dan Model II

Model	Ketepatan (%)		
	6 <i>neuron</i>	12 <i>neuron</i>	17 <i>neuron</i>
I (Nguyen-Widrow)	91.34 ± 0.950	94.42 ± 0.471	93.57 ± 3.408
II (Acak)	95.53 ± 3.502	96.65 ± 1.461	96.09 ± 1.757

Sesuai hasil yang terdapat dalam Tabel 12, terlihat bahwa untuk kedua model, rata-rata ketepatan tertinggi selalu muncul jika digunakan 12 *neuron* pada lapisan tersembunyi. Hal tersebut berarti jumlah *neuron* tersembunyi yang optimal pada penelitian kali ini adalah 12 *neuron*.

Jika dibandingkan nilai ketepatan rata-rata antara kedua model, maka terlihat bahwa untuk semua jumlah *neuron* tersembunyi nilai ketepatan rata-rata pada Model II selalu lebih besar dari nilai ketepatan rata-rata pada Model I. Untuk melihat lebih jelas perbandingan ketepatan prediksi rata-rata dari kedua model dapat dilihat pada Gambar 6.

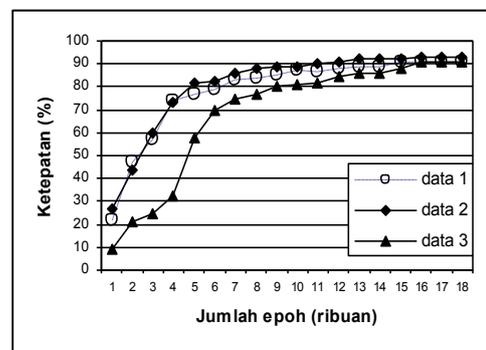
PREDIKSI JENIS PENYAKIT



Gambar 3 Perbandingan Model I dan Model II.

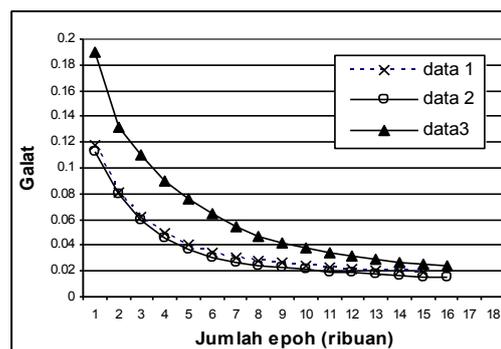
Pengaruh Jumlah Epoh Terhadap Ketepatan Prediksi dan Galat

Nilai ketepatan prediksi akan semakin besar seiring dengan peningkatan epoh. Namun, semakin besar epoh yang digunakan, maka peningkatan nilai ketepatan prediksinya semakin kecil, bahkan cenderung konstan. Gambar 7 menunjukkan pengaruh peningkatan epoh terhadap ketepatan prediksi pada Model I dengan jumlah *neuron* tersembunyi sebanyak 6.



Gambar 4 Pengaruh peningkatan epoh terhadap ketepatan prediksi pada Model I dengan 6 *neuron* tersembunyi.

Peningkatan epoh akan menyebabkan nilai galat semakin kecil. Hal ini disebabkan model semakin banyak melakukan pembelajaran, sehingga ketepatan yang dihasilkan semakin meningkat dan galatnya semakin menurun. Namun, semakin besar epoh yang digunakan maka penurunan nilai galat semakin kecil. Gambar 8 menunjukkan pengaruh peningkatan epoh terhadap galat pada Model I dengan 6 *neuron* tersembunyi.



Gambar 5 Pengaruh peningkatan epoch terhadap galat pada Model I dengan 6 *neuron* tersembunyi.

Perbandingan dengan Hasil Penelitian yang lain

Hasil prediksi model JST yang dikembangkan pada penelitian ini memiliki ketepatan yang lebih tinggi dibandingkan dengan model JST sebelumnya, yaitu JST dengan inialisasi pembobot awal menggunakan regresi logistik biner, menggunakan metode acak, dan JST dengan algoritma apriori. Hasil selengkapnya disajikan dalam Tabel 13.

Tabel 13 Perbandingan Ketepatan dengan Hasil Penelitian Lain

Model	Ketepatan (%)
Model I 6 <i>neuron</i>	91.62
Model I 12 <i>neuron</i>	94.42
Model I 17 <i>neuron</i>	93.29
Model II 6 <i>neuron</i>	95.53
Model II 12 <i>neuron</i>	96.65
Model II 17 <i>neuron</i>	96.09
JST- regresi logistik biner - 6 <i>neuron</i> tersembunyi ¹⁾	94.40
JST - acak - 6 <i>neuron</i> tersembunyi ¹⁾	76.02
JST algoritma propagasi balik dan apriori ²⁾	68.00

Pada Tabel 13 di atas terlihat bahwa sebelumnya telah terdapat penelitian yang menggunakan JST dengan 6 *neuron* tersembunyi yang menggunakan inialisasi pembobot regresi logistik biner dan acak. Dari hasil penelitian ini, ketepatan prediksi Model I (Nguyen-Widrow) pada 6 *neuron* tersembunyi lebih kecil dibandingkan dengan hasil pada penelitian sebelumnya, yaitu 91.62%. Hal ini disebabkan adanya perbedaan dalam inialisasi pembobot awal, banyaknya pengulangan untuk mencari pembobot terbaik, pengelompokan umur, fungsi aktivasi dan jumlah epoch maksimal.

Penggunaan metode inialisasi acak pada penelitian sebelumnya menghasilkan ketepatan prediksi sebesar 76.02%. Pada penelitian ini, untuk metode acak dengan 6 *neuron* tersembunyi, ketepatan prediksi yang dihasilkan lebih besar, yaitu sebesar 95.53%. Hal ini disebabkan adanya perbedaan dalam melakukan pengulangan untuk mencari pembobot terbaik, pengelompokan umur, fungsi aktivasi dan banyaknya epoch maksimal yang diperkenankan. Pada penelitian sebelumnya, untuk menentukan pembobot yang menghasilkan ketepatan prediksi tertinggi dilakukan pengulangan sebanyak tiga kali, sedangkan pada penelitian ini diulang sebanyak sepuluh kali. Ciri umur pada penelitian sebelumnya tidak dikelompokkan ke dalam kelompok tertentu. Pada penelitian ini ciri umur dikelompokkan ke dalam empat kelompok dengan menggunakan metode *k-means clustering*. Fungsi aktivasi lapis kedua pada penelitian sebelumnya ialah linier, sedangkan penelitian ini menggunakan fungsi aktivasi sigmoid biner. Pada

penelitian sebelumnya, jumlah epoch maksimal ialah 15000 epoch sedangkan pada penelitian ini sebanyak 18000 epoch.

KESIMPULAN DAN SARAN

Kesimpulan

Kesimpulan yang dapat ditarik berdasarkan penelitian yang telah dilakukan ialah:

1. Pada penelitian ini, model JST dengan inialisasi pembobot awal acak selalu menghasilkan nilai ketepatan prediksi rata-rata yang lebih tinggi daripada model JST dengan inialisasi pembobot awal Nguyen-Widrow. Pada metode inialisasi pembobot Nguyen-Widrow, untuk jumlah *neuron* tersembunyi 6 ketepatan prediksinya sebesar 91.62%, sedangkan untuk acak sebesar 95.53%. Untuk jumlah *neuron* tersembunyi 12, ketepatan prediksi rata-rata Nguyen-Widrow sebesar 94.42% dan acak sebesar 96.65%. Pada jumlah *neuron* tersembunyi 17 rata-rata ketepatan prediksi Nguyen-Widrow dan acak berturut-turut sebesar 93.29% dan 96.09%.
2. Pada model JST dengan inialisasi pembobot awal Nguyen-Widrow dan acak, rata-rata ketepatan prediksi tertinggi terjadi ketika digunakan 12 *neuron* pada lapisan tersembunyi.
3. Kedua model JST yang digunakan mampu menghasilkan nilai ketepatan yang lebih tinggi dibandingkan dengan penelitian sejenis yang telah dilakukan sebelumnya.

Saran

Penulis mengharapkan agar penelitian ini dapat dikembangkan lagi pada penelitian-penelitian selanjutnya. Misalnya, pemilihan jumlah *neuron* pada lapisan tersembunyi ditentukan dengan menggunakan algoritma genetika. Untuk mengoptimalkan pelatihan, dapat menggunakan algoritma pelatihan yang lain, misalnya *gradient descent* dengan momentum atau *resilient propagation*.

DAFTAR PUSTAKA

- Arana E, Delicado P, Bonmati ML 1999. "Validation procedures in radiological diagnostic models. Neural networks and logistik regression". <http://www.econ.upf.es/deehome/what/wpapers/postsc ripts/414.pdf>
- Fausett L. 1994. *Fundamentals of Neural Network*. New York: Prentice Hall.
- Fu LM. 1994. *Neural Networks in Computer Intelligence*. Singapore: Mc Graw-Hill.
- Güvenir HA, Demiröz G, İltner N. 1998. Learning differential diagnosis of *erythematous-squamous* diseases using voting feature intervals. *Artificial Intelligence in Medicine* 13: 147-165. [3 Agustus 2005].
- Jang J-SR, Sun C-T, Mizutani E. 1997. *Soft Computing and Neuro-Fuzzy*. New Jersey: Prentice-Hall International, Inc.
- Kustiyo A. 2004. Model *Neural Network* dengan Inialisasi Pembobot Awal Menggunakan Regresi Logistik Biner untuk Memprediksi Jenis Penyakit

¹ Kustiyo 2004

² Lay et al. 1999

Erythematous-squamous [Tesis]. Surabaya: Fakultas Teknologi Informasi, Institut Teknologi Sepuluh November.

Lay B, Khalid M, Yusof R. 1999. Intelligent Database by Neural Network and Data Mining. http://www.cairo.utm.my/4_cairo_publications.htm.

Merz C, Murphy M. 1996. UCI repository of machine learning databases. University of California, Irvine, Department of Information and Computer Science. <http://www.ics.uci.edu/pub/machine-learning-databases>.