

REKAYASA SISTEM NEURO-FUZZY UNTUK IDENTIFIKASI JENIS KAYU BANGUNAN DAN FURNITURE

Florensa Rosani Br Purba

Teknik Informatika, Fakultas Teknologi Informasi Universitas Kristen Krida Wacana Jakarta
Jl. Tanjung Duren Raya No.4 Jakarta Barat 11470
Telp. (012) 5666952-5 Ext.506, Fax.5999956
Email: frpnop@yahoo.com

ABSTRAK

There are two major class of characteristics for wood species identification. The first class is general characteristics such as colour, odour, wood grain, texture etc, those can be observed directly by common sense, namely the eyes without using additional tools except a loupe with at least ten times magnification. The second class is anatomical characteristics which provide wood structure including morphology and type of cell wood components as well as their distribution, which can be observed by using microscope. By the artificial intelligence system, wood species which one commonly used for industries become easier to identify. It takes shorter time compared with the conventional activity. Aim of research was to create the neuro-fuzzy system model, which able to identify wood species for construction and furniture utilizations based on their wood anatomical characteristics, namely vessel element (their distribution, frequency and size) and ray parenchyma (frequency, wide, high). Objects in this research were rubber wood, keruing, kamper, acacia, meranti and jelutong.

The Neuro-Fuzzy System developed could identify with 0% errorness if the system using the same data in the training process or using training sintetic data more than 1000 data.

Kata Kunci: anatomic characteristic, neuro-fuzzy, wood class identification.

1. PENDAHULUAN

Secara garis besar ada dua kelompok ciri yang digunakan untuk mengidentifikasi jenis kayu, yaitu ciri umum dan ciri anatomi. Ciri umum adalah ciri yang dapat diamati langsung dengan pancaindera, baik dengan penglihatan, penciuman, perabaan dan sebagainya tanpa bantuan alat-alat pembesar bayangan. Ciri anatomi meliputi susunan, bentuk, dan ukuran sel atau jaringan penyusun yang hanya dapat diamati secara jelas dengan mikroskop atau bantuan lup berkekuatan pembesaran minimal sepuluh kali (Mandang dan Pandit, 2002).

Secara teoritis metode identifikasi jenis kayu dapat dipelajari sebagai suatu pengetahuan dan melalui proses latihan yang rutin. Permasalahannya adalah apabila petugas yang mengidentifikasi jenis kayu belum terlalu terampil, maka waktu yang dibutuhkan untuk serangkaian kegiatan pengujian kayu menjadi lebih lama.

Sistem cerdas yang dapat melakukan identifikasi jenis kayu akan sangat membantu dalam proses kegiatan identifikasi jenis kayu, terutama untuk petugas yang belum terlalu terampil.

Penelitian ini adalah untuk membuat model sistem *neuro-fuzzy* yang dapat melakukan identifikasi jenis kayu bangunan dan *furniture* berdasarkan ciri anatomi kayu susunan pori, ukuran pori, frekuensi pori, frekuensi jari-jari, lebar jari-jari, dan tinggi jari-jari. Jenis kayu yang menjadi obyek dalam penelitian ini adalah karet, keruing, kapur, akasia, balau, dan jelutong.

Salah satu penelitian yang menggunakan *neuro-fuzzy* adalah penelitian untuk menyelesaikan masalah *multiobjective control* (I-Fang, 2000). Penelitian ini mengusulkan *neuro-fuzzy combiner* (NFC) dengan menggunakan metode belajar *supervised* untuk menyelesaikan masalah-masalah *multiobjective control*. Secara prinsip NFC yang diusulkan dapat mengkombinasikan *n low-level controller* secara hirarki untuk membentuk *contoller fuzzy multiobjective*. Aturan-aturan yang ada pada NFC digunakan *n low-level controller* untuk menentukan langkah-langkah yang sesuai dalam memperlakukan *environment (plant)*.

2. TUJUAN PENELITIAN

Penelitian ini bertujuan untuk membuat model rekayasa sistem *neuro-fuzzy* yang dapat mengidentifikasi jenis-jenis kayu bangunan dan *furniture* dengan kesalahan identifikasi rata-rata maksimal 1%. Selain itu penelitian mengenai *neuro-fuzzy* ini juga mempunyai tujuan:

- Membandingkan kinerja tiga jenis algoritma training jaringan saraf tiruan yang dapat diaplikasikan untuk pemodelan identifikasi jenis-jenis kayu.
- Menentukan jumlah data training minimal agar diperoleh kesalahan validasi dan testing rata-rata 0%.
- Menentukan korelasi pola data training dengan kinerja training jaringan saraf tiruan.

- d. Menentukan kesalahan identifikasi rata-rata hasil training set data sintesis secara *online* menggunakan data riil.

3. MANFAAT

Manfaat dari penelitian ini adalah untuk membantu proses kegiatan identifikasi jenis kayu karet, keruing, kapur, akasia, balau, dan jelutung berdasarkan ciri anatomi kayu, terutama untuk petugas yang belum terlalu terampil.

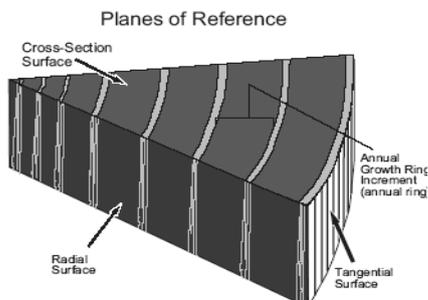
4. RUANG LINGKUP

Ruang lingkup penelitian ini adalah model sistem *neuro-fuzzy* yang dapat melakukan identifikasi jenis kayu bangunan dan *furniture* berdasarkan ciri anatomi kayu yang meliputi: susunan pori, ukuran pori, frekuensi pori, frekuensi jari-jari, lebar jari-jari, dan tinggi jari-jari. Sedangkan jenis kayu yang menjadi lingkup obyek penelitian ini adalah: karet, keruing, kapur, akasia, balau, dan jelutung.

5. TINJAUAN PUSTAKA

5.1 Metode Identifikasi Jenis Kayu

Bond and Hamner (2002) mengklasifikasikan permukaan kayu kedalam tiga kategori referensi bidang geometris, yaitu *cross section*, *radial section*, dan *tangential section* seperti terlihat pada Gambar 1.



Gambar 1. Referensi bidang geometris permukaan kayu

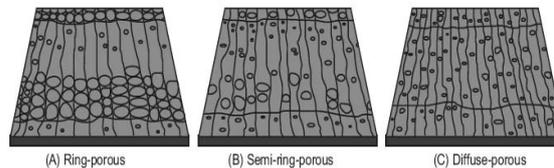
Ciri anatomi dapat dilihat pada bidang *cross-section* dengan cara memotong sel kayu secara tegak lurus dengan arah pertumbuhan pohon.

Ciri anatomi yang dapat diamati adalah:

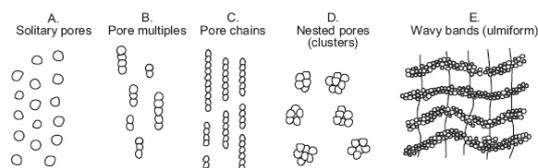
- Pori (*Vessel*), yaitu: sel yang berbentuk pembuluh dengan arah longitudinal. Berdasarkan ukuran, pori dapat diklasifikasi menjadi tiga kategori, yaitu: *Ring-porous*, *Semi-ring porous*, dan *Diffuse-porous* seperti terlihat pada Gambar 2. Sedangkan berdasarkan susunan posisi, pori dapat diklasifikasikan menjadi lima kategori, yaitu: *Solitary pores*, *Pore multiples*, *Pore chains*, *Nested pores (clusters)*, dan *Wavy bands (ulmiform)* seperti terlihat pada Gambar 3.
- Parenkim (*Parenchyma*), yaitu: sel yang ber dinding tipis berbentuk batu bata dengan arah

longitudinal. Jenis-jenis parenkim dapat dilihat pada Gambar 4.

- Jari-jari (*Rays*), yaitu: parenkim dengan arah horizontal. Jari-jari dapat dibedakan berdasarkan ukuran lebarnya dan keseragaman ukurannya

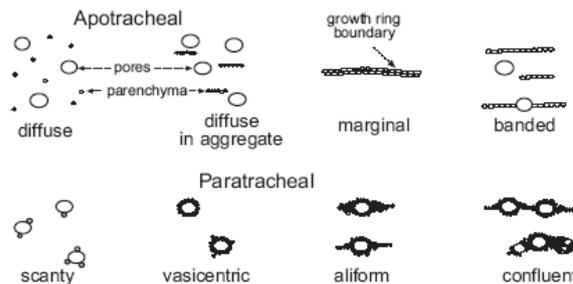


Gambar 2. Klasifikasi transisi ukuran pori



Gambar 3. Klasifikasi susunan pori

PARENCHYMA TYPES



Gambar 4. Jenis-jenis parenkim

5.2 Logika Fuzzy

Logika *fuzzy* adalah suatu cara yang tepat untuk memetakan suatu ruang *input* ke dalam suatu ruang *output* (Jang, 1997). Ada tiga hal yang harus diperhatikan untuk memahami dasar-dasar logika *fuzzy*, yaitu: himpunan *fuzzy*, fungsi keanggotaan, dan operasi logika.

Bila X adalah kumpulan obyek yang secara umum dinotasikan dengan x , maka himpunan *fuzzy* A dalam X didefinisikan sebagai himpunan pasangan berikut:

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (1)$$

dimana $\mu_A(x)$ disebut sebagai fungsi keanggotaan (*membership function*) untuk himpunan *fuzzy* A . Fungsi keanggotaan memetakan setiap elemen X ke suatu nilai keanggotaan antara 0 sampai dengan 1.

Fungsi keanggotaan (*membership function*) adalah suatu kurva yang menunjukkan pemetaan titik input data ke dalam nilai keanggotaannya yang memiliki interval 0 sampai 1 (Kusumadewi, 2003). Beberapa fungsi yang dapat digunakan adalah: *triangular*, *trapezoidal*, *generalized bell*, *gaussian*, *two-side gaussian*, kurva S, kurva Z, kurva Π ,

sigmoid, *difference of two-side sigmoid*, dan *product of two sigmoid*.

Seperti halnya pada himpunan konvensional, ada beberapa operasi yang didefinisikan secara khusus untuk mengkombinasi dan memodifikasi himpunan *fuzzy*. Beberapa operasi logika *fuzzy* yang didefinisikan oleh Zadeh adalah AND, OR, dan NOT.

Operasi AND berhubungan dengan operasi interseksi pada himpunan berikut:

$$\mu_{A \cap B} = \min(\mu_A[x], \mu_B[y]) \quad (2)$$

Operasi OR berhubungan dengan operasi union pada himpunan berikut:

$$\mu_{A \cup B} = \max(\mu_A[x], \mu_B[y]) \quad (3)$$

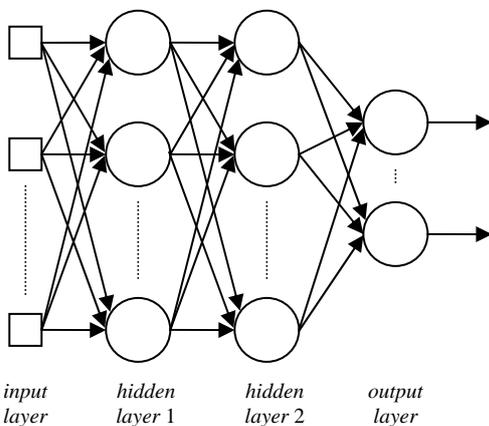
Operasi NOT berhubungan dengan operasi komplemen pada himpunan berikut:

$$\mu_{\bar{A}} = 1 - \mu_A[x] \quad (4)$$

5.3 Jaringan Saraf Tiruan *Backpropagation*

Jaringan saraf tiruan adalah suatu sistem pengolah informasi yang memiliki karakteristik kinerja tertentu yang mirip dengan jaringan saraf biologi. (Fausett, 1994).

Salah satu arsitektur jaringan saraf tiruan (JST) adalah *multilayer feedforward*. Secara umum, jaringan *feedforward L layer (multilayer)* terdiri dari: satu set unit sensor yang merupakan *input layers*, satu atau lebih ($L-1$) *hidden layer*, dan satu *output layer*, seperti terlihat pada Gambar 5.



Gambar 5. Arsitektur jaringan *multilayer L = 3*

Proses belajar jaringan *multilayer* menggunakan paradigma belajar *supervised learning* dan algoritma belajar *backpropagation* yang didasari atas aturan koreksi kesalahan. Jaringan *multilayer* dengan algoritma belajar *backpropagation* ini disebut dengan Jaringan *Backpropagation*

6. METODE PENELITIAN

6.1 Kerangka Penelitian

Dua tahap pertama dalam kerangka pemikiran adalah menentukan parameter anatomi kayu dan jenis kayu yang digunakan sebagai obyek penelitian. Parameter ciri anatomi kayu yang digunakan

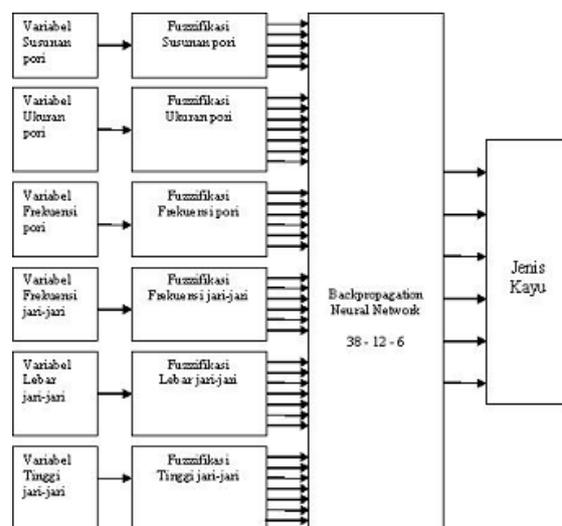
adalah: susunan pori, ukuran pori, frekuensi pori, frekuensi jari-jari, lebar jari-jari, dan tinggi jari-jari (Mandang dan Pandit, 2002). Jenis kayu bangunan dan *furniture* yang menjadi obyek penelitian adalah: kayu karet, keruing, kapur, akasia, balau, dan jelutung.

Berikutnya adalah pemodelan dan perancangan sistem cerdas yang dapat mengidentifikasi keenam jenis kayu diatas berdasarkan ciri anatominya. Sistem cerdas yang dibuat adalah sistem *neuro-fuzzy*. Untuk kebutuhan training sistem dapat digunakan set data sintesis dan set data riil.

Setelah proses training selesai, proses dilanjutkan dengan proses validasi menggunakan set data sintesis validasi. Setelah proses validasi, selanjutnya dilakukan proses testing dengan menggunakan set data testing, Pada proses validasi dan testing dilakukan pengukuran kinerjanya, yaitu prosentase kesalahan (% *error*). Setelah sistem *neuro-fuzzy* menjalankan proses training, validasi, dan testing, sistem dapat dijalankan secara *online* dengan memasukkan data riil dari ciri anatomi kayu. Berdasarkan masukan ciri anatomi kayu tersebut sistem *neuro-fuzzy* dapat mengidentifikasi jenis kayu yang sesuai.

6.2 Pemodelan Sistem

Model sistem *neuro-fuzzy* yang digunakan untuk melakukan identifikasi jenis kayu dapat dilihat pada Gambar 6. Keenam parameter ciri anatomi kayu, yaitu: susunan pori, ukuran pori, frekuensi pori, frekuensi jari-jari, lebar jari-jari dan tinggi jari-jari merupakan variabel *fuzzy*.



Gambar 6. Model sistem *neuro-fuzzy* untuk identifikasi jenis kayu

Fuzzifikasi susunan pori dibuat menjadi lima himpunan *fuzzy*, yaitu: HSB (hampir seluruhnya berganda), SBB (sebagian besar berganda), SDB (soliter dan berganda), SBS (sebagiaian besar soliter), dan HSS (hampir seluruhnya soliter).

Keluaran fuzzifikasi susunan pori bukan nilai keanggotaannya, melainkan logika biner (0 atau 1) berukuran lima bit.

Fuzzifikasi ukuran pori terdiri dari: LBK (luar biasa kecil), SK (sangat kecil), K (kecil), AK (agak kecil), AB (agak besar), B (besar), dan SB (sangat besar). Fuzzifikasi frekuensi pori terdiri dari: SJ (sangat jarang), J (jarang), AJ (agak jarang), AB (agak banyak), B (banyak), dan SB (sangat banyak).

Fuzzifikasi frekuensi jari-jari terdiri dari: SJ (sangat jarang), J (jarang), AJ (agak jarang), AB (agak banyak), B (banyak), dan SB (sangat banyak).

Fuzzifikasi lebar jari-jari terdiri dari: SSP (sangat sempit), SP (sempit), ASP (agak sempit), AL (agak lebar), L (lebar), SL (sangat lebar), dan LBL (luar biasa lebar). Fuzzifikasi tinggi jari-jari terdiri dari: LBP (luar biasa pendek), SP (sangat pendek), P (pendek), AP (agak pendek), AT (agak tinggi), T (tinggi), dan LBT (luar biasa tinggi).

Keluaran dari fuzzifikasi dari masing-masing parameter anatomi kayu yang berupa logika biner 0 atau 1 dimasukkan ke dalam jaringan saraf tiruan. Arsitektur jaringan saraf tiruan yang digunakan adalah *multilayer feedforward backpropagation*. Keluaran jaringan saraf tiruan terdiri dari enam keluaran yang merepresentasikan keenam jenis kayu secara berurutan, yaitu masing-masing: karet, keruing, kapur, akasia, balau, dan jelutung. Bentuk keluaran jaringan saraf tiruan juga berupa logika biner 0 atau 1.

7. HASIL DAN PEMBAHASAN

7.1 Kinerja Proses Training

Kinerja yang diukur pada proses training jaringan saraf tiruan adalah jumlah epoch. Hasil simulasi berupa kinerja proses training untuk algoritma training *Levenberg-Marquadt* (trainlm), *Resilent Backpropagation* (trainrp), dan *Scaled Conjugate Gradient* (trainscg) terlihat pada Tabel 1 dan Gambar 7.

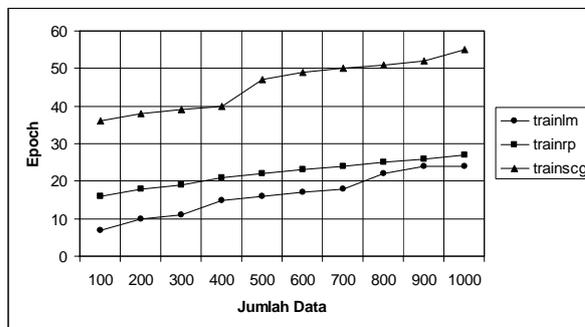
Tabel 1. Tabel kinerja proses training untuk algoritma belajar trainlm, trainrp, dan trainscg

Algoritma	Epoch untuk 100 data	Epoch untuk 200 data	Epoch untuk 300 data	Epoch untuk 400 data	Epoch untuk 500 data
trainlm	7	10	11	15	16
trainrp	16	18	19	21	22
trainscg	36	38	39	40	47
trainlm	17	18	22	24	24
trainrp	23	24	25	26	27
trainscg	49	50	51	52	55

Dari Tabel 1 dan Gambar 7 terlihat bahwa untuk masing-masing algoritma, semakin banyak jumlah data training, semakin besar jumlah epoch.

Dari Gambar 7 dapat dilihat bahwa algoritma yang proses trainingnya tercepat adalah algoritma

Levenberg-Marquadt (trainlm), kemudian diikuti oleh algoritma *Scaled Conjugate Gradient* (trainscg) dan *Resilent Backpropagation* (trainrp). Dari Tabel 1 dapat dihitung perbandingan kinerja proses training rata-rata dari ketiga jenis algoritma tersebut adalah trainlm : trainrp : trainscg = 1 : 1,35 : 2,79



Gambar 7. Grafik kinerja proses training untuk algoritma belajar trainlm, trainrp, dan trainscg

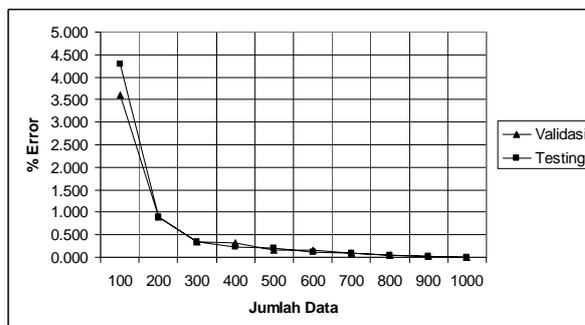
7.2 Kinerja Proses Validasi dan Testing untuk Algoritma Levenberg-Marquadt

Pada penelitian ini juga dibandingkan kinerja proses validasi dan testing untuk algoritma *Levenberg-Marquadt*. Data yang digunakan untuk simulasi adalah data sintesis masing-masing sebanyak 100, 200, sampai dengan 1000 data.

Hasil simulasi dapat dilihat pada Tabel 2 dan Gambar 8. Dari Tabel 2 dapat dilihat bahwa untuk mendapatkan kesalahan 0%, data yang dibutuhkan harus lebih besar dari 1000 data.

Tabel 2. Tabel kinerja proses validasi dan testing untuk algoritma trainlm

Proses	%error untuk 100 data	%error untuk 200 data	%error untuk 300 data	%error untuk 400 data	%error untuk 500 data
Validasi	3.600	0.900	0.333	0.325	0.160
Testing	4.300	0.900	0.333	0.225	0.200
Validasi	0.150	0.100	0.050	0.022	0.010
Testing	0.117	0.100	0.050	0.022	0.010



Gambar 8. Grafik kinerja proses validasi dan testing untuk algoritma trainlm

7.3 Kinerja Proses Validasi dan Testing untuk Algoritma Resilient Backpropagation dan Algoritma Scaled Conjugate Gradient

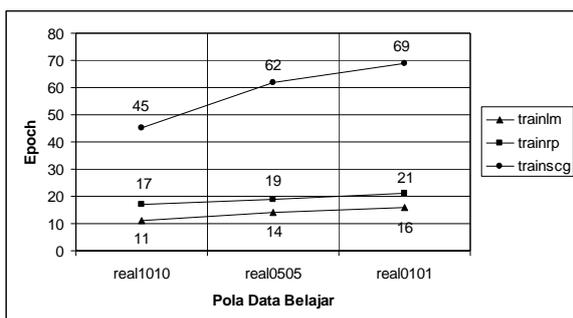
Secara tipikal seperti halnya dengan algoritma *Levenberg-Marquadt*, kinerja proses validasi dan testing untuk algoritma *Resilient Backpropagation* dan algoritma *Scaled Conjugate Gradient* juga hampir sama. Perbedaan yang jelas hanya terlihat pada jumlah data 100, tetapi secara keseluruhan kinerja untuk kedua proses tersebut dapat dikatakan sama. Semakin banyak jumlah data training, semakin kecil kesalahan pada proses validasi dan testing.

7.4 Korelasi antara Pola Susunan Data Training dengan Kinerja Proses Training

Pada penelitian ini dipelajari mengenai korelasi antara pola susunan data training dengan kinerja proses training. Set data training yang digunakan adalah data riil sebanyak 60 data yang terdiri dari masing-masing 10 data untuk jenis kayu kapur, keruing, kapur, akasia, balau, dan jelutung. Dari ke-60 data tersebut dibentuk tiga pola susunan data training yang berbeda. Masing-masing pola susunan data adalah pola 10-10, pola 5-5, dan pola 1-1. Hasil simulasi dapat dilihat pada Tabel 3 dan Gambar 9.

Tabel 3. Kinerja proses rata-rata untuk pola susunan data training 10-10, 5-5, dan 1-1

Algoritma	Epoch untuk pola susunan data training 10-10	Epoch untuk pola susunan data training 5-5	Epoch untuk pola susunan data training 1-1
trainlm	11	14	16
trainrp	17	19	21
trainscg	45	62	69



Gambar 9. Grafik perbandingan kinerja training untuk algoritma training *trainlm*, *trainrp*, dan *trainscg* berdasarkan pola susunan set data belajar.

Dari Tabel 3 terlihat bahwa semakin acak pola susunan data, semakin besar epoch. Dari hal tersebut dapat disimpulkan bahwa terdapat korelasi antara kinerja proses training dengan pola susunan data training. Dari Gambar 9 terlihat algoritma yang memiliki kinerja training yang paling baik adalah

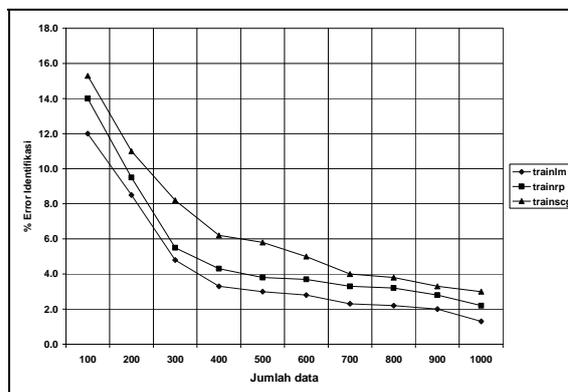
algoritma *Levenberg-Marquadt* (*trainlm*), kemudian masing-masing diikuti oleh algoritma *Resilient Backpropagation* (*trainrp*), dan *Scaled Conjugate Gradient* (*trainscg*).

7.5 Kinerja Proses Online Identifikasi Set Data Riil dengan Training Menggunakan Set Data Training Sintetis

Pada penelitian ini juga dipelajari apakah terdapat korelasi antara jumlah data training sintetis dengan kesalahan online identifikasi jenis kayu menggunakan data riil. Algoritma training yang digunakan adalah algoritma *trainlm*, *trainrp*, dan *trainscg*. Set data training yang digunakan adalah data sintetis masing-masing sebanyak 100, 200, sampai dengan 1000 data. Untuk masing-masing jumlah data dilakukan proses *online* identifikasi dengan memasukkan set data riil berjumlah 60 data. Kinerja proses *online* identifikasi dapat dilihat pada Tabel 4 dan Gambar 10.

Tabel 4. Kinerja proses *online* identifikasi

Algoritma	%error untuk 100 data	%error untuk 200 data	%error untuk 300 data	%error untuk 400 data	%error untuk 500 data
trainlm	12.0	8.5	4.8	3.3	3.0
trainrp	14.0	9.5	5.5	4.3	3.8
trainscg	15.0	11.0	8.2	6.2	5.8
trainlm	2.8	2.3	2.2	2.0	1.3
trainrp	3.7	3.3	3.2	2.8	2.2
trainscg	5.0	4.0	3.8	3.3	3.0



Gambar 10 Grafik kinerja *online* identifikasidengan training data sintetis untuk algoritma *trainlm*, *trainrp*, dan *trainscg*

Dari Tabel 4 terlihat bahwa semakin banyak jumlah data training sintetis untuk algoritma *Trainlm*, *Trainrp*, dan *Trainscg* semakin baik kinerja proses *online* identifikasi data riil, yaitu prosentase kesalahan identifikasi semakin kecil. Untuk jumlah data training 100 dari ketiga algoritma, kesalahan *online* identifikasi sebesar 12%, 14%, dan 15%. Untuk jumlah data training 1000 dari algoritma *Trainlm*, *Trainrp*, dan

Trainscg kesalahan *online* identifikasi turun menjadi sebesar 1.3%, 2.2% dan 3.0%. Untuk mendapatkan kesalahan *online* identifikasi lebih kecil dari 1% dari ketiga algoritma, jumlah data training sintetis yang digunakan harus lebih besar dari 1000.

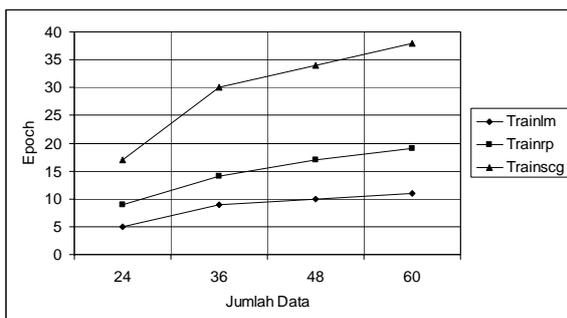
Dari Gambar 10 terlihat bahwa prosentase kesalahan identifikasi turun cukup signifikan (lebih dari 1%) untuk jumlah data training sintetis 100 sampai dengan 400. Untuk jumlah data training sintetis 500 sampai dengan 1000, penurunan prosentase kesalahan identifikasi cukup kecil, tidak lebih dari 1%, tetapi tetap terdapat kecenderungan penurunan.

7.6 Kinerja Proses *Online* Identifikasi Set Data Riil dengan Training Menggunakan Set Data Riil

Pada bagian terakhir ini dipelajari kinerja proses identifikasi jenis kayu menggunakan set data riil ciri anatomi kayu. Data training yang digunakan selama proses training juga menggunakan data riil masing-masing berjumlah 24, 36, 48, dan 60 data. Hasil proses training dan *online* identifikasi Tabel 5 dan Gambar 11.

Tabel 5. Hasil proses training dan *online* identifikasi menggunakan data riil

Jumlah data	trainlm		trainrp		trainscg	
	Epoch	%err	Epoch	%err	Epoch	%err
24	5	0	9	0	17	0
36	9	0	14	0	30	0
48	10	0	17	0	34	0
60	11	0	19	0	38	0



Gambar 11. Grafik kinerja *online* identifikasi dengan training data riil

Pada Tabel 5 tersebut terlihat bahwa prosentase kesalahan *online* identifikasi untuk 24, 36, 48, dan 60 data sebesar 0%. Demikian juga untuk ketiga jenis algoritma training yang digunakan juga menghasilkan prosentase kesalahan identifikasi sebesar 0%. Dari Gambar 11 terlihat bahwa algoritma yang memiliki kinerja training yang paling baik adalah algoritma *Levenberg-Marquadt* (trainlm), kemudian masing-masing diikuti oleh algoritma *Resilient Backpropagation* (trainrp), dan algoritma *Scaled Conjugate Gradient* (trainscg).

8. KESIMPULAN DAN SARAN

8.1 Kesimpulan

Secara umum dapat disimpulkan bahwa Sistem Neuro-Fuzzy untuk Identifikasi Jenis Kayu Bangunan dan Furniture (SNFIK) mempunyai kemampuan identifikasi dengan kesalahan mencapai 0% apabila sistem tersebut menggunakan data riil yang sama pada proses training atau menggunakan data training sintetis yang lebih besar dari 1000 data.

Dari perbandingan kinerja sistem dapat disimpulkan bahwa:

- Semakin banyak jumlah data training, semakin besar jumlah epoch.
- Dari ketiga jenis algoritma training yang digunakan, algoritma yang paling cepat proses trainingnya adalah algoritma *Levenberg-Marquadt* (trainlm), kemudian masing-masing diikuti oleh algoritma *Resilient Backpropagation* (trainrp), dan algoritma *Scaled Conjugate Gradient* (trainscg).
- Kinerja proses validasi dan testing untuk algoritma *Levenberg-Marquadt*, *Resilient Backpropagation* dan *Scaled Conjugate Gradient* hampir sama, yaitu semakin banyak jumlah data training, semakin kecil kesalahan proses validasi dan testing.

Sedangkan untuk kinerja sistem dengan menggunakan data riil dapat disimpulkan bahwa:

- Terdapat korelasi antara kinerja proses training dengan pola susunan data training, yaitu: semakin acak pola susunan data semakin besar epochnya.
- Semakin banyak jumlah data training sintetis, semakin kecil prosentase kesalahan proses *online* identifikasi yang menggunakan data riil.
- Semakin banyak jumlah data riil, ciri yang digunakan pada proses training adalah semakin besar epochnya tetapi menghasilkan prosentase kesalahan sebesar 0%.

8.2 Saran

Kekurangan-kekurangan yang muncul dalam penelitian ini disarankan untuk penelitian lanjutan, yaitu:

- Jumlah jenis kayu yang dapat diidentifikasi dapat lebih banyak lagi dan bukan hanya dari jenis kayu bangunan dan *furniture* saja.
- Sebagai masukan sistem dapat berupa *image* permukaan bidang geometris kayu, yaitu *cross section*, *radial section*, dan *tangential section* yang diambil melalui kamera mikroskop yang terhubung langsung dengan komputer.
- Untuk menentukan fungsi keanggotaan dapat menggunakan ANFIS atau *Probability Neural Network*.
- Program SNFIK dibuat menggunakan program *compiler*, misalnya Visual Basic, Delphi, atau sejenisnya, sehingga dapat berjalan sendiri tanpa program bantu seperti MATLAB.

PUSTAKA

- Bond B. and Hamner P. *Wood Identification for Hardwood and Soft wood Species Native to Tennesse*. Diakses pada 28 November 2003 <http://www.utextension.utk.edu/>
- Fauset L. *Fundamentals of Neural Networks*. New Jersey: Prentice-Hall, 1994.
- Hadikusumo, S.A. dan Prawirohatmodjo S. *Hasil Hutan dan Ilmu Kayu: Suatu Pengantar*. Yogyakarta: Gadjah Mada University Press, 1993.
- I-Fang Chung, Chin-Teng Lin. *A Neuro-Fuzzy Combiner for Multiobjective Control*. International Journal of Fuzzy Systems, Vol.2, No.2, 2000.
- Jang J-SR, Sun C.T, Mizutani E. *Neuro-Fuzzy and Soft Computing*. Prentice-hall, 1997.
- Mandang, Y.L. dan Pandit, I.K.N. *Seri Manual: Pedoman Identifikasi Jenis Kayu Lapangan*. Bogor: PROSEA Indonesia, 2002.
- Newman, M.F., Burgess, P.F., and Whitmore, T.C. *Pedoman Identifikasi Pohon-Pohon Dipterocarpaceae (Sumatera, Pulau Kalimantan, dan Jawa sampai Niugini)*. Bogor: Prosea Indonesia, 1999.
- Soerianegara, I. and Lemmens, R.H.M.J. *Plant Resources of South-East Asia No. 5(1); Timber trees: Major commercial timbers*. Bogor: Prosea Indonesia, 1994.