

Klasifikasi Penutup dan Penggunaan Lahan Pada *Multispectral Image* dari Landsat *Thematic Mapper* Menggunakan *Probabilistic Neural Network*

Agus Buono¹, Marimin², Diana Putri³

¹Staf Pengajar Departemen Ilmu Komputer, FMIPA IPB

²Staf Pengajar Departemen Teknologi Industri Pertanian, Fateta IPB

³Mahasiswa Departemen Ilmu Komputer, FMIPA IPB

Abstrak

Pada *remote sensing*, klasifikasi didefinisikan sebagai suatu metode untuk memberikan label pada pixel berdasarkan karakter spektral yang dimiliki oleh pixel tersebut. Klasifikasi yang sering dilakukan pada bidang ini adalah klasifikasi penggunaan lahan. Klasifikasi penggunaan lahan dimungkinkan karena setiap penggunaan lahan memiliki penutup lahan berupa material bumi yang mempunyai karakteristik spektral yang berbeda-beda. Ciri spektral yang spesifik atau penciri spektral (*spectral signature*) inilah yang digunakan untuk mengklasifikasi penutup lahan pada *multispectral image*.

Penelitian ini mengklasifikasikan penutup dan penggunaan lahan pada *multispectral image* dari Landsat *Thematic Mapper* daerah sekitar Cengkareng yang diambil pada tanggal 1 Agustus 1996. Selain itu, untuk melihat kehandalan metode, juga digunakan data Bunga Iris untuk diklasifikasikan. Metode yang digunakan adalah *Probabilistic Neural Network (PNN)*, yaitu jaringan syaraf tiruan yang dikembangkan berdasar fungsi pendugaan peluang metode kernel. *Probabilistic Neural Network* merupakan *feed forward network* yang terdiri dari tiga layer. Proses pelatihan pada PNN lebih cepat, namun waktu eksekusinya relatif lebih lama dan membutuhkan memori yang cukup besar. Klasifikasi dengan PNN akan lebih baik kalau nilai parameter pemulus (*smoothing parameter, h*) optimum.

Berdasar hasil penghitungan (dengan menggunakan *Mtlab 6.5*), akurasi klasifikasi penutup dan penggunaan lahan di daerah Cengkareng dan sekitarnya menggunakan fungsi PNN adalah 64,2% pada jumlah training 84 pixel dan besar *smoothing parameter (h)*=0,9. Nilai ini lebih bagus dibanding dengan menggunakan analisis diskriminan yang hanya berakurasi 54,3 %. Sedangkan untuk data Bunga Iris, hanya dengan ukuran training 10 %, akurasi klasifikasi mencapai 97,5 %.

Kata kunci: penutup lahan, penggunaan lahan, *remote sensing*, *multispectral image*, *probabilistic neural network*, analisis diskriminan.

PENDAHULUAN

Latar Belakang

Klasifikasi merupakan bagian penting dalam *remote sensing*, dalam hal ini klasifikasi didefinisikan sebagai suatu metode untuk memberikan label pada pixel berdasarkan karakter spektral yang dimiliki oleh pixel tersebut. Contoh klasifikasi yang sering dilakukan adalah klasifikasi penutup dan penggunaan lahan. Proses pelabelan dapat dilakukan oleh komputer diantaranya dengan memberikan pelatihan sebelumnya untuk dapat mengenali *pixel-pixel* dengan spektral yang sama (Richards, 1986).

Informasi mengenai klasifikasi penggunaan lahan dimungkinkan karena setiap penggunaan

lahan memiliki penutup lahan, yaitu material yang nampak dari permukaan bumi seperti air, tanaman dan tanah yang mempunyai karakteristik spektral berbeda-beda. Ciri spektral yang spesifik atau disebut penciri spektral (*spectral signature*) inilah yang akan digunakan untuk mengklasifikasikan penutup lahan pada *multispectral image*.

Klasifikasi dapat dilakukan dengan bantuan metode statistik. Namun seiring dengan pesatnya perkembangan teknologi komputer, para peneliti mulai memanfaatkan ilmu jaringan syaraf tiruan (*JST*) untuk memecahkan permasalahan klasifikasi seperti di atas. Pada penelitiannya, Boggess (1993) mengungkapkan bahwa berdasarkan penelitian Kanellopoulos et al. (1992) *neural network* bekerja lebih baik dibandingkan metode statistik seperti

pengklasifikasi *maximum likelihood* untuk data dari satelit *SPOT*.

Oleh karena itu dalam penelitian dicoba untuk menerapkan *neural network* dalam mengklasifikasikan data dari satelit *Landsat TM* dengan harapan hasilnya akan lebih baik. Data yang sama juga akan diklasifikasikan menggunakan metode statistik yaitu analisa diskriminan sehingga dapat dilihat perbandingan hasil klasifikasi antara *neural network* dan metode statistik analisa diskriminan.

Model jaringan syaraf tiruan yang digunakan untuk mengklasifikasikan penutup lahan dari *multispectral image* adalah *Probabilistic Neural Network (PNN)*. *JST* model ini meskipun memerlukan memori yang cukup besar, namun relatif cepat pada saat melakukan *training* karena hanya dilakukan satu kali jalan, dan data *training* yang sedikit sudah cukup memadai untuk menghasilkan kinerja yang baik. Selain itu, dengan semakin pesatnya perkembangan hardware dan murahnya harga, maka masalah kebutuhan memori yang besar dapat diatasi (*anonymus, 2002*).

Tujuan

Tujuan penelitian ini adalah:

1. Mempelajari dan memahami cara kerja *JST* model *Probabilistic Neural Network (PNN)* sebagai pengklasifikasi.
2. Mengetahui pengaruh perubahan besar *smoothing parameter* terhadap keakuratan hasil klasifikasi.
3. Mengetahui keakuratan hasil klasifikasi *PNN* untuk *multispectral image* yang diambil dari satelit *Landsat*.
4. Mengklasifikasikan penggunaan lahan pada *multispectral image* daerah Cengkareng menggunakan *PNN*.
5. Membandingkan akurasi hasil klasifikasi *PNN* dengan analisa diskriminan.

Ruang Lingkup Penelitian

Ruang lingkup penelitian ini mencakup:

1. Model *JST PNN* yang digunakan memiliki arsitektur lapis banyak, yang terdiri atas *pattern layer*, *summation layer* dan *output layer*.
2. Tidak dilakukan ekstraksi ciri terhadap data *multispectral image*.
3. Besar *smoothing parameter (h)* yang diuji cobakan adalah 0.25h – 1.5h.
4. Hasil penelitian menganalisis tingkat akurasi klasifikasi, waktu pelatihan, waktu klasifikasi,

hasil klasifikasi penutup dan penggunaan lahan dari image yang diteliti, dan pengaruh lebar *smoothing parameter (h)* terhadap keakuratan hasil klasifikasi.

5. Data yang sama juga diklasifikasikan menggunakan analisa diskriminan.
6. *PNN* juga digunakan untuk mengklasifikasikan bunga iris yang datanya didapat dari literatur.

Output dan Manfaat

Output dari sistem ini adalah sistem yang dapat melakukan pembelajaran dan mengklasifikasikan penggunaan lahan dari setiap *pixel* pada *multispectral image* yang diambil dari satelit *Landsat* dan menghasilkan keluaran berupa peta penutup lahan.

Dari sistem ini diharapkan dapat mengetahui kinerja *JST PNN* dengan masukan data mentah (*raw data*) dari *multispectral image*, dan mengetahui perbandingan akurasi hasil klasifikasi antara penggunaan *PNN* dengan analisis diskriminan.

TINJAUAN PUSTAKA

Klasifikasi Penutup dan Penggunaan Lahan

Penutup lahan menggambarkan material-material yang tampak pada permukaan bumi. Menurut *Ardiansyah (1987)*, penutup lahan merupakan perwujudan secara fisik obyek-obyek yang menutupi lahan dan terkadang bersifat penutup lahan alami. Sedangkan penggunaan lahan lebih berkaitan dengan aktifitas manusia di tempat tersebut.

Pada penelitian ini penutup dan penggunaan lahan diklasifikasikan menjadi tujuh kelas, yaitu laut, daerah tepi pantai, rural, urban, area parkir, kompleks perumahan dan daerah padat penduduk.

Image Data Inderaja

Image data inderaja permukaan bumi dari citra satelit didapat dalam bentuk digital. Secara khusus, data digital disusun dalam bentuk elemen-elemen gambar dengan ciri tersendiri (*pixel*) serta secara radiometrik dikelompokkan ke dalam tingkatan-tingkatan kecerahan tertentu.

Identifikasi obyek pada citra *Landsat TM* yang dilakukan dengan analisis digital secara sederhana antara lain memisahkan obyek menjadi tanah, air dan vegetasi. Ketiga kelompok ini mempunyai daya serap yang berbeda terhadap panjang gelombang tertentu sehingga setiap

obyek akan membentuk kenampakan yang berbeda pula.

Menurut *Richards (1986)*, fungsi panjang gelombang yang digunakan pada perekaman obyek disebut resolusi spektral. Menurut *Richards, Thematic Mapper* memiliki tujuh saluran spektral yang masing-masing memiliki fungsi sebagai berikut:


Band 1: 0,45-0,52 μm (biru). Untuk menghasilkan penetrasi ke dalam tubuh air dan untuk mendukung analisis sifat khas penggunaan lahan dan vegetasi.

Band 2: 0,52-0,62 μm (hijau). Untuk mengindera puncak pantulan vegetasi pada spektrum hijau yang terletak di antara dua saluran spektral serapan klorofil. Saluran ini juga membedakan vegetasi dan penilaian kesuburan.

Band 3: 0,63-0,69 μm (merah). Untuk memisahkan vegetasi. Saluran ini berada pada salah satu bagian serapan klorofil dan memperkuat kontras antara kelas vegetasi.

Band 4: 0,76-0,90 μm (inframerah dekat) dipilih agar tanggap terhadap sejumlah biomasa vegetasi yang ada pada daerah kajian. Saluran ini membedakan antara tanaman, tanah dan lahan air.

Band 5 : 1,55-1,75 μm (inframerah menengah). Untuk penentuan jenis tanaman, kandungan air pada tanaman dan kondisi kelembaban tanah.



Gambar 1. Kurva Pantulan Spektral dari Material Bumi yang Dominan (*Richards, 1986*).

Band 7: 2,08-2,35 μm (inframerah menengah). Saluran yang penting untuk memisahkan formasi batuan.

Band 6: 10,40-12,50 μm (inframerah thermal). Untuk klasifikasi vegetasi, analisis gangguan vegetasi, pemisah kelembaban tanah dan

sejumlah gejala lain yang berhubungan dengan panas.


Klasifikasi

Pada prinsipnya tujuan klasifikasi adalah mengadakan pemisahan dari suatu populasi yang kompleks ke dalam kelompok-kelompok yang disebut sebagai kelas, yang dapat dianggap sebagai unit-unit homogen untuk tujuan tertentu.

Jaringan Syaraf Tiruan

Definisi *JST* menurut *Fauset (1994)* yaitu *JST* adalah suatu sistem pemrosesan informasi yang memiliki karakteristik-karakteristik menyerupai jaringan syaraf biologi.

Setiap *neuron* buatan menerima satu set *input*, dimana setiap input dikalikan dengan bobot yang sesuai. Hasil penjumlahan seluruh input berbobot tersebut menentukan kemungkinan *neuron* untuk menembakkan sinyal. Nilai ini disebut *level aktivasi*. Secara matematis, untuk suatu *neuron*, setiap *input* X_i dikalikan dengan bobot W_i sehingga jumlah total input adalah $\sum X_i W_i$. Total sinyal *input* tersebut diproses oleh sebuah fungsi aktivasi untuk menghasilkan sinyal *output*, yang jika tidak nol, akan ditransmisikan sebagai keluaran.



Gambar 2. Model Sederhana *JST*.

Menurut *Fauset (1994)*, suatu *JST* dicirikan dari tiga hal, yaitu: (1) pola hubungan antar *neuron*, disebut arsitektur, (2) metode penentuan bobot koneksi, yaitu algoritma untuk pelatihan (*training*) dan pembelajaran (*learning*) dan (3) fungsi aktivasi yang digunakan untuk menentukan *output*.

Metode Parzen sebagai Penduga Kepekatan

Fungsi kepekatan f_k berhubungan dengan konsentrasi dari suatu kelas k untuk kasus-kasus di sekitar daerah yang tidak diketahui. *FKP* tersebut harus diduga dari himpunan pelatihan yang telah diberikan.

Penduga untuk fungsi kepekatan peluang *Parzen* menggunakan fungsi pembobot (disebut *kernel*) $K(x)$ yang nilainya akan tinggi seiring dengan besarnya nilai x . Fungsi ini akan

membuat setiap titik pelatihan ada di tengah, dengan nilai setiap fungsi contoh pada sumbu x ditentukan berdasarkan jarak antara x dan titik contoh. Menurut *Silverman (1990)*, penduga fungsi kepekatan peluang *Parzen* merupakan penjumlahan fungsi tersebut untuk setiap titik contoh.

Secara matematis metode *Parzen* ditulis sebagai berikut:

$$g(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left\{\frac{1}{h}(x-x_i)\right\} \quad (2)$$

Fungsi kernel K untuk dimensi d harus memenuhi $\int_{R^d} K(x)dx = 1$. Dalam hal ini fungsi

kernel yang digunakan adalah fungsi Gauss:

$$K(x) = \frac{1}{(2\pi)^{d/2}} e^{-\frac{1}{2}x^T x} \quad (3)$$

Dari persamaan (2) dan (3) maka didapat persamaan sebagai berikut:

$$f_A(x) = \frac{1}{(2\pi)^{d/2} h^d} \frac{1}{m_A} \sum_{i=1}^{m_A} e^{-\frac{(x-x_{Ai})^T(x-x_{Ai})}{2h^2}}$$

Keterangan:

- x_{Ai} : training pattern ke-i dari kelas A,
- d: dimensi dari vektor input,
- m_A : jumlah training pattern kelas A,
- h: smoothing parameter.

Persamaan di atas digunakan sebagai penduga fkp pada PNN (*Specht, 1990*).

Penentuan Besar Smoothing Parameter (h)

Pemilihan nilai *smoothing parameter (h)* harus diperhatikan, karena nilai ini memegang peranan yang penting terhadap ketepatan hasil pengklasifikasian yang dilakukan. *Smoothing parameter* yang terlalu kecil akan mengakibatkan pendekatan yang terlalu sempit, sedangkan jika terlalu besar dapat menghilangkan detil yang penting (*Masters, 1995*).

Dalam penelitian ini, sebagai nilai awal dari *smoothing parameter* digunakan perumusan sebagai berikut: $h = A(K)n^{-1/d+4}$ (4)

dimana n adalah jumlah data training dan A(K) untuk kasus multivariate normal dengan dimensi =d adalah $A(K) = \left\{ \frac{4}{(d+2)} \right\}^{1/d+4}$ (*Silverman, 1990*).


Probabilistic Neural Network

PNN dirancang menggunakan ide dari teori probabilitas klasik seperti pengklasifikasi Bayes dan penduga pengklasifikasi klasik seperti *Parzen* untuk fungsi kepekatan peluangnya.

Secara sederhana, cara kerja PNN dapat diterangkan sebagai berikut. Saat input masuk, *pattern* layer akan menghitung “jarak” vektor pengujian ke vektor pelatihan dan menghasilkan vektor yang mengindikasikan seberapa “dekat” input ke vektor pelatihan. Pada *summation* layer, akan dijumlahkan kontribusi dari masing-masing kelas input untuk menghasilkan probabilitas vektor *output*. Terakhir pada *output* layer, fungsi transfer *compete* akan mengambil nilai maksimum dari vektor *output*, dan menghasilkan nilai satu untuk kelas tersebut dan nilai nol untuk kelas lainnya (*Mathwork Inc, 2002*).

Arsitektur

PNN merupakan *feed forward network* yang terdiri atas 3 layer, yaitu *pattern* layer, *summation* layer dan *output* layer. Adapun gambar arsitektur PNN adalah sebagai berikut:



Gambar 3. Arsitektur PNN.

Pada *pattern* layer, setiap input yang ingin diklasifikasikan, akan dihubungkan dengan setiap neuron pada *pattern* layer dan *output* dari *pattern* layer tersebut merupakan hasil dari perhitungan sebagai berikut:

$$f_A(x) = \frac{1}{(2\pi)^{d/2} h^d} e^{-\frac{(x-x_{Ai})^T(x-x_{Ai})}{2h^2}}$$

Summation layer akan menjumlahkan *output* dari *pattern node* yang bersesuaian dengan kelas yang ada sebagai berikut:

$$f_A(x) = \frac{1}{(2\pi)^{d/2} h^d} \frac{1}{m_A} \sum_{i=1}^{m_A} e^{-\frac{(x-x_{Ai})^T(x-x_{Ai})}{2h^2}}$$

m_A adalah jumlah contoh dalam kelas A, dan d adalah jumlah band.

Output layer akan mengklasifikasikan input berdasarkan nilai tertinggi yang didapat dari *summation* layer.

Bunga Iris

Data bunga iris terdiri atas variabel-variabel panjang petal, lebar petal, panjang sepal dan lebar sepal. Data ini banyak dijadikan rujukan untuk melakukan percobaan pada penelitian *multivariate data*. Bunga iris diklasifikasikan menjadi tiga kelas yaitu Iris Setosa, Versicolor, dan Virginica. Data bunga iris diambil dari Fisher, 1936 yang ada dalam buku (*Lampiran 7*). Jumlah keseluruhan data ada 150, masing-masing kelas terdiri dari 50 data.

Matriks Hasil Klasifikasi

Matriks hasil klasifikasi (*terkadang disebut juga Error Matrix atau Confusion Matrix*) dapat digunakan untuk menunjukkan tingkat akurasi klasifikasi yang telah dilakukan. Kolom pada matrik ini menyatakan referensi *pixel* yang diketahui kelasnya, sedangkan baris menyatakan *pixel* yang diklasifikasikan. Akurasi adalah total jumlah *pixel* yang diklasifikasikan dengan benar dibagi jumlah seluruh data (*Verbyla, 1995*).

Analisis Diskriminan

Analisis diskriminan digunakan untuk memodelkan nilai dari variabel terikat berdasarkan hubungan antara satu atau lebih penduga. Secara matematis analisa diskriminan dimodelkan sebagai berikut

$$d_{ik} = b_{0k} + b_{1k} x_{i1} + \dots + b_{pk} x_{ip}$$

d_{ik} = nilai ke-k fungsi diskriminan untuk kasus ke-i
 p = jumlah penduga

b_{jk} = nilai koefisien ke-j dari fungsi ke-k

x_{ij} = nilai kasus ke-i dari penduga ke-j

jumlah fungsi = min (#kelas-1, #penduga)

Asumsi dari model diskriminan adalah variabel penduga terdistribusi normal, keanggotaan kelas *mutually exclusive* dan *collectively exhaustive* (*semua kasus merupakan anggota dari kelas tertentu*). Prosedur ini akan efektif apabila keanggotaan kelas merupakan variabel kategori.

METODOLOGI

Kerangka Pikir

Satelit *Landsat 6* memanfaatkan sensor *Thematic Mapper* untuk mengumpulkan

informasi tentang bumi. Image yang dibentuk oleh sensor tersebut terlihat sebagai suatu himpunan (*set*) dari image-image yang bersesuaian dengan satu *spectral band*.

Pixel pada *multispectral image* di-representasikan oleh vektor berukuran sama dengan jumlah band yang terekam oleh sensor yang juga merupakan karakteristik spektral dari *pixel* tersebut dan akan menentukan sinyal yang bersesuaian dengan elemen tertentu di bumi.

Melalui hasil pengamatan pada image dan perbandingan dengan *pixel-pixel* dari lokasi yang sudah diketahui elemen-elemennya, maka dapat diidentifikasi penciri spektral yang akan digunakan untuk menentukan suatu kelas penutup lahan. Kelas ini merupakan representasi dari *pixel-pixel* dengan multispektral yang berdekatan.

PNN dalam penelitian ini digunakan untuk melakukan klasifikasi penutup lahan dari data *multispectral image* secara otomatis.

Bahan

Pada penelitian ini digunakan data citra *Landsat TM* untuk daerah sekitar Cengkareng yang diambil pada tanggal 1 Agustus 1996. Data diperoleh dari Lembaga Antariksa dan Penerbangan Negara (*LAPAN*) yang beralamat di Pasar Rebo, Jakarta

Perangkat lunak yang digunakan pada penelitian ini adalah *Adobe Photoshop 6*, *Matlab 6.5* dan *SPSS 12*. Sedangkan spesifikasi perangkat keras yang digunakan adalah *Pentium III 450 MHz*, *hard disk 30 Gb* dan memori *128 MB*.

Algoritma

Setiap contoh pelatihan berhubungan dengan *pattern* unit. Vektor pembobot untuk *pattern* unit Z_{Aj} adalah vektor pelatihan ke-j dari kelas A. Seiring dengan diberikannya *training pattern*, *pattern* baru yang bersesuaian dengan kelas yang tepat ditambahkan ke jaringan, bobotnya ditentukan dan unit tersebut akan dihubungkan dengan *summation unit* yang sesuai.

Algoritma untuk membangun jaringan:

Step 1: Untuk setiap training input *pattern* $X(p)$,
 $p=1,2,\dots,P$ lakukan Langkah 2-3

Step 2: Buat *pattern* unit Z_p
 Set vektor pembobot unit Z_p :
 $W_p = X(p)$

Step 3: Hubungkan *pattern* unit ke *summation* unit:

If $X(p)$ anggota kelas A, then

Hubungkan *pattern* unit Z_p tersebut ke *summation* unit S_A
 Else
 Hubungkan *pattern* unit Z_p tersebut ke *summation* unit S_B
Step 4: Bandingkan total kontribusi pada setiap kelas hasil penjumlahan pada *summation* unit. *Output* adalah yang tertinggi nilai kontribusinya

Proses Klasifikasi Penggunaan Lahan Menggunakan PNN

Berikut ini adalah tahapan-tahapan yang akan dilakukan pada penelitian ini:



Gambar 5. Tahapan Proses Klasifikasi PNN untuk Penggunaan Lahan pada Multispectral Image.

Multispectral Image Daerah Cengkareng

Multispectral image untuk daerah sekitar Cengkareng, yang didapat dari LAPAN memiliki ukuran 512 X 512 *pixel*, sehingga total ada 262.144 *pixel* yang akan diklasifikasikan penggunaan lahannya. Karena setiap *pixel* mewakili daerah seluas 30m x 30m maka image tersebut mewakili daerah seluas 23592,96 ha.

Ekstraksi Nilai Band pada Tiap Pixel

Multispectral image dalam format .tif, terdiri atas 5 *layer*. Masing-masing *layer* tersebut mewakili nilai dari band 1, 2, 3, 4 dan 5 dari

setiap *pixel* pada *image*. Sehingga untuk setiap *pixel*nya akan didapat vektor berukuran 5x1.

Penentuan Kelas dan Pixel-Pixel Contoh Pelatihan untuk Setiap Kelas

Untuk setiap penggunaan lahan yang berbeda, diambil beberapa *pixel* yang mewakili penggunaan lahan tersebut. Pemilihan *pixel* sebagai data training dilakukan dengan bantuan dari staf LAPAN.

Data *training* yang diperlukan meliputi kelas penutup lahan, baris dan kolom beberapa *pixel* yang mewakili tiap kelas penggunaan lahan tersebut dan disimpan dalam *file* dengan format *text*.

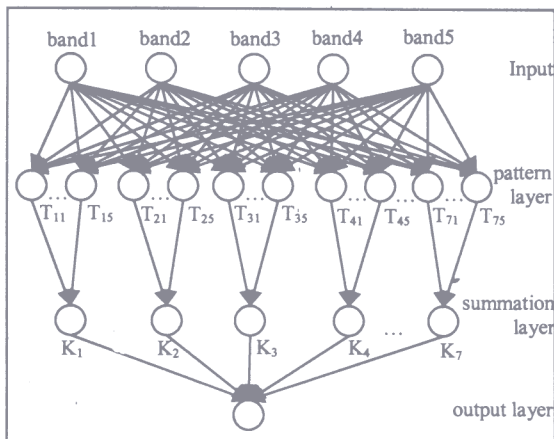
PNN

Di bawah ini adalah tabel karakteristik struktur *JST* model *PNN* yang digunakan pada penelitian ini.

Tabel 1. Struktur *JST* Model *PNN* yang digunakan pada penelitian

Karakteristik	Spesifikasi
Arsitektur:	
- neuron pada <i>pattern layer</i>	35, 70, 84
- <i>summation layer</i>	$f_A(x) = \frac{1}{(2\pi)^{d/2} \sigma^d} \frac{1}{m_A}$
- neuron output layer	$\sum_{i=1}^{m_A} e^{-\frac{(x-x_{Ai})^T(x-x_{Ai})}{2\sigma^2}}$ 7
Fungsi aktifasi	$f_A(x) = \frac{1}{(2\pi)^{d/2} \sigma^d}$
Penentuan besar <i>smoothing parameter (h)</i>	$e^{-\frac{(x-x_{Ai})^T(x-x_{Ai})}{2\sigma^2}}$ 0.25h – 1.5h

Sebagai ilustrasi, di bawah ini adalah gambaran arsitektur *PNN* untuk contoh kasus dengan data training sejumlah 35 *pixel*. Setiap input terdiri atas lima elemen, masing-masing merupakan nilai pada *band 1* sampai *band 5* dari setiap *pixel input* yang ingin diklasifikasikan.



Gambar 6. Contoh struktur PNN untuk kasus jumlah training=35 pixel.

Neuron pada *pattern layer* adalah jumlah seluruh *pixel* contoh yang digunakan pada saat pelatihan, dalam hal ini misalkan ada 35 neuron. Pada gambar T_{11} berarti data *training* kesatu untuk kelas satu, T_{15} berarti data *training* kelima untuk kelas satu dan seterusnya sampai T_{75} yang berarti data *training* kelima untuk kelas tujuh. Pada *pattern layer* setiap *pixel* input yang diberikan akan dihitung "jaraknya" terhadap semua *pattern* yang ada.

Pada *summation layer*, akan dijumlahkan total kontribusi setiap *pattern* yang bersesuaian dengan kelas yang diwakili oleh *pattern* tersebut. Jumlah neuron pada *layer* ini sama dengan jumlah kelas penutup lahan, yaitu sebanyak tujuh neuron. Pada gambar di atas, K_1 berarti kelas 1, dan K_7 berarti kelas 7.

Jumlah neuron pada *output layer* bersesuaian dengan target *output* yaitu kelas penutup lahan yang sebelumnya sudah diidentifikasi. *Output* berupa klasifikasi penggunaan lahan setiap *pixel* input yang ditentukan berdasarkan nilai tertinggi hasil perbandingan pada *summation layer*.

Proses Klasifikasi Menggunakan Metode Analisis Diskriminan

Data digital *multispectral image* yang sudah diketahui kelasnya, yaitu sebanyak 140 *pixel*, dimasukkan sebagai data dalam format yang dapat dibaca oleh program statistika SPSS. Kolom pertama dari data diisi dengan kelas asli, kolom kedua diisi nilai pada *band 1*, kolom ketiga dengan nilai *band 2*, kolom keempat dengan nilai *band 3*, kolom kelima dengan nilai *band 4* dan kolom keenam dengan nilai *band 5*.

Proses Klasifikasi Bunga Iris

Sebagai pembandingan, PNN juga digunakan untuk mengklasifikasikan data bunga iris yang didapat dari literatur.

Struktur PNN yang dipakai untuk mengklasifikasikan sama dengan yang tercantum pada Tabel 1, kecuali untuk neuron pada *pattern layer* yang berlaku sebagai data *training* berjumlah 9, 12, dan 15 (Lampiran 8.), serta *output layer* sebanyak tiga yang merupakan jumlah kelas, dengan ketentuan sebagai berikut: kelas 1 adalah kelas bunga iris *Setosa*, kelas 2 adalah kelas bunga iris *versicolor* dan kelas 3 adalah kelas bunga iris *virginica*.

Percobaan.

Setelah pengolahan awal berupa ekstraksi nilai digital dari semua *band* dan menentukan kelas beserta data *training*nya, percobaan selanjutnya adalah sebagai berikut:

□ Dari 140 *pixel* data yang diketahui kelasnya (setiap kelas=20 *pixel*) lakukan hal berikut:

- Ambil secara acak 35 *pixel*, masing-masing 5 *pixel* dari 7 kelas yang ada sebagai data *training* dan sisanya sebanyak 105 *pixel* untuk menguji
- Ambil secara acak 70 *pixel*, 10 *pixel* tiap kelas sebagai data *training*, sisanya sebanyak 70 *pixel* untuk menguji
- Ambil secara acak 84 *pixel* (Lampiran 5.), 12 *pixel* tiap kelas, dan sisanya sebanyak 56 *pixel* (Lampiran 6.) digunakan untuk menguji.

Untuk setiap jumlah *pixel training* yang berbeda, hitung besar *smoothing parameter*

(h) awal $h = A(K)n^{-1/d+4}$ sebagai inisialisasi lalu uji pada PNN dengan h sebesar 0.25h, 0.5h, 0.75h, h, 1.25h, dan 1.5h.

Untuk metode analisa diskriminan, dilakukan menggunakan bantuan program statistika SPSS versi 12. Data digital *multispectral image* yang sudah tersimpan dalam format SPSS diklasifikasikan dengan memilih menu *Analyze>>Classify>>Discriminant*. Kemudian masukkan variabel kelas pada *Grouping Variabel* dan variabel *band 1* sampai *band 5* sebagai *Independents*, lalu tekan OK untuk menjalankan analisa diskriminan pada data tersebut.

Sedangkan untuk klasifikasi bunga iris, *training* yang diambil (data *training* terlampir) sebanyak 9 (3 tiap kelas), 12 (4 tiap kelas) dan 15 data (5 tiap kelas), hitung

nilai h awal dengan perumusan yang sama, lalu diujicobakan menggunakan ke-150 data yang ada dengan nilai h sebesar 0.25h, 0.5h, 0.75h, h , 1.25h, dan 1.5h.

Analisis

Percobaan yang dirancang baik untuk *multispectral image* maupun untuk data bunga iris selanjutnya diujicoba dan dilakukan analisis sebagai berikut:

1. Waktu latih yang dibutuhkan untuk setiap percobaan
2. Waktu yang dibutuhkan PNN untuk mengklasifikasikan seluruh *image* pada setiap jumlah training sampel yang berbeda
3. Hasil klasifikasi dari *multispectral image* yang diteliti
4. Keakuratan hasil klasifikasi yang dilakukan, dimana dalam penelitian ini dihitung
$$akurasi = \frac{jumlah\ data\ benar}{jumlah\ seluruh\ data\ uji} \times 100\%$$
5. Pengaruh perubahan besar *smoothing parameter* (h) terhadap keakuratan hasil klasifikasi PNN.
6. Perbandingan akurasi hasil klasifikasi data *multispectral image* antara metode JST PNN dengan metode statistika yaitu analisis diskriminan.

HASIL DAN PEMBAHASAN


Waktu Latih

Waktu latih PNN tergolong cepat, seperti terlihat pada Tabel 2 di bawah. Hal ini disebabkan karena training dilakukan ‘sekali jalan’ untuk setiap *training vektornya*. Selain itu, berbeda dengan JST model lain seperti *propagasi* balik yang untuk setiap penambahan atau perubahan contoh *vektor training* harus mengulang pelatihan dari awal untuk mendapatkan bobot baru, pada PNN hal ini tidak perlu dilakukan.

Tabel 2. Tabel Waktu Latih terhadap Jumlah Data Training

Jumlah Data Training	Waktu Latih (detik)
35	0.07
70	0.09
84	0.1

Di bawah ini adalah grafik waktu latih PNN pada beberapa jumlah contoh training yang berbeda. Secara umum, seperti yang terlihat pada grafik di bawah, waktu latih akan meningkat seiring dengan bertambahnya jumlah contoh data training yang diberikan. Pada saat jumlah data training berjumlah 35 *vektor*, waktu latihnya hanya 0.07 detik, sedangkan pada saat jumlah data training ditambahkan menjadi 84 *vektor*, maka waktu latihnya semakin lama, yaitu 0.1 detik.




Gambar 7. Grafik Waktu Latih terhadap Jumlah Data Training.

Waktu Eksekusi (Klasifikasi)

Dari Tabel 3 dan grafik pada Gambar 8, terlihat bahwa semakin banyak jumlah data training yang diberikan, maka waktu yang dibutuhkan network untuk mengklasifikasikan *multispectral image* juga akan semakin lama.

Tabel 3. Tabel Waktu Eksekusi terhadap Jumlah Data Training

Jumlah Data Training	Waktu Klasifikasi (detik)
35	89.1
70	379.6
84	4734.7



Gambar 8. Grafik Waktu Klasifikasi terhadap Jumlah Data Training.

Pada penelitian ini, waktu klasifikasi tercepat didapat pada saat contoh data *training* berjumlah lima per kelas, yaitu selama 89.1 detik atau sama dengan 1.5 menit. Sedangkan waktu klasifikasi terlama yaitu 4734.7 atau 1 jam 20 menit didapat pada saat jumlah data *training* sejumlah dua belas per kelas.

Apabila dilihat dari waktu klasifikasi pada tabel di atas, maka dapat dihitung rata-rata waktu yang diperlukan oleh *network* untuk mengklasifikasikan satu *pixel* dari *multispectral image* dengan jumlah data *training* lima per kelas 0.00034, pada jumlah data sepuluh per kelas adalah 0.00145 detik, dan untuk jumlah data *training* sebanyak dua belas per kelas waktu yang dibutuhkan tiap *pixel* adalah 0.02 detik.

Hal di atas menunjukkan bahwa karena pada *PNN* setiap *pixel* pada image (*berlaku sebagai input*), masing-masing akan dihubungkan dengan setiap vektor *training* yang ada, diolah, kemudian baru dapat ditentukan kelas dari setiap input (*pixel*) tersebut, sehingga semakin banyak data *training* yang diberikan, waktu eksekusinya pun akan semakin lama.

Kompleksitas

Kompleksitas dari *PNN* adalah $O((n*m)+m+k)$, dimana n adalah jumlah *input*, m adalah jumlah data *training* dan k adalah jumlah kelas.

Keakuratan Hasil Klasifikasi PNN

Hasil klasifikasi *multispectral image* menggunakan *PNN* seperti yang diujicobakan pada penelitian ini kurang memuaskan (*matriks hasil klasifikasi untuk setiap jumlah data training terlampir*). Keakuratan hasil klasifikasi tertinggi pada beberapa nilai h yang diujicobakan hanya mencapai 64.3%, yaitu pada jumlah *training* sama dengan 84 *pixel* dan besar *smoothing parameter* (h) sama dengan 0,75 dan 0,9.

Akurasi aktual dari hasil klasifikasi yang dilakukan sesungguhnya tidak diketahui karena adalah tidak mungkin untuk secara pasti, tepat 100% menentukan termasuk kelas apa setiap *pixel* yang ada dalam *multispectral image*.

Beberapa alasan yang dapat menjelaskan hal ini diantaranya adalah: pertama, ketidak-sempurnaan dari data referensi (*multispectral image* yang digunakan), dimana sebelum dapat digunakan data mengalami antara lain koreksi geometrik dan radiometrik. Koreksi *radiometric* dilakukan oleh LAPAN (*Lembaga Penerbangan Antariksa Nasional*) sebagai penyedia data digital

di Indonesia. Adakalanya koreksi radiometrik tidak optimal dikarenakan gangguan pada saat pengambilan data oleh satelit *Landsat TM*. Koreksi geometrik dilakukan dengan cara menyesuaikan koordinat lokal dari citra *Landsat TM* dengan koordinat bumi yang diperoleh dari peta topografi. Dalam penelitian ini tidak dilakukan koreksi geometrik, data *multispectral image* yang didapat dari LAPAN langsung digunakan sebagai input.

Kedua, faktor pemilihan dan jumlah data *training* yang sangat mempengaruhi kinerja *PNN* sebagai pengklasifikasi. Karena tidak dilakukan studi lapang, data *training* didapat dengan mengandalkan bantuan staf ahli. Dalam hal ini karena keterbatasan penglihatan manusia, maka sulit mengukur ketelitian sang ahli dalam pengambilan contoh. Selain itu mengingat keragaman penutup lahan yang ada di Indonesia, tidak terkecuali pada image yang diteliti, dimana image merupakan daerah yang heterogen dengan beragam jenis tipe vegetasi dengan jumlah dan luas serta kelembatan yang juga berbeda-beda, dan kondisi topografi daerah, akan sulit mendapatkan hasil klasifikasi dengan akurasi 100%.

Ketiga, adalah faktor spektral penciri itu sendiri. Tipe penutup-lahan yang sama tetapi ada pada lokasi yang berbeda, spektral pencirinya dapat saja berbeda. Untuk lebih jelasnya dapat dilihat pada contoh spektral penciri daerah laut dan tepi laut pada tabel di bawah ini:

Tabel 4. Kisaran Nilai Band Untuk Kelas Laut

Band	Contoh pd lokasi 2 (row besar, col kecil)	Contoh pd lokasi 2 (row kecil, col kecil)
1	36 - 63	12 - 36
2	28 - 80	9 - 11
3	87 - 98	90 - 91
4	34 - 39	31 - 33
5	39 - 55	30 - 31

Tabel 5. Kisaran Nilai Band Untuk Kelas Tepi Pantai

Band	Contoh pd lokasi 2 (row kecil, col kecil)	Contoh pd lokasi 2 (row besar, col besar)
1	14 - 15	24 - 55
2	7 - 11	25 - 70
3	89 - 93	82 - 90
4	36 - 38	31 - 34
5	38 - 43	36 - 46

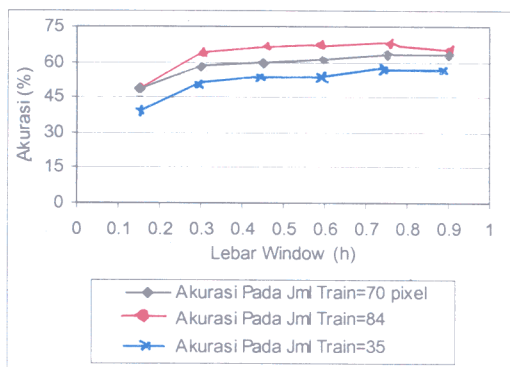
Dari kedua tabel di atas juga terlihat bahwa tipe penutup lahan yang berbeda dengan lokasi terpisah dapat saja memiliki spektral penciri yang

sama. Hasil pemilihan area contoh kelas kedua tipe penutup lahan di atas mencerminkan adanya reflektan yang saling tumpang tindih. Hal ini diduga karena pada kedua penutup lahan tersebut mempunyai kesamaan bahan dasar penutupan, seperti kesamaan jumlah kadar air, kelembaban tanah, jenis bebatuan dan vegetasi pada kedua daerah tersebut.

Perubahan Besar Smoothing Parameter (h) terhadap Keakuratan Hasil Klasifikasi

Memilih nilai *smoothing parameter (h)* yang tepat berpengaruh pada ketepatan hasil klasifikasi. Kesalahan dalam memilih nilai h akan berdampak pada buruknya kinerja PNN, sehingga kurang akurat sebagai pengklasifikasi.


Pada penelitian ini, dimana sebagai inisialisasi nilai h digunakan perumusan seperti yang dijelaskan pada bagian metodologi, hasilnya menunjukkan bahwa dengan adanya perubahan nilai *smoothing parameter (h)* yang kecil, pengaruhnya terhadap keakuratan hasil klasifikasi *Probabilistic Neural Network* hanya sedikit. Pada beberapa nilai h yang diujicobakan, besarnya akurasi ada yang berubah, namun ada juga yang nilai akurasinya tidak berubah dengan adanya perubahan lebar h. Contohnya pada jumlah *training* sama dengan 70 *pixel* akurasi yang didapat untuk lebar h 0,75 dan 0,9 tetap, yaitu sebesar 62,86%. Sedangkan untuk jumlah *training* sama dengan 84 *pixel*, ada dua nilai akurasi yang tetap, yaitu untuk lebar h sama dengan 0,45 dan 0,56 akurasinya sama yaitu sebesar 62,48 dan untuk lebar h sama dengan 0,75 dan 0,9 akurasinya juga sama yaitu 64,26%. Hal ini dapat dilihat pada *grafik* di bawah ini.



Gambar 9. Grafik Akurasi Klasifikasi.

Hasil Klasifikasi Penggunaan Lahan

Di bawah ini adalah gambar hasil klasifikasi penggunaan lahan pada *multispectral image* daerah sekitar Cengkareng menggunakan PNN.



Gambar 10. Grafik Hasil Klasifikasi Penggunaan Lahan Menggunakan PNN.

Dari tabel di bawah, sebagian besar daerah Cengkareng yang ada pada *image* yang diteliti merupakan Laut atau daerah perairan yaitu sebesar 32,4% dari keseluruhan *image*. Berikutnya merupakan kompleks perumahan sebesar 14,9%, disusul daerah tepi pantai sebesar 11,7%, kemudian tempat parkir atau jalan raya, dimana banyak mobil melintas yaitu sebesar 11,5%. Daerah *urban* pada *image* menempati 12,7% dan daerah rural sebesar 8,6% dan daerah padat penduduk menempati bagian terkecil dari *image* yaitu sebesar 8,2% dari keseluruhan *image*. Hasil klasifikasi di atas didapat pada jumlah *training* sama dengan 70 *pixel* akurasi yang didapat untuk lebar h 0,75 dan 0,9 tetap, yaitu sebesar 62,86%. Sedangkan untuk jumlah *training* sama dengan 84 *pixel*, ada dua nilai akurasi yang tetap, yaitu untuk lebar h sama dengan 0,45 dan 0,56 akurasinya sama yaitu sebesar 62,48 dan untuk lebar h sama dengan 0,75 dan 0,9 akurasinya juga sama yaitu 64,26%. Hal ini dapat dilihat pada *grafik* di bawah ini.

Tabel 6. Hasil Klasifikasi Penutup lahan Menggunakan PNN

Kelas Penggunaan Lahan	Jumlah Pixel	Persentase (%)
1 (Laut)	84915	32.4
2 (Tepi Pantai)	30682	11.7
3 (Rural)	22477	8.6
4 (Urban)	33397	12.7
5 (Tempat Parkir)	30151	11.5
6 (Kompleks Perumahan)	39124	14.9
7 (Daerah Padat Penduduk)	21398	8.2
Total	62144	100

Bandara banyak didapati daerah yang terklasifikasi sebagai laut, hal ini diduga pada

saat pemotretan dilakukan, daerah bandara sedang digenangi air. Seperti yang diketahui bahwa daerah bandara awalnya merupakan rawa, dan sepanjang jalan menuju bandara masih berupa rawa yang seringkali tergenang air sehingga spektral pencirinya akan mirip dengan spektral penciri daerah laut dan oleh sistem diklasifikasikan sebagai laut.

Tabel 7. Luas Area Penutup lahan Pada Image

Kelas Penggunaan Lahan	Luas Area ($\times 100m^2$)
1 (Laut)	764235
2 (Tepi Pantai)	276138
3 (Rural)	202293
4 (Urban)	300573
5 (Tempat Parkir)	271359
6 (Kompleks Perumahan)	352116
7 (Daerah Padat Penduduk)	192582
Total	2359296

Perbandingan Akurasi Hasil Klasifikasi PNN dengan Analisis Diskriminan

Akurasi hasil klasifikasi data digital *multispectral image* menggunakan analisis diskriminan hanya mencapai 54,3%. Nilai ini lebih kecil 10% dibandingkan dengan akurasi yang didapat menggunakan PNN untuk data yang sama, dimana akurasi PNN pada penelitian ini mencapai 64,3%.

Hasil Klasifikasi Bunga Iris

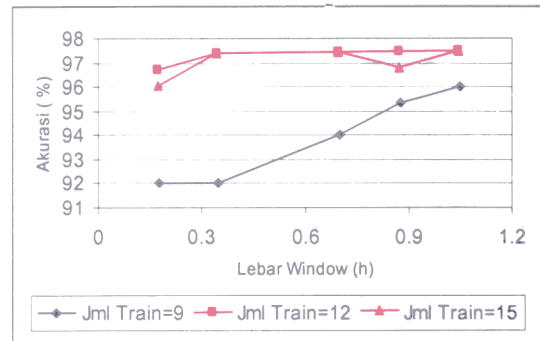
Pada penelitian ini, penerapan PNN untuk klasifikasi bunga iris akurasi dapat mencapai 97,33% dengan jumlah data *training* kurang dari sepuluh persen dari data, yaitu 12 data. Bahkan khusus untuk data bunga iris jenis *Iris Setosa* akurasi mencapai 100%. Hal ini dimungkinkan karena data bunga iris termasuk data acuan yang dapat dikatakan mendekati ideal jika dibandingkan dengan data *multispectral image* yang didapat dari *Landsat Thematic Mapper*, sehingga akurasi yang dicapai pun dapat jauh lebih besar dari percobaan dengan data *multispektral image*.

Memilih nilai *smoothing parameter (h)* yang tepat berpengaruh pada keakuratan hasil klasifikasi. Pada penelitian ini, dimana sebagai inisialisasi awal nilai *h* digunakan perumusan seperti yang dijelaskan pada bagian metodologi, hasilnya menunjukkan bahwa keakuratan hasil klasifikasi *Probabilistic Neural Network* cukup bervariasi seiring dengan adanya perubahan nilai

smoothing parameter (h). Untuk jumlah training = 9, dan 15, perubahan lebar *h* menyebabkan akurasi menjadi cukup bervariasi, seperti yang terlihat pada gambar 10.

Khusus untuk kasus jumlah training=12, perubahan lebar *h* tidak banyak berpengaruh terhadap besarnya akurasi yang didapat, dimana untuk *h*=0.35, 0.7, 0.875 dan 1.05 akurasi yang didapat tetap 97.33%. Faktor pemilihan kombinasi training yang baik yaitu dengan memilih data yang homogen pada saat membuat data training ini dapat menjelaskan hal tersebut dan membuat akurasi PNN untuk jumlah data training 12 dan 15 sama, yaitu mencapai 97.33%.

Grafik perubahan akurasi PNN seiring dengan perubahan jumlah data training dan besar nilai *smoothing* dapat dilihat pada grafik di bawah ini.



Gambar 11. Grafik Keakuratan PNN Pada Beberapa *h* untuk Beberapa Jumlah Data Training yang Berbeda.

Kelebihan dan Keterbatasan Sistem

1. Kelebihan Sistem

Kelebihan dari sistem diantaranya adalah:

- Sistem dapat melakukan pembelajaran dan mengklasifikasikan input berupa data *multispectral image* yang diambil dari *Landsat Thematic Mapper*. Dengan jumlah training yang terbatas yaitu sebanyak 84 (12 data per kelas), akurasi mencapai 64, 26%.
- Penambahan data training dapat dilakukan tanpa harus mengulang pelatihan dari awal.
- Keluaran berupa peta dengan pewarnaan *pixel* yang berbeda untuk setiap kelasnya sehingga akan lebih jelas.
- Sistem dibuat sederhana dan *user friendly* dengan menggunakan *user interface* berbasis GUI (*Graphical User Interface*), sehingga lebih mudah dipahami.

2. Keterbatasan Sistem

Sistem masih mempunyai keterbatasan dalam melakukan pengklasifikasian. Beberapa hal yang menjadi keterbatasan sistem antara lain:

- Seiring dengan bertambahnya jumlah training, proses klasifikasi berjalan semakin lambat dan memerlukan kapasitas memori yang cukup besar untuk dapat bekerja dengan baik
- Pengguna tidak dapat menentukan sendiri besar nilai *smoothing parameter (h)* yang akan digunakan
- Belum ada fasilitas untuk mencari tahu lokasi tertentu di image diklasifikasikan sebagai kelas penggunaan lahan apa

KESIMPULAN DAN SARAN

Kesimpulan

Probabilistic Neural Network merupakan *feed forward network* yang terdiri dari tiga *layer*. Proses pelatihannya lebih cepat karena hanya 'sekali jalan', namun waktu eksekusinya relatif lebih lama dan membutuhkan memori yang cukup besar.

Perubahan besar *smoothing parameter (h)* yang kecil kurang mempengaruhi keakuratan hasil klasifikasi PNN, namun apabila pemilihan besar nilai *smoothing parameter (h)* tepat, maka hasil klasifikasi akan semakin baik. Selain itu akurasi klasifikasi juga dipengaruhi oleh jumlah dan kehomogenan data *training* yang diberikan.

Keakuratan hasil klasifikasi PNN pada *multispectral image* yang diteliti menggunakan *Matlab Neural Network Toolbox* paling tinggi sebesar 64,26% yang dicapai pada saat jumlah *training* 84 *pixel* dan besar *smoothing parameter (h)*=0,9. Sedangkan untuk kasus bunga iris, akurasi hasil klasifikasinya mencapai 97,33%.

Dengan akurasi sebesar 64,26% daerah sekitar Cengkareng yang terekam oleh satelit Landsat 6 yang diteliti diklasifikasikan menjadi daerah laut sebesar 7642,35ha, tepi pantai 2761,38 ha, rural 2022,93 ha, *urban* 3005,73 ha, area parkir kendaraan 2713,59 ha, kompleks perumahan 3521,16 ha dan daerah padat penduduk sebesar 1925,82 ha.

Jika dibandingkan dengan metode statistik analisa diskriminan, dihasilkan akurasi sebesar 54,3%, maka untuk kasus *multispectral image* metode *JST PNN* bekerja lebih baik, karena akurasi yang dihasilkan mencapai 64,26%

Pemilihan data training akan lebih baik jika merupakan daerah yang homogen. Untuk kasus penutup lahan, area contoh yang diambil untuk tipe penutup lahan yang sama pada lokasi yang berbeda dapat saja menunjukkan spektral penciri yang berbeda, begitu juga sebaliknya.

Saran

Penelitian lebih lanjut yang dapat dilakukan adalah sebagai berikut:

- Memanfaatkan algoritma genetika dalam memilih besar nilai *smoothing parameter (h)* yang optimal.
- Memakai nilai *smoothing parameter* yang berbeda untuk setiap kelasnya.
- Menambah dan memperbaiki data training agar lebih homogen dan tepat.
- Menggunakan *threshold* sehingga jika tidak memenuhi *threshold*, maka *pixel* tidak akan diklasifikasikan.

Metode klasifikasi PNN dapat diaplikasikan juga dalam penelitian lain seperti klasifikasi mutu tanaman teh, klasifikasi pohon tembakau dan lain-lain.

DAFTAR PUSTAKA

- Anyomous.** *Probabilistic Neural Network*. http://homepages.gold.ac.uk/nikolaev/311_pnn.htm [Juli 2003].
- Ardiansyah, M.**1987. Analisis Digital Data MSS Landsat Untuk Pemetaan Penutup Lahan/Tataguna Lahan, Suatu Studi Kasus Daerah Lembang dan Sekitarnya, Jawa Barat. Skripsi. Jurusan Tanah Fakultas Pertanian IPB, Bogor.
- Fauset, L.** 1994. *Fundamentals of Neural Networks*. Prentice-Hall, New Jersey.
- Masters, T.** 1995. *Advanced Algorithms for Neural Networks: A C++ Sourcebook*, pp.157-220. John Willey, New York.
- Mathwork Inc.** 2002. *Neural Network Toolbox for Use With Matlab*. The Mathwork Inc. Natick, USA.
- Richards, John A.** 1986. *Remote sensing Digital Image Analysis: An Introduction*. Springer-Verlag Berlin Heidelberg, New York.

SPSS Inc. 2003. *SPSS Help*. The SPSS Inc. USA.

Silverman, B.W. 1990. *Density Estimation for Statistics and Data Analysis*. Chapman and Hall, New York.

Specht, D.F. 1990. *Probabilistic Neural*

Networks and The Polynomial Adaline as Complementary Techniques for Classification. IEEE Transactions on Neural Networks, vol.1, pp.111-114.

Verbyla, David.1995. *Satellite Remote Sensing of Natural Resources*. CRC Press,Inc. USA.