

**KLASIFIKASI PENUTUP/PENGGUNAAN LAHAN DENGAN DATA
SATELIT PENGINDERAAN JAUH HIPERSPEKTRAL (HYPERION)
MENGUNAKAN METODE NEURAL NETWORK TIRUAN
(LAND-USE/LAND-COVER CLASSIFICATION WITH HYPERSPECTRAL
REMOTE SENSING SATELLITE DATA USING ARTIFICIAL NEURAL
NETWORKS METHOD)**

Dony Kushardono

Pusat Pemanfaatan Penginderaan Jauh

Lembaga Penerbangan dan Antariksa Nasional

Jl. Kalisari Lapan No. 8, Pekayon, Pasar Rebo, Jakarta Timur 13710, Indonesia

e-mail : dony_kushardono@lapan.go.id

Diterima 19 Agustus 2016; Direvisi 2 Desember 2016; Disetujui 13 Desember 2016

ABSTRACT

Hyperspectral remote sensing data has numerous spectral information for the land-use/land-cover (LULC) classification, but a large number of hyperspectral band data is becoming a problem in the LULC classification. This research proposes the use of the back propagation neural network for LULC classification with hyperspectral remote sensing data. Neural network used in this study is three layers, in which to test input layer has a number of neurons as many as 242 to process all band data, 163 neurons, and 50 neurons to process the data band has a high average digital number, and data bands at wavelengths of visible to near infrared. The results showed the use of all the data band hyperspectral on classification with the neural network has the highest classification accuracy of up to 98% for 18 LULC class, but it takes a very long time. Selecting a number of bands of precise data for classification with a neural network, in addition to speeding up data processing time, can also provide sufficient accuracy classification results.

Keywords: *Hyperspectral, LULC, Classification, Neural network*

ABSTRAK

Data penginderaan jauh hiperspektral memiliki informasi spektral yang sangat banyak untuk klasifikasi penutup/penggunaan lahan (LULC), akan tetapi banyaknya jumlah *band* data hiperspektral menjadi masalah dalam klasifikasi LULC. Penelitian ini mengusulkan penggunaan *back propagation neural network* untuk klasifikasi LULC dengan data penginderaan jauh hiperspektral. *Neural network* yang dipergunakan 3 lapis, dimana untuk uji coba lapis masukan memiliki jumlah *neuron* sebanyak 242 untuk mengolah seluruh *band*, 163 *neuron*, dan 50 *neuron* untuk mengolah data *band* yang memiliki nilai digital rata-rata yang tinggi, dan data *band* pada panjang gelombang cahaya tampak hingga infra merah dekat. Hasil penelitian menunjukkan penggunaan seluruh *band* data hiperspektral pada klasifikasi dengan *neural network* memiliki akurasi hasil klasifikasi tertinggi hingga 98% untuk 18 kelas LULC, akan tetapi waktu yang diperlukan sangat lama. Pemilihan sejumlah *band* data yang tepat untuk klasifikasi dengan *neural network*, selain mempercepat waktu pengolahan data, juga bisa memberikan akurasi hasil klasifikasi yang mencukupi.

Kata Kunci : *Hiperspektral, LULC, Klasifikasi, Neural network*

1 PENDAHULUAN

Rendahnya keakuratan hasil klasifikasi penutup/penggunaan lahan dengan data penginderaan jauh (inderaja) secara digital adalah karena kurangnya informasi yang diperlukan untuk membedakan obyek lahan. Pada klasifikasi penutup/penggunaan lahan dengan hanya mempergunakan informasi spektral dari data penginderaan jauh, dipandang tidak bisa meningkatkan akurasi hasil klasifikasinya [Kushardono *et.al.*, 1995a, Whiteside dan Ahmad, 2005]. Untuk itu guna meningkatkan akurasi hasil klasifikasi tersebut, saat ini banyak diusulkan penggunaan informasi spasial [Kushardono *et.al.*, 1995a, Sun *et al.*, 2005, Whiteside dan Ahmad, 2005, Sari dan Kushardono, 2014], penggunaan informasi spektral beda waktu dari data inderaja multi-temporal [Kushardono *et al.*, 1995b, Muller *et al.*, 2004, Deilmai *et al.*, 2014], penggunaan informasi gabungan spasial dan temporal [Kushardono *et al.*, 1995b], penggunaan informasi multisensor dari data inderaja optic dan radar [Kushardono, 1997a]. Dengan kata lain penelitian sebelumnya mengatakan semakin banyak informasi penginderaan jauh yang dipergunakan untuk klasifikasi obyek penutup/penggunaan lahan, akurasinya makin meningkat.

Dengan telah diluncurkannya satelit EO-1 yang dilengkapi pengindera

hiperspektral Hyperion 242 *band* pada panjang gelombang 400 nm hingga 2500 nm (Beck, 2003), maka penggunaan informasi inderaja untuk klasifikasi penutup/penggunaan lahan secara digital menjadi tidak hanya terbatas pada data multispektral tiga hingga delapan *band*. Dengan demikian meningkatkan akurasi hasil klasifikasi penutup/penggunaan lahan diharapkan dapat dilakukan dengan masukan informasi data hiperspektral.

Muhammad dan Arjasakusuma (2010) melakukan klasifikasi dengan data hiperspektral berbasis metode *spectral angle mapper* dari data spektral lapangan, tetapi hasil klasifikasinya masih rendah. Craig dan Shan (2002) mengusulkan metode pengolahan klasifikasi dengan data hiperspektral penggunaan metode PCA pada data AVIRIS 60 *band*, tetapi hasilnya juga masih belum tinggi dibanding penggunaan data asli seluruh *band* (Du *et al.*, 2006). Untuk meningkatkan pengelompokan dalam klasifikasi, Kitti *et al.* (2012) mengusulkan metode penggabungan informasi PCA dan *informations gain* dari data hiperspektral. Sedang Ablin dan Sulochana (2013) mengusulkan penggunaan informasi spektral dan spasial untuk meningkatkan akurasi hasil klasifikasi dengan data hiperspektral.

Permasalahan klasifikasi penutup/penggunaan lahan secara digital meng-

gunakan data inderaja hiperspektral adalah bagaimana caranya memperoleh informasi dari ratusan *band* data tersebut untuk pengklasifikasi. Untuk mendapatkan informasi maksimal dari seluruh *band* data hiperspektral dalam klasifikasi penutup/penggunaan lahan, penelitian ini mengusulkan metode pengklasifikasi *neural networks*, dimana berdasarkan penelitian sebelumnya pengklasifikasi *neural networks* memiliki kemampuan mengolah data *volume* besar (Kushardono, 1997b).

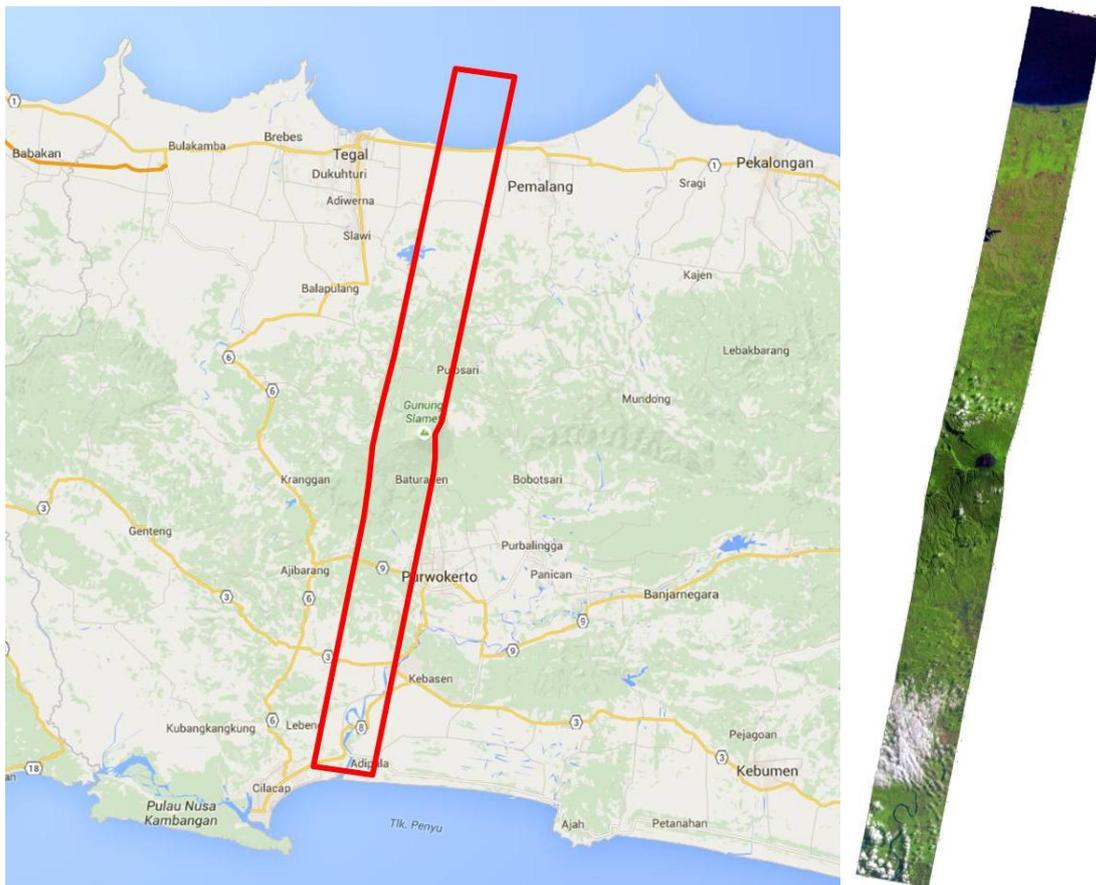
2 BAHAN DAN METODE

2.1 Lokasi dan Bahan

Bahan utama dalam penelitian ini adalah Data Satelit EO-1 Hyperion 242 *band*, 16 bit data, resolusi spasial 30m dan luas cakupan 7,5 km kali 100

km, level data koreksi terain (Level 1Gst), format GeoTIFF, serta tanggal akuisisi data 5 Agustus 2014. Adapun daerah cakupan datanya pada sebagian Kabupaten Pemalang, Gunung Slamet, Kabupaten Purwokerto hingga Kabupaten Cilacap seperti pada Gambar 2-1. Dimana dipilihnya daerah ini karena adanya keberagaman penutup/penggunaan lahan mulai dari laut hingga pegunungan.

Sebagai data referensi juga dipergunakan data satelit resolusi spasial tinggi pada 29 Juli 2014 sebagaimana contoh pada Gambar 2-2, untuk mendukung pembuatan data referensi yakni *training data* untuk pembelajaran dalam klasifikasi dan *test site data* untuk menguji akurasi hasil klasifikasi.



Gambar 2-1: Lokasi dan data hiperspektral yang dipergunakan

2.2 Metode

Pengklasifikasi yang dipergunakan dalam penelitian ini adalah *Back propagation neural networks* atau BPNN (Kushardono, 1997b), yakni seperti yang diperlihatkan pada Gambar 2-3, jenis *neural network* yang berlapis-lapis, terdiri dari lapis masukan yang memiliki jumlah *neuron* untuk memasukan *band* data hiperspektral, satu lapis tengah dengan sejumlah *neuron* dan *neuron* pada lapis keluaran untuk mendapatkan hasil klasifikasi. Dimana BPNN yang pada penelitian sebelumnya menggunakan lapis masukan dengan jumlah *neuron* sedikit sejumlah *band* spektral data Landsat TM atau SPOT, pada penelitian ini untuk dapat mengolah data hiperspektral jumlah *neuron* pada lapis masukan didisain hingga ratusan. Selain itu untuk mengetahui jumlah yang optimal *band* hiperspektral untuk klasifikasi penutup/penggunaan lahan, diujicoba berbagai *band* spektral yang dimasukan berdasarkan hasil kajian statistik datanya.

Tahapan pengolahan klasifikasi dengan BPNN dilakukan sebagai berikut,

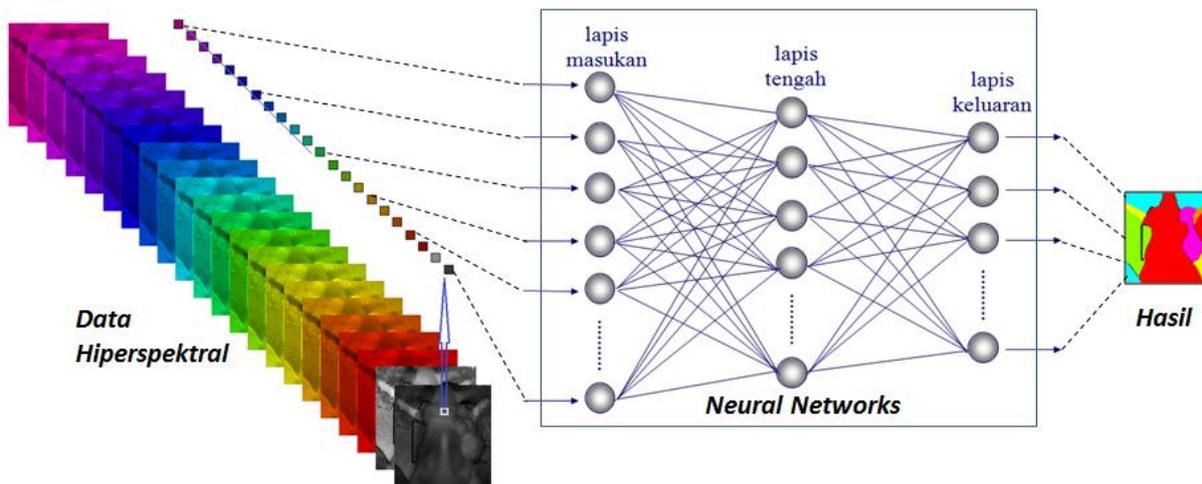
- a. Penentuan kelas penutup/penggunaan lahan dilakukan dengan interpretasi visual pada citra hiperspektral 3 *band* yang dipilih mewakili *band* merah, hijau dan inframerah dekat, dengan referensi citra satelit resolusi tinggi Gambar 2-2,
- b. Berdasarkan interpretasi visual pola yang nampak pada citra diidentifikasi 18 kelas penutup/penggunaan lahan

untuk pemetaan skala 1:50.000 berdasarkan SNI 7645:2010 seperti pada Tabel 2-1 yang dipergunakan sebagai data pembimbing (*training data*) dalam klasifikasi,

- c. Arsitektur BPNN yang dipergunakan adalah lapis masukan terdiri dari *neuron-neuron* yang jumlahnya sama dengan jumlah *band* data yang dimasukan, sedang lapis tengah jumlah *neuron*-nya adalah 2 kali jumlah *neuron* pada lapis keluaran yang merupakan jumlah optimum sebagaimana hasil penelitian sebelumnya (Kushardono, 1995a), dan lapis keluaran jumlah *neuron*-nya 18 sama dengan jumlah kelas penutup/penggunaan lahan,
- d. Klasifikasi penutup/penggunaan lahan menggunakan BPNN dilakukan dengan memasukan seluruh *band* (242 *band*) atau sebagian *band* data hiperspektral, dimana hasilnya akan dibandingkan untuk mendapatkan jumlah *band* yang optimum dalam klasifikasi. Pembelajaran BPNN menggunakan *training data* dilakukan hingga maksimum 10.000 iterasi pembelajaran atau hingga RMS *error*-nya kurang dari 0,01,
- e. Evaluasi hasil klasifikasi dilakukan dengan menggunakan data uji (*test site Data*) dari 18 kelas penutup/penggunaan lahan sebagaimana Tabel 2-1, dimana *test site data* diperoleh berdasarkan interpretasi visual dan bantuan citra referensi pada daerah diluar daerah *training data*.



Gambar 2-2: Sebagian citra satelit resolusi tinggi sebagai referensi (Sumber: Google Earth)



Gambar 2-3: Model klasifikasi berbasis *Neural Networks*

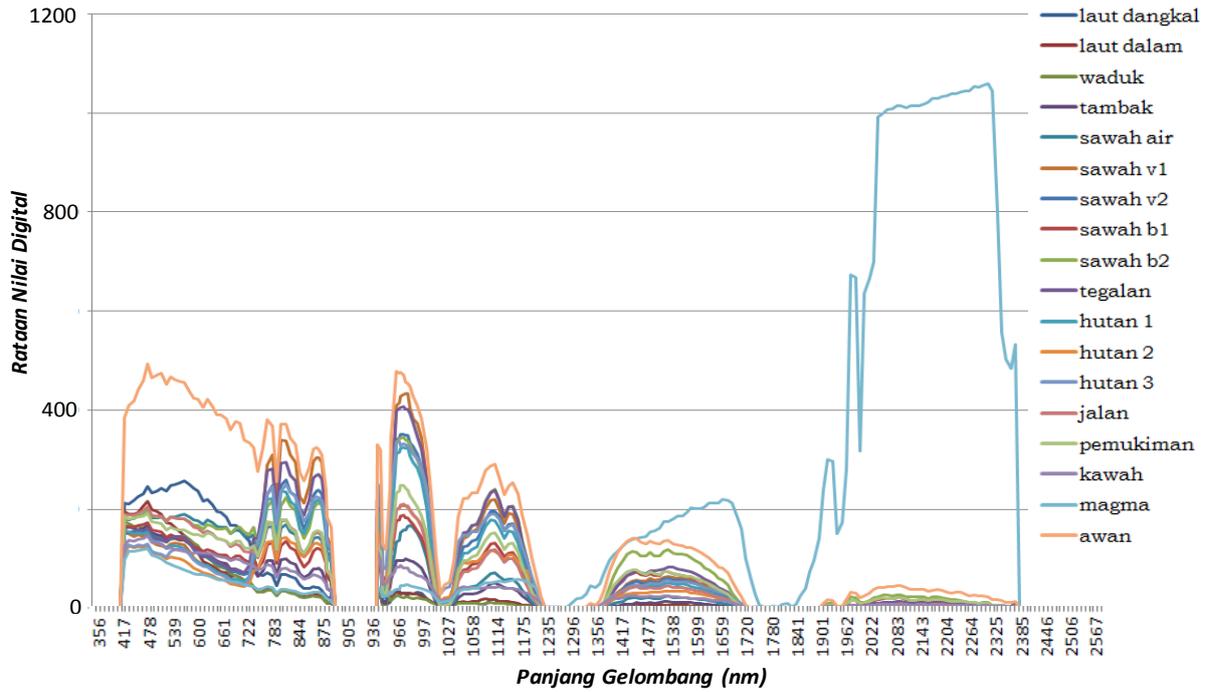
Tabel 2-1: KELAS PENUTUP/PENGGUNAAN LAHAN YANG DIPERGUNAKAN

No	Kelas	Kelas SNI 7645:2010	Warna	Keterangan Lokasi	Luasan (M ²)	
					Training	Test Site
1	Laut dalam	Laut		Laut Jawa	8.089,4	88.983,8
2	Laut dangkal	Laut		Pesisir Laut Jawa	8.089,4	73.703,8
3	Waduk	Waduk		Waduk Cacaban-Tegal	8.089,4	133.026,4
4	Jalan	Jaringan Jalan		Jalan Pantura di Suradadi	8.988,3	40.447,2
5	Pemukiman	Pemukiman		Pemukiman di Suradadi	9.887,1	48.536,6
6	Tambak	Tambak Ikan		Tambak dan kolam ikan di Suradadi	8.089,4	62.019,0
7	Sawah air	Sawah Irigasi		Sawah fase air di Suradadi	9.887,1	89.882,7
8	Sawah v1	Sawah Irigasi		Sawah fase vegetatif awal di Suradadi	9.887,1	86.287,4
9	Sawah v2	Sawah Irigasi		Sawah fase vegetatif di Suradadi	8.089,4	75.501,4
10	Sawah b1	Sawah Irigasi		Sawah fase panen di Suradadi	8.089,4	44.941,3
11	Sawah b2	Sawah Irigasi		Sawah fase bera di Suradadi	8.089,4	52.131,9
12	Tegalan	ladang		Kebun campuran di Kedung Banteng	8.089,4	38.649,5
13	Hutan 1	Hutan Jati		Hutan Jati di Kedung Banteng	8.089,4	85.388,5
14	Hutan 2	Hutan lahan kering		Hutan di Lereng Gunung Slamet	8.089,4	139.318,1
15	Hutan 3	Hutan lahan kering		Hutan semak di lereng Gunung Slamet	9.887,1	51.233,1
16	Kawah 1	Kaldera		Lereng kawah Gunung Slamet	8.089,4	99.769,7
17	Kawah 2	Lahar		Magma Gunung Slamet	8.089,4	27.863,6
18	Tidak ada info	-		Daerah tertutup awan	8.089,4	94.376,8

3 HASIL DAN PEMBAHASAN

Dari *Training Data* yang diperoleh dilakukan analisis statistik diperoleh histogram nilai rata-rata 18 kelas penutup/penggunaan lahan seperti pada Gambar 3-1 di bawah, dimana nampak keterpisahan antar kelas cukup baik hampir pada seluruh panjang gelombang yang tercakup pada sensor Hyperion antara 400nm hingga 2500nm

yang terbagi dalam 242 *band*. Maka dilakukan klasifikasi BPNN dengan masukan 242 *band data Hyperion* dan diperoleh hasil klasifikasi seperti pada Gambar 3-3(a), dimana setelah dilakukan evaluasi akurasi hasil klasifikasinya mempergunakan *Test Site Data* diperoleh pengukuran hasilnya seperti Pada Tabel 3-1.



Gambar 3-1: Statistik data hiperspektral pada 18 kelas penutup/penggunaan lahan

Tabel 3-1: AKURASI HASIL KLASIFIKASI BPNN UNTUK 242 BAND SEBAGAI DATA MASUKAN

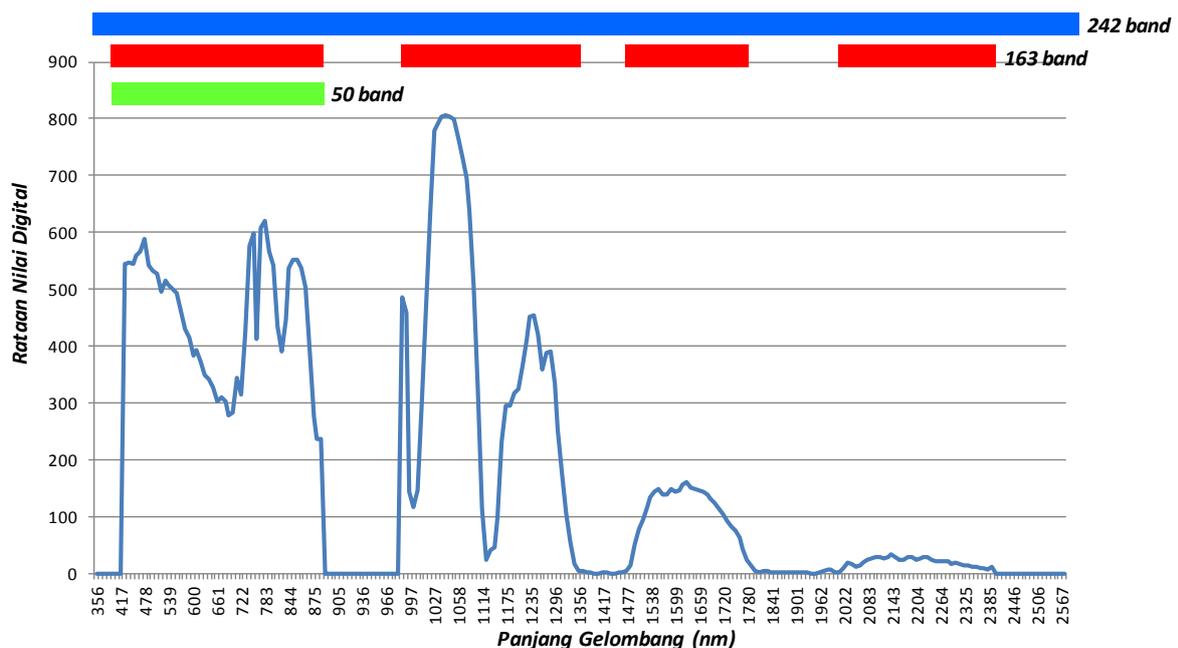
Kelas Hasil	Test Site Data																	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	93.3	0	0	0	0	1.19	0	1.72	0	0	0	0	0	0	0
5	0	0	0	6.7	100	0	0	0	1.19	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	100	0	0	0	0	0	1.05	0	0	0	0	0
8	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	97.6	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	98.3	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	100	1.75	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98.3	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	53.57	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	46.4	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100

Sebagai perbandingan pada penelitian ini juga dilakukan klasifikasi BPNN mempergunakan data hiperspektral dan *training data* yang sama, dengan masukan 163 *band* dan 50 *band* data. Dimana 163 *band* diambil pada *band-band* data yang secara statistik memiliki nilai rata-rata tinggi sebagaimana yang diperlihatkan pada Gambar 3-2, sedang 50 *band* diambil dari *band-band* data dengan rata-rata yang tinggi pada daerah panjang gelombang cahaya tampak hingga inframerah dekat (400nm~880nm). Selain itu sebagai pembandingan juga dilakukan klasifikasi terbimbing *Maximum Likelihood* dengan masukan data informasi utama PCA (MLL PCA) sebagaimana yang diusulkan Mader *et al.* (2006) dari data Hyperion dan *training data* yang sama. Adapun hasilnya adalah seperti pada Gambar 3-3(b), (c), (d) dengan akurasi hasil klasifikasi seperti pada Tabel 3-2.

Pada perbandingan hasil klasifikasi Gambar 3-3, sekilas nampak bahwa hasil BPNN dengan 242 *band* data sebagai masukan, sama dengan 163 *band* data dan 50 *band* data untuk klasifikasi terhadap 18 kelas penutup/penggunaan lahan. Akan tetapi hasil

sangat berbeda dan nampak kurang baik pada hasil klasifikasi menggunakan MLL PCA. Hal ini disebabkan karena pada klasifikasi MLL PCA yang mempergunakan data 5 komponen utama PCA sebagai masukan tersebut tidak mampu mewakili seluruh informasi spektral pada 242 *band* data hiperspektral.

Dari pengukuran akurasi hasil klasifikasi dan waktu pengolahan datanya Tabel 3-2, terlihat bahwa walaupun pada MLL PCA waktu pengolahan datanya sangat cepat yakni tidak sampai satu menit, tetapi akurasi hasil klasifikasinya tidak lebih baik dibanding BPNN. Sedang pada klasifikasi BPNN penggunaan seluruh *band* data atau 242 *band* data akurasinya tertinggi dan 2% lebih tinggi dari BPNN dengan 163 *band* maupun 50 *band*, tetapi waktu pengolahannya menggunakan masukan seluruh *band* untuk pembelajaran *neural network* satu menit lebih lama dan untuk klasifikasi 18 menit lebih lama dibanding menggunakan masukan 163 *band*, bahkan jauh lebih lama 45 menit untuk pembelajaran dan 1 jam lebih dibanding dengan masukan 50 *band* data.



Gambar 3-2: Statistik data hiperspektral yang dipergunakan dan jumlah *band* data sebagai *input* dalam klasifikasi

Diperolehnya akurasi hasil klasifikasi BPNN dengan masukan 50 *band* pada panjang gelombang cahaya tampak hingga inframerah dekat yang sudah cukup tinggi, disebabkan karena untuk 18 kelas LULC yang dijadikan target klasifikasi sebagaimana terlihat pada statistik Gambar 3-1, pada panjang gelombang tersebut keterpisahan antar kelasnya sudah nyata.

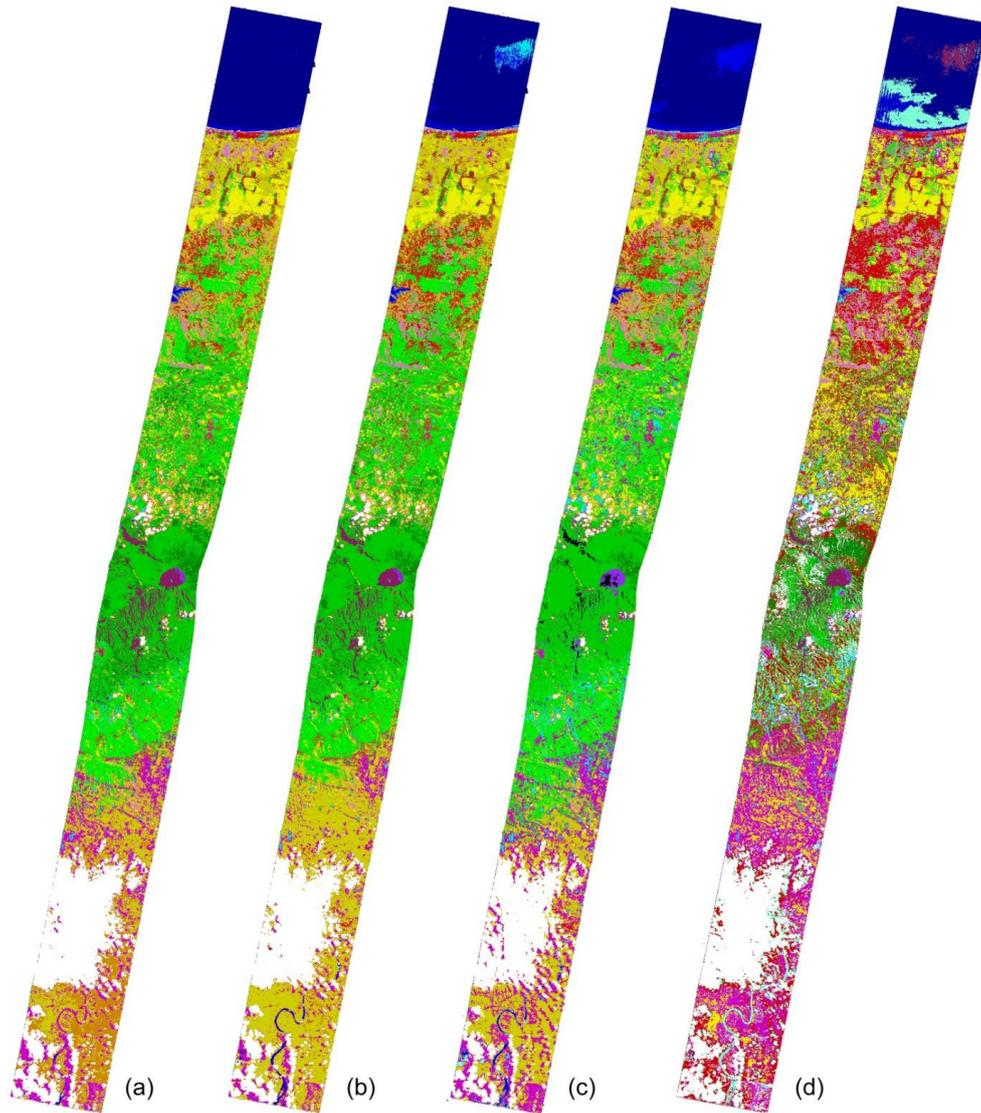
Demikian pula jumlah iterasi dalam pembelajaran BPNN untuk mencapai RMS *error* klasifikasi yang ditetapkan kurang dari 0.01, sebagaimana terlihat pada Gambar 3-4, makin banyak jumlah *band* data hiperspektral sebagai masukan, semakin banyak jumlah iterasi untuk mencapai RMS *error* yang diinginkan, yakni pada masukan 242 *band* dibutuhkan 9233 iterasi, 163 *band* 8717 iterasi, dan 50 *band* 7356 iterasi. Hal tersebut disebabkan semakin banyak *band* data masukan semakin banyak interaksi antar *neuron* lapis tengah dan lapis masukan pada *neural network*, yang berarti semakin banyak *update* parameter *gain offset* antar *neuron* (Kushardono, 1997) tiap kali iterasi untuk upaya menurunkan RMS *error*, dimana nampak pula pada Gambar 3-4 *gain offset* antar *neuron* tersebut yang awalnya ditentukan acak, semakin banyak *neuron*, penurunan RMS *error*-nya semakin sulit terutama pada awal-awal iterasi. Dengan demikian jumlah penggunaan *band* data pilihan sesuai obyek lahan yang diklasifikasi sebagai masukan dalam BPNN, semakin sedikit semakin cepat waktu pembelajaran dan klasifikasinya.

Tingginya akurasi hasil klasifikasi pada penggunaan model 242 kanal, selain jumlah *neuron* lapis masukan yang berhubungan dengan *neuron* lapis tengah menjadi semakin banyak, dimana pada penelitian Kushardono *et al.* (1995a) jumlah *neuron* pada lapisan ini semakin banyak semakin memudahkan pengklasifikasi *neural network* dalam membedakan kelas, terutama pada klasifikasi dengan jumlah kelas penutup lahannya yang banyak. Selain itu dengan model 163 kanal yang tidak mempergunakan informasi pada panjang 1235nm hingga 1356nm dan 1721nm hingga 1900nm, sebagaimana nampak pada Gambar 3-1 pada daerah panjang gelombang tersebut masih terdapat sebagian informasi kelas lahan utamanya kawah dan magma, yang kemungkinan informasi ini dijadikan pembeda utama dalam klasifikasi non parametrik ini pada *neuron* yang terkait, sehingga menyebabkan turunnya akurasi hasil kelas lahan ini menjadi 88% dan 44% dibanding dengan model 242 kanal yang akurasinya dapat mencapai 100% dan 46%. Sedang pada model penggunaan 163 kanal dan 50 kanal sebagai masukan dalam klasifikasi dengan BPNN memiliki akurasi hasil hampir tidak berbeda, itu disebabkan untuk klasifikasi kelas lahan pemukiman, sawah, tegalan, hutan dan perairan dengan data pada panjang gelombang 406nm hingga 902 nm yang dipergunakan model 50 kanal sebagaimana nampak pada Gambar 3-1 untuk kelas-kelas lahan tersebut sudah dapat mudah dapat dibedakan dalam klasifikasinya.

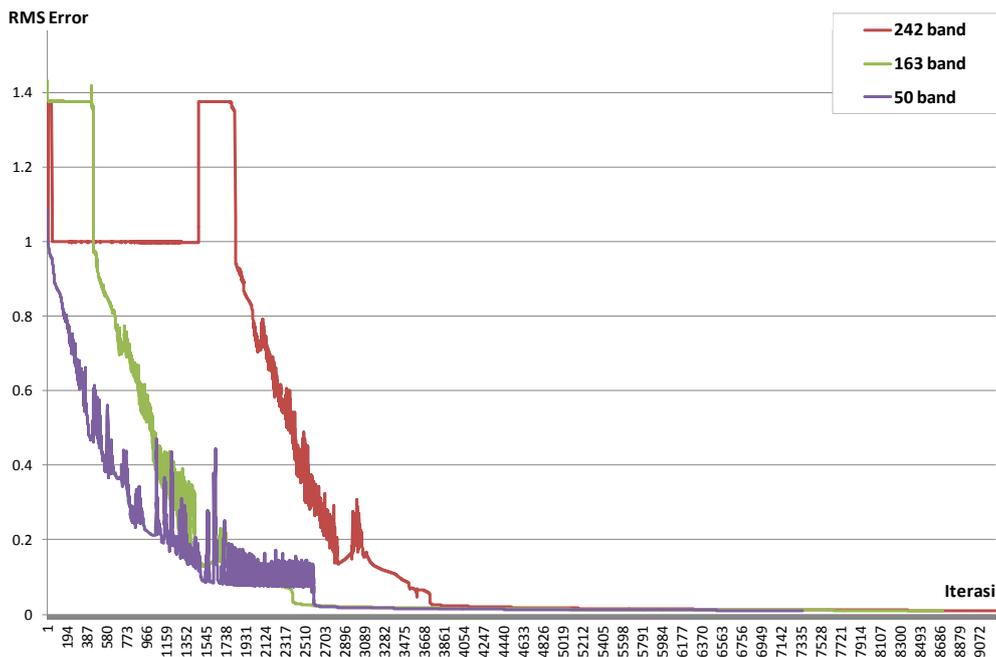
Tabel 3-2: PERBANDINGAN AKURASI HASIL KLASIFIKASI DAN WAKTU PENGOLAHANNYA

Metode	Overall Akurasi (%)	Kappa	Waktu Pengolahan*)	
			Pembelajaran	Klasifikasi
BPNN 242 <i>band</i>	98.44	0.98	49menit 24detik	69menit 32detik
BPNN 163 <i>band</i>	96.75	0.97	48menit 50detik	41menit 57detik
BPNN 50 <i>band</i>	96.22	0.96	4menit	2menit 19detik
MLL PCA	81.24	0.80	52 detik	

*) pada Komputer Core I3, 2.7GHz processor, RAM 4GB



Gambar 3-3: Perbandingan hasil klasifikasi, (a) 242 band, (b) 163 band, (c) 50 band, (d) MLL PCA



Gambar 3-4: Perbandingan proses pembelajaran klasifikasi BPNN dengan masukan 242 band, 163 band dan 50 band

4 KESIMPULAN

Penelitian ini telah menguji penggunaan *back propagation neural network* untuk klasifikasi penutup/penggunaan lahan dengan data penginderaan jauh hiperspektral.

Hasil penelitian menunjukkan penggunaan seluruh *band* data hiperspektral pada klasifikasi dengan *neural network* memiliki akurasi hasil klasifikasi sangat tinggi, akan tetapi waktu yang diperlukan sangat lama.

Dari penelitian ini juga telah dibuktikan bahwa pemilihan sejumlah *band* data yang tepat sesuai karakteristik spektral obyek lahannya untuk klasifikasi, selain mempercepat waktu pengolahan data dalam klasifikasi menggunakan *neural network* juga bisa memberikan akurasi hasil klasifikasi yang mencukupi.

Pada penelitian ini, *band* data Hyperion yang optimum untuk klasifikasi 18 kelas penutup/penggunaan lahan adalah 50 *band* data pada panjang gelombang cahaya tampak hingga inframerah dekat yang dipilih secara statistik memiliki nilai digital tinggi, dengan akurasi hasil klasifikasi mencapai 96% atau hanya 2% lebih rendah tetapi waktu pengolahannya 20 kali lebih cepat dibanding menggunakan seluruh band hiperspektral.

UCAPAN TERIMA KASIH

Diucapkan terima kasih kepada NASA's *Land Processes Distributed Active Archive Center* (LP DAAC) untuk Data EO-1 Hyperion yang dipergunakan pada penelitian ini. Ucapan terima kasih juga disampaikan kepada Ir. Mahdi Kartasmita MS. PhD. yang telah memberikan masukan untuk penyempurnaan penulisan makalah ini.

DAFTAR RUJUKAN

Ablin R. And C.H. Sulochana, 2013. *A Survey of Hyperspectral Image Classification in Remote Sensing*, Inter. J. of Advanced Research in Computer and Communication Engineering, Vol. 2, Issue 8, pp.2986-3000.

- Beck R. (ed), 2003. *EO-1 users Guide v.2.3*, Cincinnati Univ., Ohio, Amerika, <http://eo1.usgs.gov/> (diunduh Januari 2016).
- Craig R., and J. Shan, 2002. *Principal Component Analysis for Hyperspectral Image Classification*, Surveying and Land Information Systems, Vol. 62, No. 2, pp.115-123.
- Deilmai B.R., K.D. Kanniah, A.W. Rasib and A. Ariffin, 2014. *Comparison of Pixel - Based and Artificial Neural Networks Classification Methods for Detecting Forest Cover Changes in Malaysia*, IOP Conf. Ser.: Earth Environ, Sci. 18 012069.
- Du Q., I. Kopriva, and H. Szu, 2006. *Independent-Component Analysis for Hyperspectral Remote Sensing Imagery Classification*, *Optical Engineering*, Vol. 45, No. 1, 1-13.
- Kitti K., C. Jaruskulchai, and A. Eiumnoh, 2012. *Band Selection for Dimension Reduction in Hyper Spectral Image Using Integrated Information Gain and Principal Components Analysis Technique*, Inter. J. of Machine Learning and Computing, Vol. 2, No. 3, 248-251.
- Kushardono D., 1997a. *Model Klasifikasi Penutup Lahan Data Multisensor Radar Optik*, Majalah LAPAN, No.83, 31-41.
- Kushardono D., 1997b. *Metode Fuzzy Neural Network untuk Klasifikasi Penutup Lahan dari Data Penginderaan Jauh serta Perbandingannya dengan Back Propagation Neural Network dan Maximum Likelihood*, Majalah LAPAN, No.80, 31-45.
- Kushardono D., K. Fukue, H. Shimoda and T. Sakata, 1995a. *Optimized Neural Network for Spatial Landcover Classification with the Aid of Co-occurrence Matrix*, J.of the Japan Soc. Of Photogrammetry and Remote Sensing, vol.34, no.4, 22-35.
- Kushardono D., K. Fukue, H. Shimoda and T. Sakata, 1995b. *Comparison of Multitemporal Image Classification Methods*, IEEE Proc. of IGARSS, vol.II, 1282-1284.
- Mader S, M. Vohland, T. Jarmer, and M. Casper, 2006. *Crop Classification with*

- Hyperspectral Data of the Hymap Sensor using Different Feature Extraction Techniques*, Proc. of the 2nd Workshop of the EARSeL SIG on Land Use and Land Cover, Center for Remote Sensing of Land Surfaces, Bonn, 28-30 September 2006, 96-101.
- Muhammad K., dan S. Arjasakusuma, 2010. *Ekstraksi Informasi Penutup Lahan Menggunakan Spektrometer Lapangan Sebagai Masukan Endmember pada Data Hiperspektral Resolusi Sedang*, J. Ilmiah Geomatika, Vol. 16, No. 2, 10-22.
- Muller S., G.L.A. Mota, and C.E. Liedtke, 2004. *Multitemporal Interpretation of Remote Sensing Data*, Proc. of XXth ISPRS Congress Technical Commission IV, July 12-23, 2004, Istanbul, Turkey, 1244-1248.
- Sari, N.N. dan D. Kushardono, 2014. *Klasifikasi Penutup Lahan Berbasis Obyek pada Data Foto Udara untuk Mendukung Penyediaan Informasi Penginderaan Jauh Skala Rinci*, J. Penginderaan Jauh, Vol. 11, No.2, 114-127.
- Sun X., J. Zhang, and Z. Liu, 2005. *A Comparison of Object-Oriented and Pixel-Based Classification Approachs using Quickbird*, Proc. of Int. Symposium on Spatio-temporal Modeling, Spatial Reasoning, Analysis, Data Mining and Data Fusion, 27-29 Aug, Beijing, China.
- Whiteside T. and W. Ahmad, 2005. *A Comparison of Object-Oriented and Pixel-Based Classification Methods for Mapping Land Cover in Northern*, Proc. of Spatial Intelligence, Innovation and Praxis: The national biennial Conf. of the Spatial Sciences Institute, September 2005. Melbourne, Australia.