

PERBANDINGAN KLASIFIKASI BERBASIS OBYEK DAN KLASIFIKASI BERBASIS PIKSEL PADA DATA CITRA SATELIT SYNTHETIC APERTURE RADAR UNTUK PEMETAAN LAHAN (COMPARISON OF OBJECT BASED AND PIXEL BASED CLASSIFICATION ON SYNTHETIC APERTURE RADAR SATELLITE IMAGE DATA FOR LAND MAPPING)

Ahmad Sutanto*,**)¹, Bambang Trisakti** dan Aniati Murni Arimurthy*)

*) Fakultas Ilmu Komputer, Universitas Indonesia, Depok, Indonesia

***) Lembaga Penerbangan dan Antariksa Nasional, Jakarta, Indonesia

¹e-mail: sutanto_ahmad@yahoo.com

Diterima 30 April 2014; Disetujui 23 Mei 2014

ABSTRACT

Utilization of remote sensing data for land mapping has long been developed. In Indonesia, as a tropical region, the cloud becomes a classic problem in observing the Earth's surface using optical remotely sensor satellite. Synthetic Aperture Radar (SAR) sensor satellite has the ability to penetrate clouds so it can solve cloud cover problems. In this study, the ALOS PALSAR data were used to assess object-based and pixel-based classification techniques. This data was chosen due to its capacity for object recognition based on backscatter characteristics. Object-based classification using the methods of Statistical Region Merging (SRM) for the object segmentation process and Support Vector Machine (SVM) for the classification process, whereas the pixel-based classification using SVM method. In the classification stage, several features of Target Decomposition and Image Decomposition of ALOS PALSAR data have been tested. The accuracy assessment of the classification was conducted using confusion matrix of the Region of Interest (ROI) data using the QuickBird data. Implementation of the object-based classification produced better result comparing to the pixel-based classification (the number of optimal features is seven) which consisted of three features Freeman Decomposition (Red, Green, Blue), Entropy, Alpha Angle, Anisotropy and Normalized Difference Polarization Index (NDPI). Overall accuracy attained were 73.64 % for the result of the object-based classification and 62.6% for the pixel-based classification.

Keywords: *Object oriented classification, Remote sensing, SRM, SVM, SAR*

ABSTRAK

Pemanfaatan data penginderaan jauh untuk pemetaan lahan sudah lama berkembang. Di Indonesia yang beriklim tropis, awan menjadi masalah klasik dalam pemindaian permukaan bumi dengan menggunakan satelit penginderaan jauh sensor optik. Satelit dengan sensor *Synthetic Aperture Radar* (SAR) mempunyai kemampuan untuk menembus awan sehingga menjadi solusi permasalahan tutupan awan. Pada penelitian ini digunakan data ALOS PALSAR untuk mengkaji teknik klasifikasi berbasis obyek dan berbasis piksel. Data ALOS PALSAR dipilih karena mempunyai kemampuan pengenalan suatu obyek berdasarkan karakteristik hamburan baliknya (*backscatter*). Klasifikasi berbasis obyek menggunakan metode *Statistical Region Merging* (SRM) untuk proses segmentasi obyek, dan metode *Support Vector Machine* (SVM) untuk proses

klasifikasi, sedangkan klasifikasi berbasis piksel menggunakan metode SVM. Pada tahap klasifikasi telah diujicobakan beberapa fitur Dekomposisi Target dan Dekomposisi Citra dari data ALOS PALSAR. Pengujian akurasi klasifikasi dilakukan dengan metode *confusion matrix* menggunakan data *Region of Interest* (ROI) dari data QuickBird. Implementasi klasifikasi berbasis obyek memberikan hasil lebih baik dari klasifikasi berbasis piksel dengan jumlah fitur optimal yakni 7 fitur, terdiri dari 3 fitur dekomposisi *Freeman (Red, Green, Blue)*, *Entropy*, *Alpha Angle*, *Anisotrophy* dan *Normalized Difference Polarization Index* (NDPI). Akurasi keseluruhan mencapai 73,64% untuk hasil klasifikasi berbasis obyek dan 62,6% untuk klasifikasi berbasis piksel.

Kata kunci : *Klasifikasi berbasis obyek, SRM, SVM, Sensor SAR*

1 PENDAHULUAN

Konsep dasar sistem penginderaan jauh adalah seluruh rangkaian proses pengumpulan informasi suatu obyek, daerah, atau fenomena melalui analisis data yang diperoleh dengan suatu alat tanpa kontak langsung dengan obyek, daerah, atau fenomena yang dikaji (Lillesand and Kiefer, 1979). Letak geografis wilayah Indonesia yang berada pada iklim tropis dengan curah hujan tinggi serta kabut dan liputan awan yang tebal sering menyebabkan tampilan obyek pada citra hasil rekaman sensor optik terhalang oleh awan. Kondisi cuaca yang demikian dapat diatasi dengan penggunaan sistem penginderaan jauh aktif gelombang mikro. Gelombang mikro terpanjang kira-kira 25.000.000 kali lebih panjang daripada gelombang cahaya terpendek (Lillesand and Kiefer, 1979). Semakin besar panjang gelombangnya maka semakin kuat daya tembus gelombangnya. Oleh karena itu, energi gelombang mikro dapat menembus awan yang menutupi obyek yang akan diamati. RADAR merupakan sistem penginderaan jauh sensor aktif gelombang mikro yang dapat dipakai pada hampir semua kondisi cuaca.

Hasil riset internasional *European Space Agency* (ESA) menunjukkan bahwa citra ALOS PALSAR terbukti mampu mendeteksi *land use* sawah yang luasan arealnya sempit dan bentuk lahannya yang bervariasi menurut galangan pada salah satu daerah pusat

produksi padi di Provinsi Jawa Barat (Raimadoya, et. al 2000). Arifin menunjukkan bahwa citra RGB *false color* antara citra polarisasi ganda ALOS PALSAR (*dual polarimetry*: HH Horizontal-Horizontal dan HV Horizontal-Vertikal) dan citra sintetik berhasil menampilkan penutup lahan sawah di daerah bukan sentra produksi padi di Yogyakarta (Arifin, 2007). Saat ini banyak penelitian telah dilakukan untuk mengembangkan teknik/ algoritma untuk ekstraksi informasi dan klasifikasi data citra satelit *Synthetic Aperture Radar* (SAR).

Secara garis besar teknik klasifikasi tersebut dibagi menjadi dua yaitu teknik klasifikasi berbasis piksel dan teknik klasifikasi berorientasi obyek. Teknik klasifikasi berbasis piksel pada intinya adalah mengklasifikasi tiap piksel citra menjadi beberapa kelas penutup lahan berdasarkan fitur-fitur yang dimiliki piksel tersebut. Teknik klasifikasi berbasis piksel dengan menggunakan dekomposisi Yamaguchi dapat membedakan kelas hutan dan non hutan (Han, Shao, 2000), walaupun klasifikasi berbasis piksel pada citra SAR memberikan masalah mempunyai efek *salt-and-pepper* yang memberikan hasil yang kurang sempurna pada produk klasifikasi (Li et al., 2008). Efek *salt-and-pepper* atau yang biasa disebut *speckle noise* merupakan *noise* berupa efek bintik yang timbul pada citra SAR akibat interferensi gelombang-gelombang

mikro yang *out-of-phase* yang diterima sensor SAR (Lee et al, 1994). *Noise* ini mengganggu kualitas citra SAR yang dihasilkan. *Speckle noise* bisa dihilangkan antara lain dengan menggunakan *Enhanced Lee Filter* (Lopez et al, 1990). Teknik klasifikasi berorientasi obyek pada intinya mengklasifikasi citra berdasarkan segmen-segmen obyek hasil segmentasi menjadi kelas-kelas penutup lahan yang sesuai dengan karakteristik obyek (Li et al., 2008), sehingga teknik ini juga dapat menghilangkan permasalahan efek *salt-and-pepper*.

Pada penelitian ini dilakukan kajian teknik klasifikasi berorientasi obyek pada citra SAR, yaitu menerapkan teknik klasifikasi berorientasi obyek menggunakan SRM dan SVM pada data citra SAR (ALOS PALSAR) *full polarimetric*. Kemudian melakukan perbandingan hasil klasifikasi menggunakan teknik klasifikasi berorientasi obyek dan teknik klasifikasi berbasis piksel dengan cara mengevaluasi tingkat akurasi kedua teknik tersebut terhadap data citra satelit resolusi sangat tinggi.

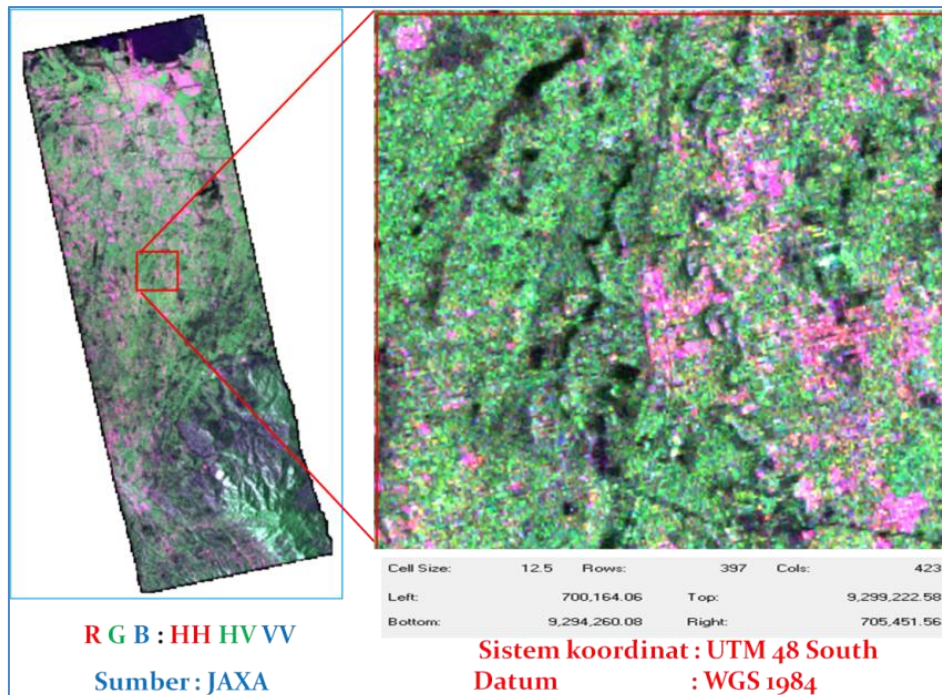
2 METODE PENELITIAN

2.1 Data dan Lokasi

Data utama yang digunakan adalah data citra Satelit ALOS PALSAR level 1.1 wilayah Jakarta dan sekitarnya dengan tanggal akuisisi data 6 Mei 2010 (Gambar 2-1). Data ALOS PALSAR ini mempunyai resolusi spasial 12,5 meter. Selain data citra ALOS PALSAR, data citra lain yang digunakan adalah data citra satelit QuickBird tahun 2010 yang merupakan data resolusi sangat tinggi dengan resolusi spasial sekitar 0,6 meter sebagai data citra referensi (Gambar 2-2).

2.2 Pengolahan Data SAR

Secara umum tahapan pengolahan data citra PALSAR dibagi menjadi empat bagian yaitu (a) ekstraksi fitur berupa dekomposisi target, dekomposisi citra, dan tekstur, (b) klasifikasi berbasis obyek, (c) klasifikasi berbasis piksel dan (d) evaluasi akurasi. Diagram alir pengolahan data dapat dilihat pada Gambar 2-2.



Gambar 2-1: Data ALOS PALSAR Daerah Kajian Wilayah Jakarta

2.2.1 Ekstraksi fitur berupa Dekomposisi Target, Dekomposisi Citra, dan Tekstur

Pada bagian ini data citra SAR yang telah dibentuk menjadi matrik koherensi kemudian didekomposisi menjadi 3 parameter target yaitu *Entropy*, *Mean Alpha Angle* dan *Anisotropy* berdasarkan *eigenvalue* dan *eigenvector* dari matriks koherensi (Sambodo, et.al 2005). Hasilnya didapatkan nilai dari ketiga parameter tadi pada setiap piksel pada citra SAR. Selain itu dihitung juga nilai *Normalized Difference Polarization Index* (NDPI) dari dual polarisasi data SAR (HV dan HH) dengan menggunakan Persamaan 2-1. NDPI dapat meningkatkan perbedaan obyek geologi dan obyek permukaan bumi lainnya (Cao, et. al, 2008. Kushardono, 2012).

$$\text{NDPI} = [\text{HV}-\text{HH}] / [\text{HH}+\text{HV}] \quad (2-1)$$

Pada dekomposisi citra, dibuat dekomposisi Pauli, dekomposisi Sinclair dan dekomposisi Freeman-Durden. Tetapi berdasarkan hasil pengamatan visual dan kajian segmentasi terhadap penampakan obyek, hasil dekomposisi Freeman-Durden (1998) lebih sesuai dengan kenampakan obyek sehingga dekomposisi ini selanjutnya digunakan dalam kegiatan klasifikasi. Dekomposisi Freeman-Durden menggambarkan tiga mekanisme fisis hamburan gelombang mikro pada data SAR yaitu *surface scattering*, *double-bounce scattering* dan *volume scattering* (Freeman, Durden, 1998). Mekanisme *surface scattering* terjadi pada obyek seperti lahan terbuka, perairan, dan lapangan. Mekanisme *double-bounce scattering* terjadi pada obyek seperti gedung dan permukiman. Mekanisme *volume scattering* terjadi pada obyek seperti pepohonan dan hutan.

Fitur tekstur didapatkan dengan menggunakan analisa Matrik kookurensi tingkat keabuan (*Grey Level Cooccurance*

Matrix (GLCM)). Hasil analisa GLCM ini menghasilkan delapan fitur tekstur yaitu *Energy*, *Contrast*, *Homogeneity*, *Entropy*, *Dissimilarity*, *Correlation*, *Mean*, dan *Variance* (Haralick, R.M, 1985).

2.2.2 Klasifikasi Berbasis Obyek

A. Tahapan Segmentasi

Proses segmentasi yang dilakukan pada penelitian ini memakai algoritma *Statistical Region Merging* (SRM). Implementasi SRM dilakukan dengan menggunakan MATLAB *source code* yang diperoleh dari internet dengan beberapa modifikasi. *Source code* dibuat oleh Sylvain Boltz (2009). ([http:// www.mathworks.com/matlabcentral/file-exchange/25619-image-segmentation-using-statistical-region-merging](http://www.mathworks.com/matlabcentral/file-exchange/25619-image-segmentation-using-statistical-region-merging)).

Proses segmentasi dilakukan dengan menggunakan metode *Statistical Region Merging* (SRM). *Input* data dalam proses segmentasi adalah citra dekomposisi Freeman-Durden. Parameter segmentasi dengan algoritma SRM ini adalah parameter *Q level* dan *Region Pixel Minimum* (Nock et al, 2004). Parameter *Q level* berkaitan dengan kompleksitas segmentasi dan menentukan banyak sedikitnya region segmen yang akan terbentuk. Nilai *Q level* yang lebih tinggi menghasilkan region segmen yang lebih banyak sehingga kompleksitas segmentasi lebih tinggi. Parameter *Region Pixel Minimum* menentukan jumlah piksel minimum yang dapat digabungkan dalam suatu region segmen. Makin tinggi nilai *Region Pixel Minimum* maka makin sedikit region segmen yang akan terbentuk (Suwono, E. 2009).

Algoritma SRM didasarkan pada analisis statistik dari piksel-piksel yang berdekatan lalu melakukan penggabungan piksel-piksel yang mirip/homogen dalam suatu batasan/region. Proses penggabungan piksel dilakukan dengan memperhatikan fungsi pengurutan (*sort function*) dan predikat penggabungan

(merging predicate) yang akan menentukan apakah dua piksel yang berdekatan akan digabung atau tidak.

Nielsen and Nock (2004) mendefinisikan fungsi pengurutan (sort function) f sebagai berikut:

$$f(p, p') = \max_{a \in \{R, G, B\}} |p'_a - p_a| \quad (2-2)$$

dimana p_a dan p'_a adalah nilai-nilai piksel yang berdekatan pada kanal a . Nielsen and Nock (2004) juga memodelkan predikat penggabungan (merging predicate) sebagai berikut:

$$p(R, R') = \begin{cases} \text{true.} & \text{if } \forall a \in \{R, G, B\}, |\overline{R'_a} - \overline{R_a}| \leq \sqrt{b^2(R) + b^2(R')} \\ \text{false.} & \text{otherwise} \end{cases} \quad (2-3)$$

dimana

$$b(R) = g \sqrt{\frac{1}{2Q|R|} \left(\ln \frac{|R_{|R|}|}{\delta} \right)}$$

$\overline{R_a}$ = nilai rata-rata kanal a pada region R
 $R_{|R|}$ = himpunan region-region dengan R piksel

Parameter SRM untuk semua citra $\delta = 1/(6 |I|^2)$

$g = 256$ (lihat referensi Nock, Nielsen, 2004)

$0 \leq \delta \leq 1$ (lihat referensi Nock, Nielsen 2004)

Pada kegiatan awal dilakukan perubahan parameter Q level dan parameter Region Pixel Minimum, dan dikaji hasil segmentasi karena perubahan parameter-parameter tersebut. Nilai Q level sebesar 256 memberikan batasan obyek yang paling jelas secara visual, dibandingkan dengan nilai Q level yang lebih rendah atau lebih tinggi. Sedangkan nilai *region pixel* minimum digunakan nilai 3, 5 dan 10.

B. Tahapan Klasifikasi Berbasis Obyek

Hasil segmentasi yang membagi citra SAR menjadi beberapa poligon segmen yang di dalamnya memiliki piksel-piksel yang mirip. Dari poligon segmen-segmen tersebut akan diklasifikasi kelas penutup lahannya. Pada penelitian ini digunakan metode *Support Vector*

Machine (SVM) untuk proses klasifikasi kelas penutup lahan. SVM merupakan salah satu pengklasifikasi (*classifier*) pada sistem klasifikasi terbimbing (*supervised classification*), yang memerlukan data latih (*training sample*) dalam proses klasifikasinya (Sembiring, 2007. Vapnik, 1999). *Input* data untuk proses klasifikasi adalah fitur dekomposisi target (*Entropy, Mean Alpha Angle* dan *Anisotropy*), NDPI, dan fitur Dekomposisi Freeman-Durden (RGB), serta enam fitur tekstur Haralick (*entropy, homogeneity, correlation, mean, contrast* dan *variance*) sehingga total adalah 13 fitur yang digunakan dalam proses klasifikasi.

Dalam proses klasifikasi pemilihan poligon segmen-segmen yang akan dijadikan data latih (*training sample*) akan mengacu pada data referensi (citra satelit resolusi tinggi). Poligon segmen-segmen yang akan dijadikan data latih (*training sample*) akan diberikan label kelas seperti label kelas yang terdapat pada data referensi. Data latih yang telah dipilih untuk tiap kelas penutup lahan kemudian akan dimasukkan ke dalam sistem klasifikasi untuk menentukan kelas penutup lahan untuk seluruh segmen yang ada pada data citra SAR. Variabel yang mewakili poligon segmen-segmen pada klasifikasi SVM adalah nilai rata-rata (Mean) dari piksel segmen tersebut pada tiap-tiap kanal.

Tahapan yang dilakukan dalam proses klasifikasi menggunakan SVM yakni melakukan penyamaan skala antara data latih (*training samples*) dan data tes (*test samples*), memilih beberapa segmen untuk menjadi data latih yang mewakili tiap kelas penutup lahan, dan menginputkan data latih ke dalam sistem SVM untuk mengklasifikasi kelas penutup lahan dari seluruh segmen. Selanjutnya, apabila secara visual hasil klasifikasi belum sesuai dengan penampakan pada citra maka dilakukan koreksi dengan memasukkan beberapa data latih atau menghapus data latih

yang lama dan memilih data latih yang baru. Proses tersebut terus berlanjut hingga didapatkan hasil seperti yang diharapkan.

Pada penelitian ini juga dilakukan eksperimen untuk mengetahui pengaruh penambahan fitur tekstur yang berupa nilai *variance*, *entropy*, *energy/second moment*, *homogeneity*, *contrast*, *correlation* dan *mean/average* dari *band* HH, HV dan VV pada proses klasifikasi. Variasi eksperimen yang dilakukan dengan menggunakan fitur tekstur dapat dilihat pada Tabel 2-2 percobaan 4.

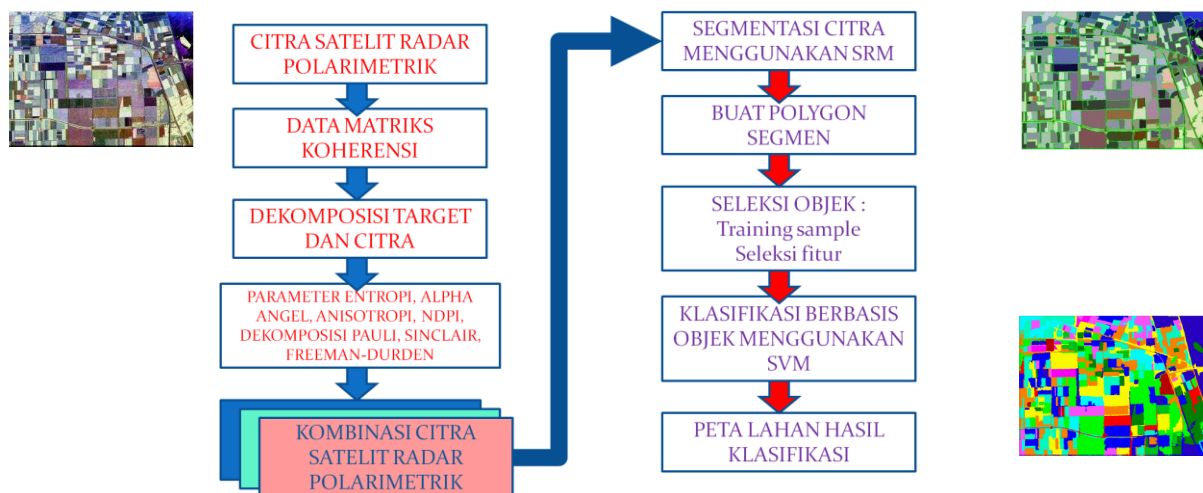
2.2.3 Klasifikasi berbasis piksel

Klasifikasi berbasis piksel dilakukan dengan menggunakan persyaratan dan data latih yang sama dengan yang digunakan pada klasifikasi berbasis

obyek. Metode yang digunakan adalah metode SVM. Perbedaan antara kedua metode klasifikasi ini yakni ada tidaknya proses segmentasi, dimana klasifikasi berbasis piksel tidak menggunakan tahapan segmentasi obyek.

2.2.4 Evaluasi akurasi

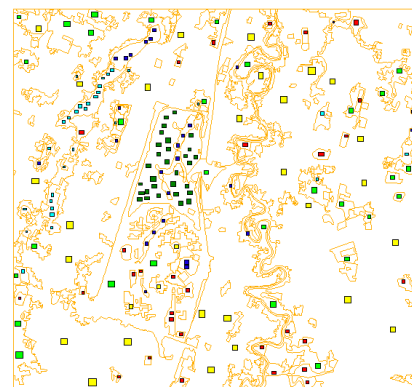
Perhitungan nilai akurasi hasil klasifikasi dilakukan dengan menggunakan metode *confusion matrix*. Data referensi yang digunakan dalam pengujian dilakukan dengan mengambil dan mengumpulkan *Ground truth Region of Interest (ROI)* dari data QuickBird, seperti diperlihatkan pada Gambar 2-3. Hasil *confusion matrix* adalah *Kappa Coefficient*, *Overall Accuracy*, *User Accuracy* dan *Producer Accuracy*.



Gambar 2-2: Diagram Alir Pengolahan Data



Data QuickBird tahun 2010 sebagai referensi



- Permukiman / gedung
- Belukar / Vegetasi jarang
- Lahan terbuka
- Tambak
- Perairan / sungai / danau
- Hutan / Vegetasi padat

Gambar 2-3: Data QuickBird Wilayah Jakarta dan *Training Sampel* untuk Pengujian

2.3 Skenario Eksperimen

Pada kegiatan ini, klasifikasi dilakukan dengan menggunakan lima skenario besar, selanjutnya dibagi lagi menjadi 22 skenario yang lebih kecil (Tabel 2-1 dan Tabel 2-2). Tujuan dari masing-masing skenario klasifikasi antara lain:

- Skenario klasifikasi 1 bertujuan untuk mengetahui pengaruh bentuk *training sample*
- Skenario klasifikasi 2 bertujuan untuk mengetahui pengaruh jumlah piksel

minimum dalam satu region segmen dan pengaruh jumlah *training sample* per kelas penutup lahan.

- Skenario klasifikasi 3 bertujuan untuk mengetahui pengaruh fitur-fitur yang dijadikan *input*.
- Skenario klasifikasi 4 bertujuan untuk mengetahui pengaruh penambahan fitur tekstur
- Skenario klasifikasi 5 bertujuan untuk mengetahui pengaruh pemberian filter pada citra SAR.

Tabel 2-1: KONDISI UNTUK PERCOBAAN KLASIFIKASI 1,2 DAN 3

Percobaan	Kondisi	Keterangan
1	1A	Jumlah fitur : 3
		Jenis fitur : dekomposisi Freeman (R,G,B)
		Segmentasi : Q level = 256, Region pixel minimum = 10
		Bentuk training sample : polygon segmentasi
		Jumlah training sample per kelas = rata-rata 3 buah
	1B	Filter : tanpa filter
		Tipe file input : 8 bit uninteger
		Jumlah fitur : 3
		Jenis fitur : dekomposisi Freeman (R,G,B)
		Segmentasi : Q level = 256, Region pixel minimum = 10
3	3A	Bentuk training sample : rectangle (persegi panjang)
		Jumlah training sample per kelas = 30 buah
		Filter : tanpa filter
		Tipe file input : 8 bit uninteger
		Jumlah fitur : 4
	3B	Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotrophy.
		Segmentasi : Q level = 256, Region pixel minimum = 10
		Bentuk training sample : rectangle (persegi panjang)
		Jumlah training sample per kelas = 30 buah
		Filter : tanpa filter
	3C	Tipe file input : 8 bit uninteger
		Jumlah fitur : 7
		Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotrophy,NDPI.
		Segmentasi : Q level = 256, Region pixel minimum = 10
		Bentuk training sample : rectangle (persegi panjang)
2	2A-1	Jumlah training sample per kelas = 10 buah
		Filter : tanpa filter
		Tipe file input : 8 bit uninteger
		Jumlah fitur : 3
		Jenis fitur : dekomposisi Freeman (R,G,B)
	2A-2	Segmentasi : Q level = 256, Region pixel minimum = 5
		Bentuk training sample : rectangle (persegi panjang)
		Jumlah training sample per kelas = 10 buah
		Filter : tanpa filter
		Tipe file input : 8 bit uninteger
	2A-3	Jumlah fitur : 3
		Jenis fitur : dekomposisi Freeman (R,G,B)
		Segmentasi : Q level = 256, Region pixel minimum = 10
		Bentuk training sample : rectangle (persegi panjang)
		Jumlah training sample per kelas = 10 buah
2B-1	Filter : tanpa filter	
	Tipe file input : 8 bit uninteger	
	Jumlah fitur : 3	
	Jenis fitur : dekomposisi Freeman (R,G,B)	
	Segmentasi : Q level = 256, Region pixel minimum = 3	
2B-2	Bentuk training sample : rectangle (persegi panjang)	
	Jumlah training sample per kelas = 30 buah	
	Filter : tanpa filter	
	Tipe file input : 8 bit uninteger	
	Jumlah fitur : 3	
2B-3	Jenis fitur : dekomposisi Freeman (R,G,B)	
	Segmentasi : Q level = 256, Region pixel minimum = 10	
	Bentuk training sample : rectangle (persegi panjang)	
	Jumlah training sample per kelas = 30 buah	
	Filter : tanpa filter	
		Tipe file input : 8 bit uninteger
		Jumlah fitur : 3
		Jenis fitur : dekomposisi Freeman (R,G,B)
		Segmentasi : Q level = 256, Region pixel minimum = 5
		Bentuk training sample : rectangle (persegi panjang)

Tabel 2-2: KONDISI UNTUK PERCOBAAN KLASIFIKASI 4,5

Percobaan	Kondisi	Keterangan	
4	4A	Jumlah fitur : 7	
		Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI.	
		Segmentasi : Q level = 256, Region pixel minimum = 10	
		Bentuk training sample : rectangle (persegi panjang)	
		Jumlah training sample per kelas = 30 buah	
		Filter : tanpa filter	
	4B	Tipe file input : 32 bit float	
		Jumlah fitur : 10	
		Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI,Varians HH, Varians HV, Varians VV. (ukuran window fitur tekstur 3X3)	
		Segmentasi : Q level = 256, Region pixel minimum = 10	
		Bentuk training sample : rectangle (persegi panjang)	
		Jumlah training sample per kelas = 30 buah	
	4C	Filter : tanpa filter	
		Tipe file input : 32 bit float	
		Jumlah fitur : 13	
		Jenis fitur : Dekomposisi Freeman (R, G, B), Entropy, Alpha Angle, Anisotropy, NDPI, Nilai entropy dan mean dari band HH, HV, VV. (ukuran window fitur tekstur 3X3)	
		Segmentasi : Q level = 256, Region pixel minimum = 10	
		Bentuk training sample : rectangle (persegi panjang)	
	4D	Jumlah training sample per kelas = 30 buah	
		Filter : tanpa filter	
Tipe file input : 32 bit float			
Jumlah fitur : 16			
Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI,Nilai entropy , mean dan homogeneity dari band HH, HV, VV. (ukuran window fitur tekstur 3X3)			
Segmentasi : Q level = 256, Region pixel minimum = 10			
4E	Bentuk training sample : rectangle (persegi panjang)		
	Jumlah training sample per kelas = 30 buah		
	Filter : tanpa filter		
	Tipe file input : 32 bit float		
	Jumlah fitur : 16		
	Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI,Nilai contrast , energy dan correlation dari band HH, HV, VV. (ukuran window fitur tekstur 3X3)		
5	4G	Segmentasi : Q level = 256, Region pixel minimum = 10	
		Bentuk training sample : rectangle (persegi panjang)	
		Jumlah training sample per kelas = 30 buah	
		Filter : tanpa filter	
		Tipe file input : 32 bit float	
		Jumlah fitur : 16	
	4H	Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI,Nilai entropy , homogeneity dan correlation dari band HH, HV, VV. (ukuran window fitur tekstur 11 X 11)	
		Segmentasi : Q level = 256, Region pixel minimum = 10	
		Bentuk training sample : rectangle (persegi panjang)	
		Jumlah training sample per kelas = 30 buah	
		Filter : tanpa filter	
		Tipe file input : 32 bit float	
5A	5A	Jumlah fitur : 7	
		Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI.	
		Segmentasi : Q level = 256, Region pixel minimum = 10	
	5B	Bentuk training sample : rectangle (persegi panjang)	
		Jumlah training sample per kelas = 30 buah	
		Filter : Enhanced Lee Filter 3X3	
		Tipe file input : 32 bit float	
		5C	Jumlah fitur : 7
			Jenis fitur : dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotropy,NDPI.
Segmentasi : Q level = 256, Region pixel minimum = 10			
5C	Bentuk training sample : rectangle (persegi panjang)		
	Jumlah training sample per kelas = 30 buah		
	Filter : Enhanced Lee Filter 7X7		
5C	Tipe file input : 32 bit float		

3 HASIL DAN DISKUSI


Citra komposit RGB yang dihasilkan dengan metode dekomposisi Freeman-Durden diperlihatkan pada Gambar 3-1. Pada citra dekomposisi Freeman-Durden, *surface scattering* menampilkan besarnya energi pantulan yang rendah yang terjadi pada obyek-obyek permukaan bumi yang datar,

seperti: tubuh air dan lapangan rumput. Penempatan *rough surface* pada band biru mengakibatkan obyek-obyek tersebut berwarna hitam kebiruan. *Double bounce* menampilkan besarnya energi pantulan yang tinggi, sehingga penempatan pada band merah menjadikan obyek-obyek bangunan tinggi yang tersebar di beberapa tempat,

terutama di sekitar jalan-jalan besar berwarna kemerahan. Sedangkan *volume scattering (canopy layer)* pada band hijau menampilkan energi pantulan menengah (menunjukkan terjadinya *scatter* berulang), yang umumnya terdapat pada daerah permukiman dan vegetasi.

Citra dekomposisi Freeman-Durden menjadi *input* proses segmentasi menggunakan metode *SRM*. Pada Gambar 3-2 diperlihatkan hasil segmentasi dari citra dekomposisi Freeman-Durden dengan parameter segmentasi *Q level* 256 dan *Region Pixel Minimum* 3,5 dan 10 piksel. Pada penelitian ini, evaluasi visual untuk melihat kemiripan antara bentuk obyek dan hasil segmentasi menjadi cara yang digunakan untuk mengukur keakuratan segmentasi dan menentukan nilai parameter yang paling sesuai.

Perbandingan antara citra dekomposisi Freeman-Durden (Gambar 3-1) dengan tiga citra hasil segmentasi (Gambar 3-2) dengan nilai *Region Pixel Minimum* yang berbeda, memperlihatkan bahwa segmentasi dengan region piksel minimum 3 dan 5 menghasilkan jumlah poligon segmen yang banyak dan terlalu detil, sehingga mengakibatkan obyek yang sama terdiri dari poligon-poligon segmen dalam berbagai ukuran. Sementara region piksel minimum 10 menghasilkan hasil segmentasi yang lebih sedikit dan kurang detil, tapi segmentasi yang dihasilkan mempunyai bentuk yang relatif sesuai dengan penampakan obyek pada citra dekomposisi Freeman-Durden, seperti tubuh air (warna hitam pada citra dekomposisi Freeman-Durden), atau kumpulan obyek bangunan tinggi (warna kemerahan).



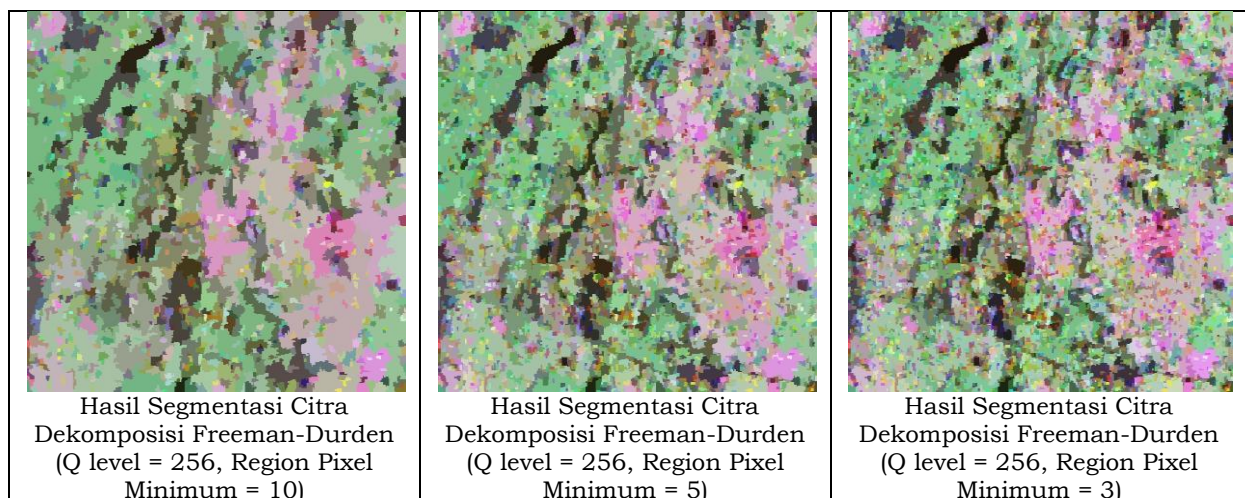
Dekomposisi Freeman-Durden

R : double bounce

G : canopy layer

B : rough surface

Gambar 3-1: Citra hasil dekomposisi Freeman-Durden



Gambar 3-2: Citra Hasil Segmentasi dengan *Region Pixel Minimum* Berbeda

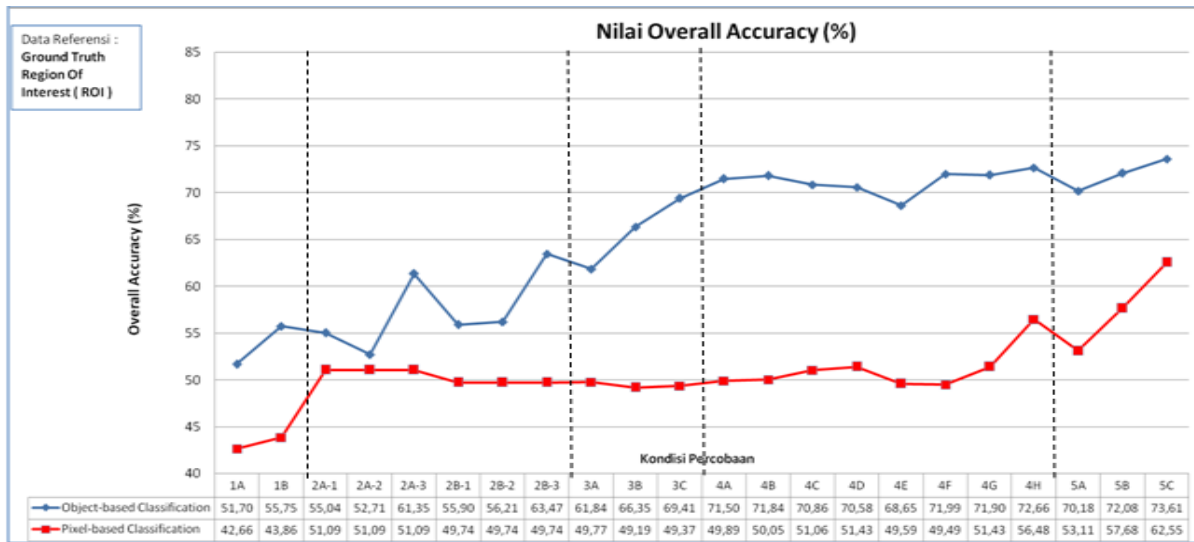
Dalam proses klasifikasi menggunakan *classifier* SVM digunakan fitur-fitur dekomposisi target dan dekomposisi Freeman-Durden yang diturunkan dari citra PALSAR, seperti yang telah dijelaskan pada bagian metode. Klasifikasi berbasis obyek dan klasifikasi berbasis piksel dilakukan dengan menggunakan skenario klasifikasi pada Tabel 2-1 dan 2-2, hanya saja tidak ada proses segmentasi pada tahapan klasifikasi berbasis piksel. Tingkat akurasi hasil klasifikasi berbasis obyek dan berbasis piksel untuk seluruh skenario klasifikasi dievaluasi dengan metode *confusion matrix*, dengan menghitung *Kappa Coefficient*, *Overall Accuracy*, *User Accuracy* dan *Producer Accuracy* (Tabel 3-1). Perbandingan *overall accuracy* untuk kedua jenis klasifikasi pada semua skenario diperlihatkan pada Gambar 3-3, dimana hasil evaluasi memperlihatkan bahwa skenario 5C merupakan skenario klasifikasi terbaik yang menghasilkan *overall accuracy* sebesar 73.6% untuk hasil klasifikasi

berbasis obyek dan *overall accuracy* sebesar 62.6% untuk hasil klasifikasi berbasis piksel.

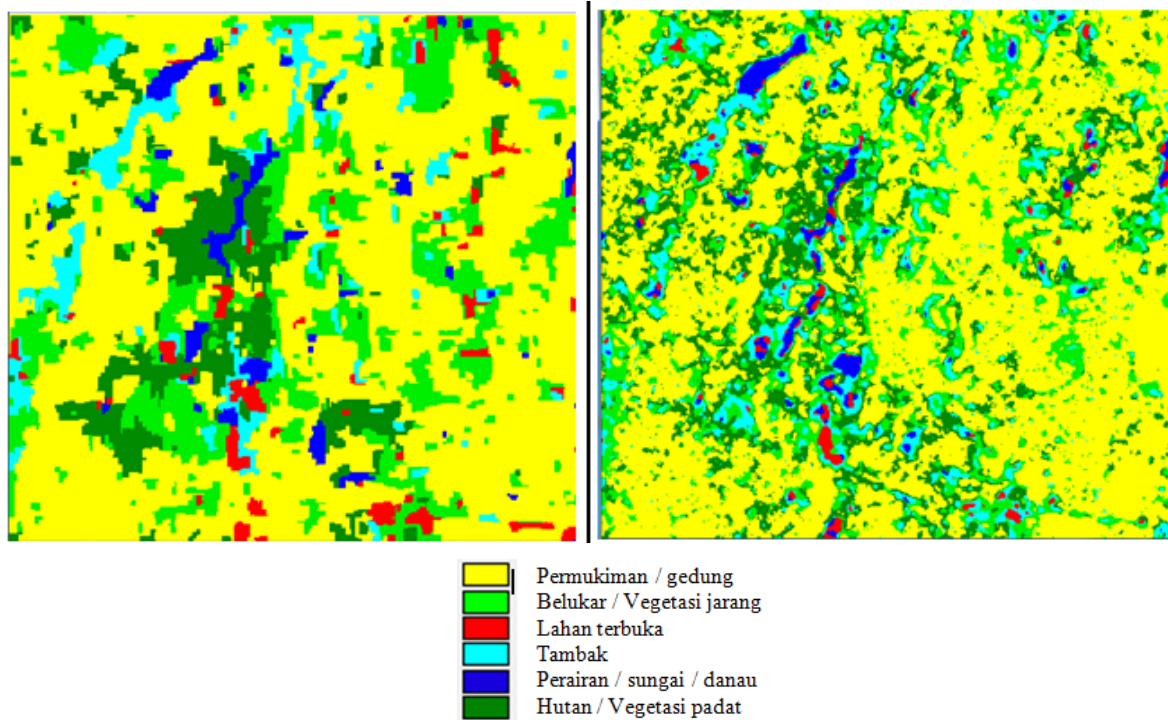
Gambar 3-4 menunjukkan hasil klasifikasi penutup lahan wilayah kajian berbasis obyek (kiri) dan berbasis piksel (kanan) untuk skenario 5C dengan menggunakan *classifier* SVM. Kedua jenis klasifikasi menggunakan *training sample*, *filter* dan *window size* 7x7 yang sama. Fitur yang digunakan adalah tiga fitur dekomposisi Freeman-Durden (RGB), *Entropy*, *Alpha Angle*, *Anisotrophy* dan NDPI. Perbedaan antara hasil kedua jenis klasifikasi terlihat dengan jelas, pada hasil *object-oriented classification* sebaran kelas penutup lahan terlihat lebih homogen karena piksel-piksel sudah dikelompokkan dalam region-region segmen, sedangkan pada hasil *pixel-based classification* sebaran kelas penutup lahan masih bercampur karena klasifikasi didasarkan pada klasifikasi per piksel bukan per obyek yang terdapat pada citra.

Tabel 3-1: PENGUJIAN HASIL KLASIFIKASI MENGGUNAKAN *CONFUSION MATRIX*

Percobaan	Kondisi	Data Referensi : Ground Truth Region Of Interest (ROI)							
		Object-based Classification				Pixel-based Classification			
		Kappa Coefficient	Overall Accuracy (%)	Average		Kappa Coefficient	Overall Accuracy (%)	Average	
				Producer Accuracy (%)	User Accuracy (%)			Producer Accuracy (%)	User Accuracy (%)
1	1A	0.3954	51.70	49.22	52.48	0.2163	42.66	36.23	18.77
	1B	0.4321	55.75	46.00	50.97	0.2562	43.86	36.75	45.89
2	2A-1	0.4242	55.04	49.66	51.28	0.3652	51.09	46.33	47.57
	2A-2	0.4023	52.71	48.67	40.92	0.3652	51.09	46.33	47.57
	2A-3	0.5126	61.35	58.03	63.51	0.3652	51.09	46.33	47.57
	2B-1	0.433	55.90	52.57	52.75	0.351	49.74	45.70	46.78
	2B-2	0.436	56.21	52.39	56.83	0.351	49.74	45.70	46.78
	2B-3	0.5289	63.47	56.33	57.02	0.351	49.74	45.70	46.78
3	3A	0.507	61.84	58.65	60.73	0.3502	49.77	45.30	46.28
	3B	0.572	66.35	65.03	65.19	0.3469	49.19	45.86	46.97
	3C	0.6106	69.41	69.60	68.75	0.3493	49.37	46.17	47.26
4	4A	0.6346	71.50	69.48	70.06	0.3531	49.89	46.64	47.54
	4B	0.6385	71.84	69.81	71.38	0.356	50.05	47.21	48.17
	4C	0.6281	70.86	69.71	68.26	0.3684	51.06	46.80	47.81
	4D	0.6253	70.58	69.65	66.53	0.3731	51.43	47.55	47.66
	4E	0.6024	68.65	67.69	65.64	0.3482	49.59	46.08	46.59
	4F	0.6434	71.99	71.39	69.57	0.3461	49.49	45.29	45.56
	4G	0.6426	71.90	70.03	67.23	0.3659	51.43	44.55	46.18
4H	0.6505	72.66	70.62	70.01	0.438	56.48	52.14	52.13	
5	5A	0.6188	70.18	65.54	67.09	0.3958	53.11	49.82	51.47
	5B	0.6402	72.08	70.52	71.41	0.4552	57.68	54.57	55.40
	5C	0.6575	73.61	69.17	73.81	0.5172	62.55	58.55	60.70



Gambar 3-3: Grafik Fluktuasi Hasil Akurasi Total dari Hasil Klasifikasi untuk Seluruh Skenario, Berbasis Obyek (Biru) dan Berbasis Piksel (Merah)



Gambar 3-4: Hasil Klasifikasi Skenario 5C, (Kiri) Berbasis Obyek dan (Kanan) Berbasis Piksel

Analisis lebih lanjut yakni untuk mengetahui pengaruh dari setiap skenario (lima skenario besar) terhadap hasil klasifikasi, dilakukan dengan mengacu perubahan tingkat akurasi (khususnya nilai koefisien Kappa dan nilai *overall accuracy*) dari setiap proses klasifikasi yang dikerjakan (Tabel 3-1 dan Gambar 3-3). Beberapa hasil analisis sebagai berikut:

- Pada skenario klasifikasi 1, tingkat akurasi hasil klasifikasi yang lebih baik didapatkan saat menggunakan *training sample* berbentuk *rectangle* dibandingkan berbentuk poligon segmentasi
- Terdapat kecenderungan kenaikan nilai koefisien Kappa dan nilai *overall accuracy* apabila terjadi penambahan jumlah *training sample*. Hal ini bisa

terlihat pada skenario klasifikasi 2. Penambahan jumlah *training sample* ini bisa membantu *classifier* SVM untuk mengenali kelas obyek lahan.

- Pada skenario klasifikasi 3 dimana terdapat variasi jumlah fitur, penggunaan fitur polarimetri (*Entropy*, *Alpha Angel*, dan *Anisotrophy*) dan fitur NDPI secara bersamaan dapat meningkatkan nilai koefisien Kappa dan nilai akurasi dibandingkan bila digunakan secara terpisah.
- Penambahan fitur tekstur dengan ukuran window 3x3 pada skenario klasifikasi 4 tidak signifikan mempengaruhi peningkatan tingkat akurasi. Fenomena ini terlihat dari nilai *overall accuracy* yang cenderung stabil (Gambar 3-3). Hal ini mungkin karena dalam percobaan ini telah digunakan fitur dekomposisi Freeman-Durden yang terdiri dari fitur *Double bounce* pada band *Red*, *Canopy layer* pada band *Green* dan *Rough Surface* pada band *Blue*, dimana ketiga band tersebut merepresentasikan tekstur dari permukaan bumi. Oleh karena itu penambahan fitur tekstur kurang mempengaruhi kenaikan tingkat akurasi. Perbesaran ukuran window fitur tekstur menjadi 7x7 dan 11x11 mempengaruhi klasifikasi berbasis piksel tetapi tetap kurang berpengaruh klasifikasi berbasis obyek. Hal ini diperkirakan karena penambahan ukuran window fitur tekstur akan memberi efek penghalusan citra (*smoothing*) yang berpengaruh pada klasifikasi berbasis piksel. Sedangkan pada klasifikasi berbasis obyek, hal ini kurang berpengaruh karena sudah ada proses segmentasi yang meratakan nilai piksel dalam satu region.
- Efek filter pada skenario klasifikasi 5 kurang berpengaruh pada peningkatan akurasi untuk klasifikasi berbasis obyek, tetapi berpengaruh pada klasifikasi berbasis piksel. Hal ini terlihat dari nilai *overall accuracy* yang

meningkat cukup tinggi. Hal ini karena filter merupakan juga proses homogenisasi piksel-piksel yang berdekatan. Efek ini serupa dengan proses segmentasi pada klasifikasi berbasis obyek. Pemberian filter dapat mengurangi efek *speckle noise* yang selanjutnya meningkatkan akurasi pemisahan obyek. Pada klasifikasi berbasis obyek proses pengurangan *speckle noise* ini sudah dilakukan pada tahapan segmentasi sehingga penggunaan filter kurang berpengaruh pada hasil klasifikasi berbasis obyek.

4 KESIMPULAN

Dari berbagai percobaan yang dilakukan dalam penelitian ini dapat diambil beberapa kesimpulan antara lain:

- Pemberian variasi filter kurang berpengaruh pada peningkatan akurasi hasil klasifikasi berbasis obyek, tapi berpengaruh cukup signifikan pada klasifikasi berbasis piksel. Hal ini karena pada proses klasifikasi berbasis obyek telah dilakukan proses segmentasi yang menyatukan piksel-piksel yang homogen sehingga pemberian-pemberian filter kurang berpengaruh. Pada klasifikasi berbasis piksel, filter akan mengurangi *speckle noise* yang meningkatkan homogenitas piksel, sehingga meningkatkan akurasi hasil klasifikasi.
- Tingkat akurasi klasifikasi berbasis obyek lebih baik dari pada klasifikasi berbasis piksel untuk seluruh skenario klasifikasi. Akurasi keseluruhan (*Overall accuracy*) mencapai 73,61% untuk hasil klasifikasi berbasis obyek dan 62,55% untuk klasifikasi berbasis piksel, dimana jumlah fitur yang optimal dalam percobaan klasifikasi data citra SAR dengan menggunakan SVM yaitu 7 fitur yang terdiri dari 3 fitur dekomposisi Freeman (R,G,B), Entropy, Alpha Angle, Anisotrophy dan NDPI.

DAFTAR RUJUKAN

- Arifin, S., 2007. *Identifikasi Penutup Lahan Menggunakan Data Polarimetrik Satelit ALOS Palsar*. Berita Inderaja.
- Cao, Y.G., Yan, L.J., & Zheng, Z.Z., 2008. *Extraction of Information on Geology Hazard From Multi-Polarization Sar Images*, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B4. Beijing, pp.1529-1532.
- Freeman, A. & Durden, S. L., 1998. *A Three-Component Scattering Model for Polarimetric SAR Data* *IEEE Trans. on GRS*, GRS-36(3), pp. 963-973.
- Han, Y., Shao, Y., 2010. *Full Polarimetric SAR Classification Based on Yamaguchi Decomposition Model and Scattering Parameters*, *IEEE Journal*, pages 1104-1108.
- Haralick, R.M., 1985. *Statistical and Structural Approaches to Texture*, Digital Image Processing and Analysis, Volume 2, IEEE Comp. Soc. Press, pp. 304-322.
- Kushardono, D., 2012. *Klasifikasi Spasial Penutup Lahan dengan Data SAR Dual-Polarisasi Menggunakan Normalized Difference Polarization Index dan Fitur Keruangan dari Matriks Kookurensi*, *Jurnal Penginderaan Jauh* Vol.9 No.1, pp.12-24.
- Lee, J.-S., Jurkevich, I., Dewaele, P., Wambacq, P., and A. Oosterlinck, 1994. *Speckle Filtering of Synthetic Aperture Radar Images: A Review*, *Remote Sensing Review*, 8:313-340.
- Li, H. T., Gu, H.Y., Han, Y. S., Yang, J. H., 2008. *Object-oriented Classification of Polarimetric SAR Imagery based on Statistical Region Merging and Support Vector Machine*, International Workshop on Earth Observation and Remote Sensing Applications.
- Lillesand, T.M., & Kiefer, R.W., 1979. *Remote Sensing and Image Interpretation*, John Willey & Sons, New York.
- Lopes, A., Touzi, R., & Nezry, E., 1990. *Adaptive Speckle Filters and Scene Heterogeneity*. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 28, No. 6, pp. 992-1000.
- Nock, R., & Nielsen, F., 2004. *Statistical Region Merging*. *IEEE transactions on pattern analysis and machine intelligence*. Vol. 26, pp. 1452-1458.
- Raimadoya, M.A., Trisasongko, B.H., & Nurwadjedi, 2007. *Eksplorasi Citra Radar untuk Intelijen Ketahanan Pangan*, Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, Institut Pertanian Bogor.
- Sambodo, K. A., Teguh, K., & Santoso, H., 2005. *Klasifikasi Data Polarimetrik RADAR dengan Menggunakan Metode Dekomposisi Cloude & Pottier*, *Pertemuan Ilmiah MAPIN XIV*, hal 79-84, Surabaya, Indonesia.
- Sembiring, K., 2007. *Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan*, skripsi sarjana, Jurusan Teknik Informatika, Sekolah Teknik Elektro dan Informatika, Institut Teknologi Bandung, 2007.
- Suwono, E., 2009. *Aplikasi Deteksi Obyek Pada Citra Digital Dengan Metode Global Contour Shape*, skripsi sarjana, Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.
- Sylvain Boltz, 2009. (<http://www.mathworks.com/matlabcentral/fileexchange/25619-image-segmentation-using-statistical-region-merging>).
- Vapnik, V. N., 1999. *The Nature of Statistical Learning Theory*, 2nd edition, Springer-Verlag, New York Berlin Heidelberg.