

OPTIMASI PARAMETER DALAM KLASIFIKASI SPASIAL PENUTUP PENGGUNAAN LAHAN MENGGUNAKAN DATA SENTINEL SAR (PARAMETERS OPTIMIZATION IN SPATIAL LAND USE LAND COVER CLASSIFICATION USING SENTINEL SAR DATA)

Galdita Aruba Chulafak¹, Dony Kushardono, Zylshal

Pusat Pemanfaatan Penginderaan Jauh

Lembaga Penerbangan dan Antariksa Nasional

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

¹e-mail: galdita.aruba@lapan.go.id

Diterima 30 Agustus 2017; Direvisi 12 Desember 2017; Disetujui 13 Desember 2017

ABSTRACT

In this study, application of Sentinel-1 Synthetic Aperture Radar (SAR) data for the land use cover classification was investigated. The classification was implemented with supervised Neural Network classifier for *Dual polarization* (VH and VV) Sentinel-1 data using texture information of gray level co-occurrence matrix (GLCM). The purpose of this study was to obtain the optimum parameters in the extraction of texture information of pixel window size, the orientation of neighboring relationships on the texture feature extraction, and the type of texture information feature used for the classification. The classification results showed that in the study area, the best accuracy obtained is 5 × 5 pixel window size, 0° orientation angle, and the use of entropy texture information as classification input. It was also found that more features texture information used as classification input can improve the accuracy, and with careful selection of appropriate texture information as classification input will give the best accuracy.

Keywords: SAR, *Sentinel-1*, GLCM

ABSTRAK

Pada penelitian ini dilakukan kajian mengenai klasifikasi penutup penggunaan lahan menggunakan data Sentinel-1 yang merupakan data *Synthetic Aperture Radar* (SAR). Informasi tekstur digunakan sebagai masukan dalam pembuatan klasifikasi terbimbing *Neural Network* dengan menggunakan *Dual polarization* (VH dan VV). Klasifikasi dilakukan menggunakan informasi tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM) dari data Sentinel-1. Tujuan penelitian ini adalah mendapatkan parameter optimum dalam ekstraksi informasi, yaitu ukuran jendela pemrosesan, orientasi hubungan ketetanggaan pada ekstraksi fitur tekstur, serta jenis fitur informasi tekstur yang digunakan dalam klasifikasi. Hasil klasifikasi menunjukkan bahwa pada area yang dikaji, akurasi terbaik adalah pada ukuran jendela 5×5 piksel, sudut orientasi hubungan ketetanggaan 0° , serta penggunaan informasi tekstur *entropy* sebagai masukan dalam klasifikasi. Serta diketahui bahwa semakin banyak fitur informasi tekstur yang digunakan sebagai masukan klasifikasi dapat meningkatkan akurasi dan pemilihan informasi tekstur yang tepat sebagai masukan klasifikasi akan menghasilkan akurasi terbaik.

Kata kunci: SAR, *Sentinel-1*, GLCM

1 PENDAHULUAN

Pemantauan penutup penggunaan lahan di Indonesia perlu dilakukan. Pemantauan ini bisa dilakukan dengan cara melakukan pemantauan langsung maupun tidak langsung. Namun, pemantauan secara langsung dapat memakan biaya yang tinggi dan waktu yang lama sehingga dapat dilakukan pemantauan penutup penggunaan lahan menggunakan data penginderaan jauh (Martono, 2008; Suwargana, 2008).

Indonesia terletak di wilayah tropis, sehingga mempunyai liputan awan yang tinggi (Panuju, *et al.*, 2009). Liputan awan yang cukup tinggi ini dapat menyulitkan pemantauan di Indonesia terutama dalam penggunaan penginderaan jauh optik (Hasyim, *et al.*, 2010; Tjahjono, *et al.*, 2009), sehingga dalam mengatasi permasalahan ini dapat menggunakan penginderaan jauh *Synthetic Aperture Radar* (SAR) (Kushardono, 1996; Kushardono, 2012; Suwarsono, *et al.*, 2013) dikarenakan mempunyai panjang gelombang yang lebih panjang daripada partikel awan (Sutanto, *et al.*, 2014). Selain dapat menembus awan, SAR juga tidak terpengaruh oleh kondisi atmosfer, cuaca, maupun waktu pengambilan

data baik itu siang ataupun malam hari (Prahasta, 2009; Hutagalung, 2013).

Pada tahun 2014 telah diluncurkan Satelit Sentinel-1A dengan pengindera radar (Geudner, *et al.*, 2014) dan pada tahun 2016, sebagai bagian dari konstelasi satelit Sentinel-1, Satelit Sentinel-1B diluncurkan (Miranda, *et al.*, 2016). Satelit Sentinel-1 merupakan Satelit yang membawa muatan SAR pada kanal C (Xiaofeng, 2015) dan mempunyai mode pengambilan *single polarization* ataupun *dual polarization* (Torres, *et al.*, 2012). Satelit lain pembawa pengindera SAR kanal C yaitu RADARSAT-2 dan Envisat-ASAR (Mouche dan Chapron, 2015).

Klasifikasi penutup penggunaan lahan menggunakan data satelit penginderaan jauh sudah banyak dilakukan, misalnya klasifikasi pada data SPOT di wilayah perbatasan perkotaan yang menggunakan metode *spatial feature* (Gong, *et al.*, 1992), klasifikasi penutup lahan pada data EO-1 hiperspektral menggunakan *neural network* (Kushardono, 2016), klasifikasi pada Wordview-1 dan Quickbird menggunakan pendekatan *neural network* di wilayah pemukiman (Pacifici *et al.*, 2009), klasifikasi menggunakan data ALOS PALSAR dan Envisat ASAR pada penggunaan lahan di Kabupaten Siak,

Riau (Kushardono, 2012), dan klasifikasi pada data TerraSAR-X untuk mengelaskan lahan pertanian (Sonobe *et al.*, 2014).

Dengan semakin meningkatnya resolusi spasial pada citra penginderaan jauh, analisis tekstur semakin mempunyai peranan penting dalam pengolahan citra, klasifikasi citra, dan interpretasi citra penginderaan jauh (He dan Wang, 1990). Banyak kajian yang menyatakan bahwa klasifikasi berdasarkan fitur tekstur dapat meningkatkan akurasi (Ulaby, *et al.*, 1986; Kushardono, *et al.*, 1994; Simard, *et al.*, 2000; Dekker, 2003).

Analisis tekstur yang digunakan dalam kajian ini adalah menggunakan *Gray Level Co-occurrence Matrix* (GLCM). Pemilihan GLCM ini dikarenakan metode ini mengungguli metode lain dalam membedakan tekstur (Weszka, *et al.*, 1976; Conners dan Harlow, 1980). GLCM juga telah berhasil digunakan dalam banyak aplikasi (Haralick, *et al.*, 1973; Kruger, *et al.*, 1974; Soh dan Tsatsoulis, 1996; Kushwaha, *et al.*, 1994; Wu, *et al.*, 2008) dan juga pada klasifikasi data SAR (Shanmugan, *et al.*, 1981; Barber, dan LeDrew, 1991; Kushardono, 1996). Terdapat berbagai macam jenis fitur tekstur seperti *Angular Second Moment* (ASM), *Inverse Difference Moment*, *Correlation*, dan *Entropi* (Mohanaiah, *et al.*, 2013).

Pada penelitian ini dikaji mengenai penggunaan fitur tekstur dalam klasifikasi dengan berbagai parameter seperti ukuran jendela piksel, orientasi ketetanggaan, dan jenis dari fitur tekstur yang digunakan pada data Sentinel-1, sehingga diperoleh parameter yang optimal.

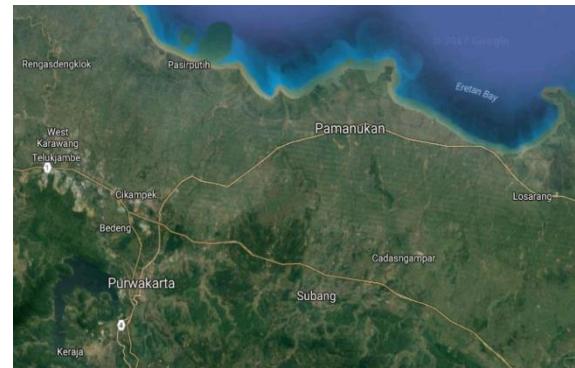
2 METODOLOGI

2.1 Lokasi dan Data

Lokasi kajian berada pada wilayah Kabupaten Karawang, Subang, dan Indramayu, Provinsi Jawa Barat yang termasuk daerah penghasil padi terbesar di Indonesia seperti terlihat

pada Gambar 2-1. Data yang digunakan adalah data Sentinel-1A yang merupakan data penginderaan jauh SAR dengan waktu perekaman tanggal 10 September 2016 05: UTC.

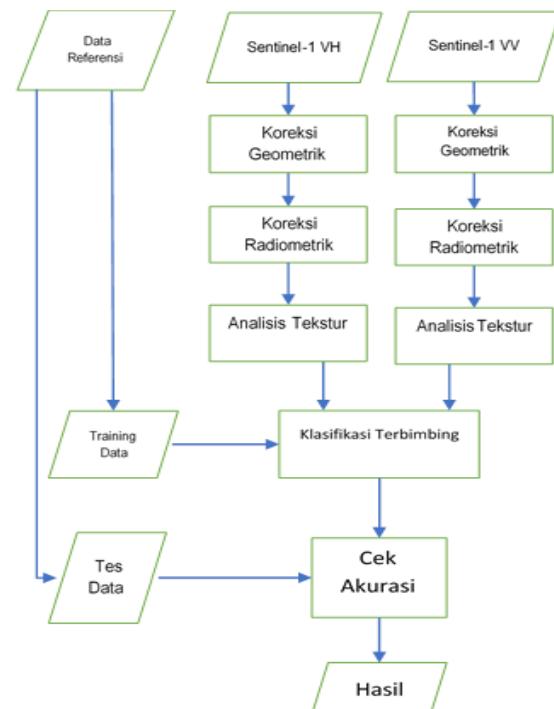
Data Sentinel-1A yang digunakan merupakan data *dual polarization* VH dan VV yang mempunyai resolusi spasial 5x10 m.



Gambar 2-1: Area kajian yang dilakukan

2.2 Metode Penelitian

Metode yang dilakukan dalam kajian ini seperti terlihat pada Gambar 2-2.



Gambar 2-2: Diagram alir kajian klasifikasi data Sentinel-1

Data Sentinel-1 yang digunakan berada pada level-1 *Ground Range Detected* (GRD). Level GRD ini sudah

terkoreksi *terrain* dan sudah ditransformasi ke dalam bentuk koordinat geografik (Twelve, et al., 2016) namun masih perlu dilakukan reprojeksi citra sehingga citra mempunyai posisi yang benar. *Preprocessing* data Sentinel-1 dilakukan di lingkungan perangkat lunak ESA SNAP Toolbox (ESA, 2017).

Data yang diperoleh pada data satelit Sentinel-1 berupa data amplitudo dan intensitas dalam bentuk angka digital. Dari data tersebut dilakukan kalibrasi sehingga didapatkan nilai hamburan balik dalam *sigma naught* (σ^0) dengan menggunakan persamaan berikut (Cazals, et al., 2016; Miranda dan Meadows, 2015):

$$\sigma^0[dB] = 10 * \log_{10}\left(\frac{DN^2}{A_{dn}^2 K} \sin(\alpha)\right) \quad (2-1)$$

Keterangan:

σ^0 = Koefisien hamburan balik (dB)

K = Koefisien kalibrasi

DN = *Digital Number*

α = *Incidence Angle*

A = Amplitudo

Dari hasil tersebut kemudian dilakukan ekstraksi informasi keruangan berdasarkan GLCM. Di mana GLCM untuk tiap polarisasi data dihitung berdasarkan jendela piksel (*window*) ukuran $n \times n$ piksel dengan suatu hubungan ketetanggaan sudut orientasi yang bergerak tiap piksel pada citra. Ukuran tersebut tidak dibatasi dalam ukuran tertentu namun ukuran *window* akan membedakan optimalisasi penggunaannya. Nilai *displacement* yang digunakan adalah sebesar satu piksel. Menurut Barber dan LeDrew, 1991, nilai *displacement* 1 menghasilkan hasil yang lebih baik dibandingkan nilai lain.

Ukuran matriks yang dihasilkan adalah sebesar jumlah tingkat keabuan di dalam *window* tersebut dikali jumlah tingkat keabuan. Agar prosesnya tidak memakan waktu yang lama dan terlalu

ber variasi, maka dilakukan kuantisasi tingkat keabuan. Kuantisasi yang digunakan adalah sebesar 64 tingkat keabuan. Penggunaan kuantisasi ini akan mempengaruhi hasil klasifikasi, semakin kecil maka semakin banyak informasi yang hilang, namun semakin banyak kuantisasi juga tidak akan menghasilkan hasil yang optimal karena waktu proses yang lama (Kushardono, 1996; Wen, et al., 2009).

Nilai pada tiap elemen matriks kookurensi adalah $P(i,j)$ di mana nilai tersebut merupakan peluang kejadian nilai digital i bertemu dengan nilai digital j. Dari nilai peluang tersebut dapat dihasilkan delapan fitur tekstur yang diformulasikan oleh Haralick, 1985 sebagai berikut:

- *Angular second moment:*

$$\sum_{i,j} \{P(i,j)\}^2 \quad (2-2)$$

- *Contrast :*

$$\sum_{i,j} (i-j)^2 P(i,j) \quad (2-3)$$

- *Homogeneity :*

$$\sum_{i,j} (i-j)^2 P(i,j) \quad (2-4)$$

- *Entropy:*

$$-\sum_{i,j} P(i,j) \log P(i,j) \quad (2-5)$$

- *Dissimilarity:*

$$\sum_{i,j} P(i,j) |i - j| \quad (2-6)$$

- *Correlation:*

$$\sum_{i,j} [(ij) P(i,j) - \mu_x \mu_y] / \sigma_x \sigma_y \quad (2-7)$$

- *Mean:*

$$\sum_{i,j} i \cdot P(i,j) \quad (2-8)$$

- *Variance:*

$$\sum_{i,j} P(i,j)(i - \mu_i)^2 \quad (2-9)$$

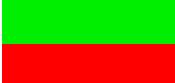
Keterangan:

μ_x, μ_y = rataan

σ_x, σ_y = standar deviasi

Setelah didapatkan kedelapan informasi tersebut, kemudian dilakukan klasifikasi terbimbing *Neural Network*

Tabel 2-1: KATEGORI KELAS PENUTUP PENGGUNAAN LAHAN

No	Kategori Kelas	Kode Warna	Jumlah Training Data (pixel)	Jumlah Tes Data (pixel)
1	Perairan		1063	16597
2	Sawah Bera		2532	17600
3	Sawah Vegetasi 1		2828	22711
4	Sawah Vegetasi 2		2750	24738
5	Kebun Campuran		3470	18223
6	Pemukiman		4420	13726
7	Kosong		1332	6284

perulangan maksimal 10,000 perulangan dan *RMS error* kurang dari 0.1. Training data yang dipergunakan adalah berupa poligon yang merupakan hasil interpretasi dengan bantuan data referensi dan jumlah pixel perpoligon tiap kelassnya sebagaimana pada Tabel 2-1. Uji akurasi hasil klasifikasi yang diperoleh dilakukan dengan menggunakan data referensi yang diperoleh dari hasil interpretasi visual citra resolusi tinggi. Sampel data uji akurasi yang digunakan adalah sampel poligon yang mewakili tiap kelas penutup lahan hasil klasifikasi yang diperoleh sebelumnya. Akurasi kemudian dihitung dengan menggunakan metode *confusion matrix* (Congalton dan Green, 2008). Dari *confusion matrix* tersebut dapat dilakukan analisis lebih lanjut. Tahap klasifikasi dan uji akurasi dilakukan di lingkungan perangkat lunak IDL ENVI.

dengan menggunakan kelas dari *training* data dengan kategori terlihat pada Tabel 2-1. Pembelajaran dengan klasifikasi *Neural Network* dilakukan dengan

3 HASIL PEMBAHASAN

Dalam klasifikasi yang dilakukan dibedakan dalam beberapa perlakuan, yaitu berdasarkan ukuran jendela piksel, orientasi ketetanggan, serta informasi tekstur yang digunakan.

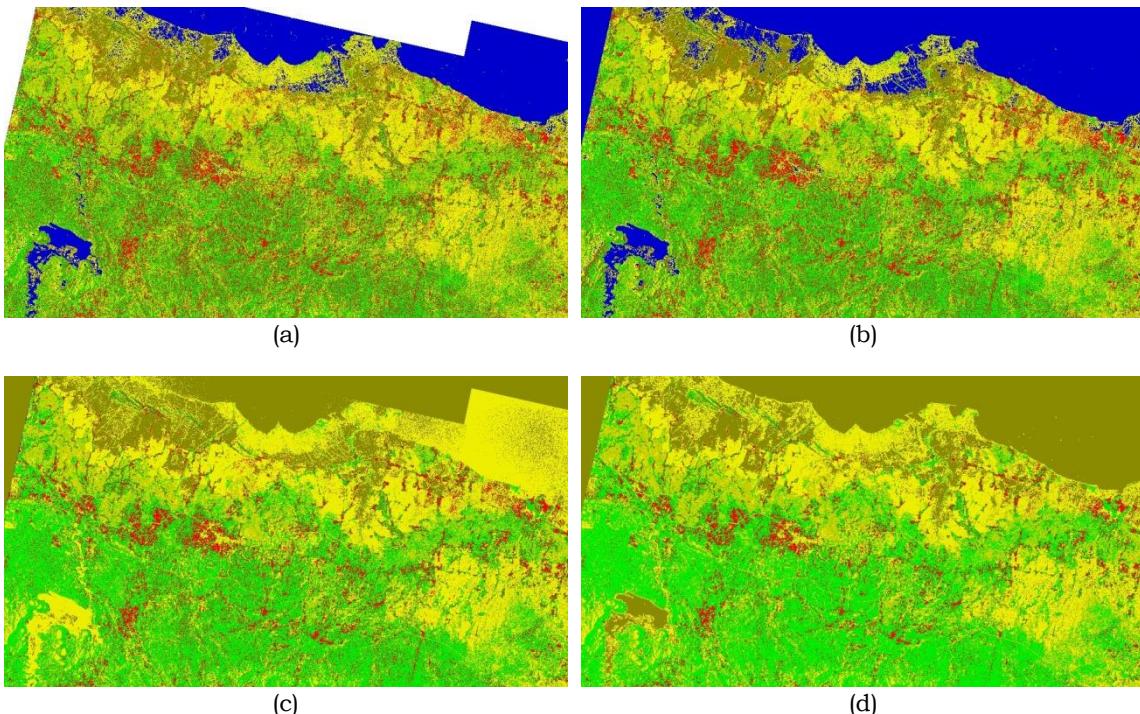
Pada perlakuan berdasarkan ukuran jendela pemrosesan informasi tekstur, digunakan ukuran jendela 5x5, 7x7, 9x9, dan 11x11 piksel dengan menggunakan kuantisasi 64 tingkat, serta orientasi semua arah dan menggunakan delapan fitur tekstur sebagai masukannya. Hasil klasifikasi berdasarkan ukuran jendela tersebut dapat dilihat pada Gambar 3-1.

Secara visual terlihat bahwa penggunaan ukuran jendela 5x5 dalam klasifikasi menghasilkan klasifikasi terbaik dikarenakan masih terdapatnya kelas perairan dan kelas data kosong.

Hasil akurasi penggunaan keempat ukuran jendela tersebut dapat dilihat pada Tabel 3-1 dalam bentuk

confusion matrix. Hasil akurasi tertinggi diperoleh pada jendela berukuran 5x5

kemudian 7x7, 11x11, dan yang terakhir 9x9.



Gambar 3-1. Hasil klasifikasi menggunakan ukuran *window* (a) 5x5, (b) 7x7, (c) 9x9, dan (d) 11x11

Tabel 3-1: CONFUSION MATRIX PADA BERBAGAI UKURAN WINDOW (%)

UKURAN WINDOW 5x5									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	99.96	0	0.07	0.01	0	0	0	0	13.85
Sawah bera	0	89.05	0.49	0	0	0.01	0	0	13.17
Sawah Veg 1	0	6.8	49.93	10.47	0.07	0.09	0	0	12.64
Sawah Veg 2	0	0.66	40.74	66.06	7.33	1.41	0	0	22.72
Kebun Campur	0	0.01	8.12	20.36	69.01	6.56	0	0	16.98
Pemukiman	0	3.48	0.66	3.1	23.6	91.93	0	0	15.39
Kosong	0.04	0	0	0	0	0	100	0	5.25
Total	100	100	100	100	100	100	100	100	100

Overall Accuracy = 76.2611%

Kappa Coefficient = 0.7189

UKURAN WINDOW 7x7									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	100	0.19	0.05	0	0	0	100	0	19.12
Sawah bera	0	95.08	0.19	0	0	0	0	0	14
Sawah Veg 1	0	2.73	56.35	9.63	0	0.01	0	0	13.06
Sawah Veg 2	0	0.01	36.4	69.78	3.98	1.04	0	0	22.02
Kebun Campur	0	0	6.76	18.88	80.05	4.2	0	0	17.83
Pemukiman	0	1.99	0.25	1.71	15.97	94.75	0	0	13.97
Kosong	0	0	0	0	0	0	0	0	0
Total	100	100	100	100	100	100	100	100	100

Overall Accuracy = 75.8974%

Kappa Coefficient = 0.7130

UKURAN WINDOW 9X9									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun	Campur	Pemukiman	Kosong	Total
Perairan	0	0	0.22	0.09	0.31	0	0	0	0.11
Sawah bera	41.12	96.89	0.01	0	0	0	0	100	25.16
Sawah Veg 1	58.88	2.06	58.27	9.45	0	0.03	0	0	21.45
Sawah Veg 2	0	0	35.19	69.63	1.9	0.44	0	0	21.37
Kebun Campur	0	0	6.24	20.29	90.36	4.41	0	0	19.61
Pemukiman	0	1.05	0.07	0.55	7.43	95.13	0	0	12.3
Kosong	0	0	0	0	0	0	0	0	0
Total	100	100	100	100	100	100	100	100	100

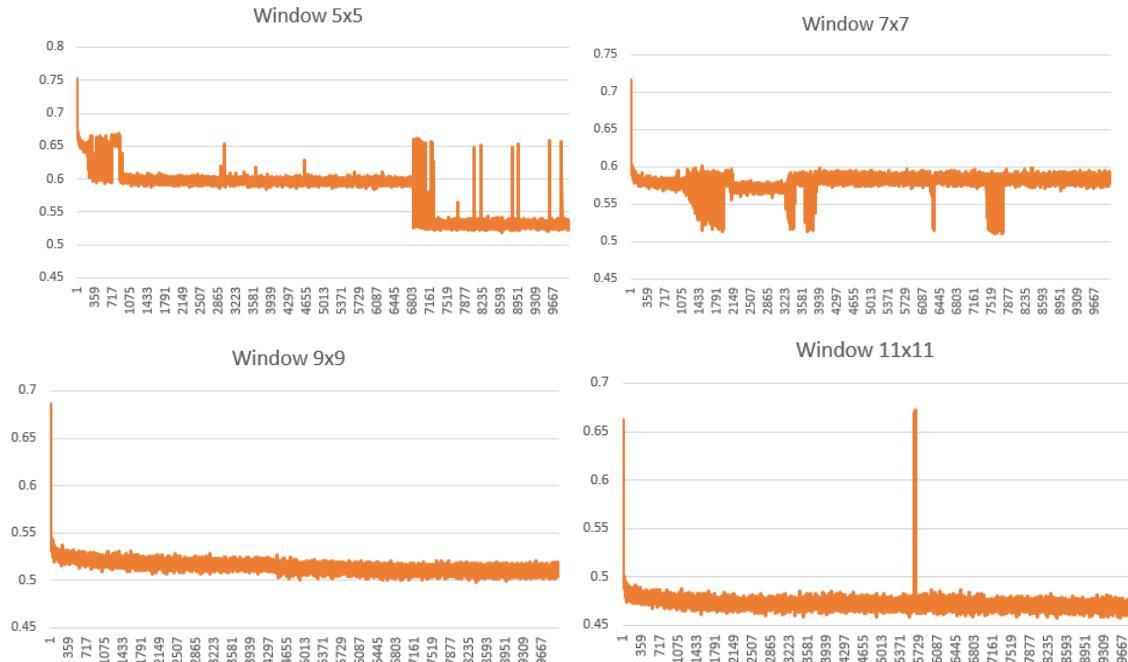
Overall Accuracy = 64.2598%

Kappa Coefficient = 0.5716

UKURAN WINDOW 11X11									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun	Campur	Pemukiman	Kosong	Total
Perairan	0	0	0	0	0	0	0	0	0
Sawah bera	100	99.55	0.01	0	0	0	0.36	100	33.75
Sawah Veg 1	0	0.45	58.18	6.04	0	0	0.01	0	12.34
Sawah Veg 2	0	0	37.96	77.96	2.84	0	0.62	0	23.78
Kebun Campur	0	0	3.85	15.97	95.35	5.41	0	0	19.14
Pemukiman	0	0	0	0.03	1.81	93.59	0	0	11
Kosong	0	0	0	0	0	0	0	0	0
Total	100	100	100	100	100	100	100	100	100

Overall Accuracy = 66.9342%

Kappa Coefficient = 0.6046



Gambar 3-2: Grafik penurunan RMS error (sumbu Y) berbagai ukuran window pada setiap jumlah iterasi (sumbu X)

Hasil akurasi ini berbeda dengan kajian yang dilakukan oleh Kushardono, 2012, yang menggunakan metode klasifikasi Maksimum *Likelihood* pada data Envisat ASAR, di mana ukuran *window* yang paling optimal adalah menggunakan ukuran 7 x 7 piksel. Hal ini dikarenakan perbedaan ukuran obyek penutup lahan di wilayah Jawa tempat studi yang lebih sempit dibanding penutup lahan hutan di Riau.

Su, 2008, juga mengkaji akurasi berdasarkan ukuran *window* ini pada penggunaan beberapa fitur tekstur dan hasil akurasi terbaik tidak selalu berada pada ukuran *window* tertentu, seperti ukuran 11x11 menghasilkan akurasi tertinggi pada fitur *homogeneity* dan *entropy*, 9x9 pada fitur *angular second moment*, dan 7x7 pada penggunaan fitur *contrast*.

Apabila dilihat berdasarkan *RMS error* yang didapatkan ketika melakukan klasifikasi *neural network* maka akan terlihat seperti Gambar 3-2. Terlihat jika *error* yang didapat tidak berkorelasi dengan akurasi yang didapat. Ukuran *window* dengan *error* terendah dihasilkan pada ukuran 11x11 sebesar 0.42, namun hasil akurasi menunjukkan bahwa pada ukuran *window* ini hanya menempati akurasi tertinggi ketiga di bawah ukuran *window* 5x5 dan 7x7.

Berdasarkan penelitian yang dilakukan oleh Clausi dan Jernigam, 1998, jika ukuran *window* terlalu besar, maka akan terjadi banyak kekaburuan pada perbatasan antar kelas, sedangkan pada *window* dengan ukuran lebih kecil akan menghasilkan *error* yang lebih banyak namun menghasilkan akurasi yang lebih tinggi pada wilayah perbatasan.

Kayitakire, 2006 mengatakan bahwa ukuran *window* merupakan parameter kunci dalam tekstur analisis, pemilihannya tidak dapat dilakukan secara langsung. Pemilihan ukuran *window* ini dapat dilakukan dengan *trial*

dan *error*, di mana beberapa nilai diuji (Franklin, et al., 2001; Pesaresi, 2000). Hal ini menandakan jika ukuran *window* paling optimal akan berbeda untuk kasus yang berbeda sekalipun diterapkan pada data Sentinel-1.

Pada Tabel 3-2 disajikan mengenai perbandingan akurasi *producer* dan *user*. Terlihat pada kelas kosong baik pada akurasi *producer* maupun akurasi *user* menghasilkan nilai 0 pada ukuran *window* selain 5x5. Sedangkan pada kelas perairan nilai 0 muncul pada ukuran *window* 9x9 dan 11x11 baik itu pada akurasi *producer* maupun akurasi *user*.

Perlakuan kedua dilakukan berdasarkan pada orientasi hubungan ketetanggaan dari matriks kookurensi. Orientasi ini dibedakan pada semua arah, orientasi 0°, 45°, 90°, dan orientasi 135°. Hasil klasifikasi berdasarkan orientasi ini seperti terlihat pada Gambar 3-3 dan Gambar 3-1(a) untuk orientasi semua arah.

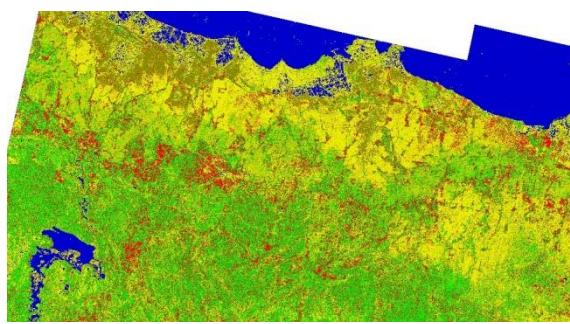
Secara visual tidak terlalu banyak terlihat perbedaan antara klasifikasi berdasarkan orientasi ini kecuali pada orientasi 90° di mana kelas kosong terkelaskan menjadi kelas perairan.

Hasil akurasi berdasarkan arah orientasi ini seperti terlihat pada Tabel 3-3. Akurasi tertinggi didapat pada klasifikasi dengan orientasi 0° sebesar 76.9% dan diikuti sudut orientasi semua arah sebesar 76.2%, 45° sebesar 76.0%, 90° sebesar 69.6%, dan 135° sebesar 66.9%.

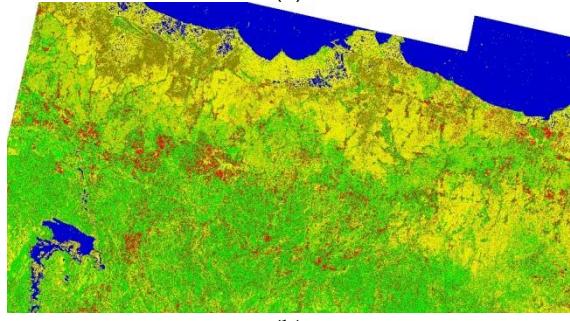
Berdasarkan kajian yang dilakukan oleh Su (2008), hasil akurasi berdasarkan sudut orientasi ini juga akan menghasilkan akurasi yang berbeda untuk tiap-tiap penggunaan fitur tekstur yang berbeda serta orientasi dari tekstur dapat meningkatkan nilai akurasi klasifikasi tergantung pola dari area kajian.

Tabel 3-2: PERBANDINGAN PRODUSER AKURASI DAN USER AKURASI BERDASARKAN UKURAN WINDOW (%)

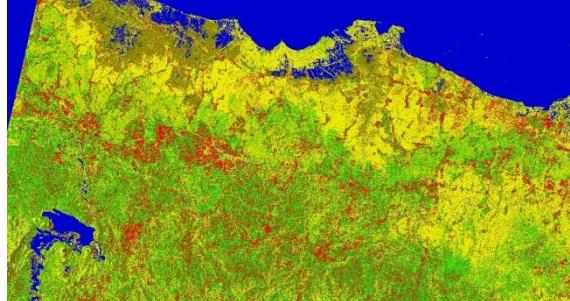
Kelas	Producer's Accuracy				User's Accuracy			
	5x5	7x7	9x9	11x11	5x5	7x7	9x9	11x11
Perairan	99.96	100	0	0	99.89	72.4	0	0
Sawah bera	89.05	95.08	96.89	99.55	99.28	99.74	56.53	43.31
Sawah Veg 1	49.93	56.35	58.27	58.18	74.83	81.71	51.47	89.34
Sawah Veg 2	66.06	69.78	69.63	77.96	59.99	65.39	67.23	67.65
Kebun Campur	69.01	80.05	90.36	95.35	61.78	68.26	70.05	75.73
Pemukiman	91.93	94.75	95.13	93.59	68.4	77.67	88.55	97.44
Kosong	100	0	0	0	99.9	0	0	0



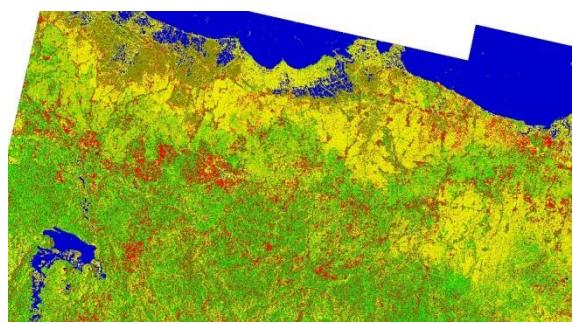
(a)



(b)

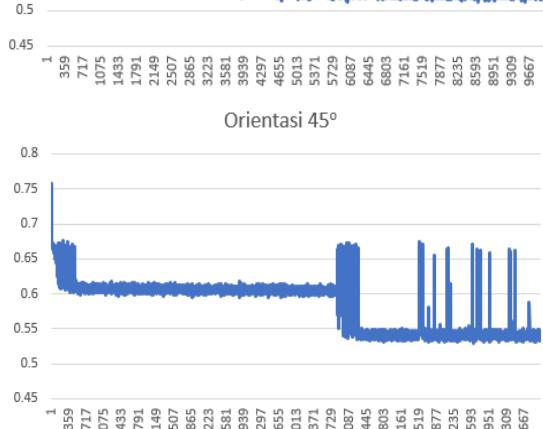
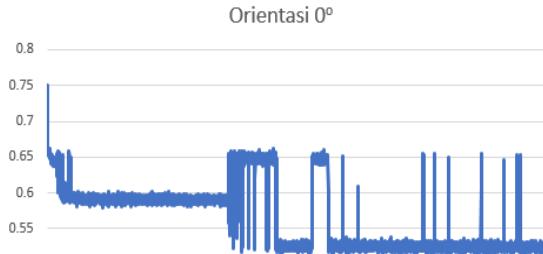


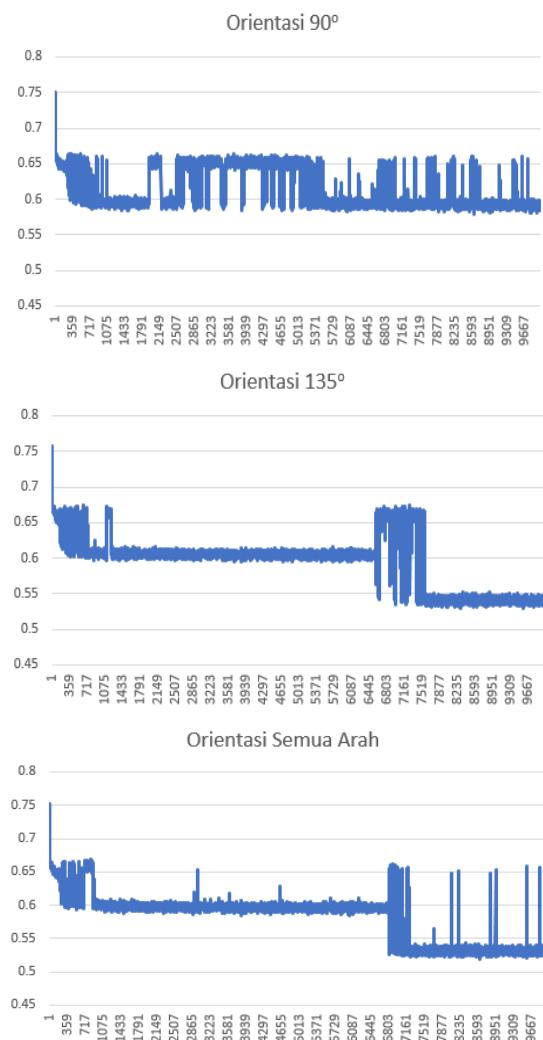
(c)



(d)

Gambar 3-3: Hasil klasifikasi menggunakan orientasi (a) 0°, (b) 45°, (c) 90°, dan (d) 135°





Gambar 3-4: Grafik penurunan *RMS error* (sumbu Y) berbagai orientasi *window* pada setiap jumlah iterasi (sumbu X)

Pola pada area kajian yang dilakukan termasuk mempunyai pola yang cukup heterogen dengan arah orientasi yang berbeda-beda seperti pada wilayah pertambakan, pertanian, perumahan, dan wilayah pegunungan, sehingga bisa terlihat jika beberapa orientasi yang digunakan mempunyai tingkat akurasi yang tidak jauh berbeda, dengan selisih kurang dari 1% dikarenakan kondisi pada area kajian yang mempunyai arah pola yang bervariasi.

Grafik *RMS error* yang didapatkan dapat dilihat pada Gambar 3-4, di mana terlihat *RMS error* untuk orientasi sudut 0°, 45°, 135°, dan semua arah mempunyai nilai *RMS Error* yang tidak jauh berbeda berada pada kisaran nilai 0,52 hingga 0,53, sedangkan *RMS Error* pada orientasi 90° adalah sebesar 0,59. Sama seperti halnya pada perbandingan dengan ukuran *window*, *RMS error* dan akurasi tidak mempunyai korelasi.

Tabel perbandingan berbagai jenis orientasi ketetapan terhadap hasil akurasi *producer* dan akurasi *user* disajikan pada Tabel 3-4. Pada kelas perairan, akurasi *producer* pada tiap orientasi menghasilkan nilai akurasi yang tinggi, > 99%, begitu pula pada akurasi *user* kecuali pada orientasi 90° yang hanya mempunyai akurasi sebesar 72,2%. Nilai produser akurasi dan akurasi *user* yang tinggi juga dihasilkan pada kelas sawah bera dan kelas kosong, namun pada kelas kosong, pada orientasi 90° menghasilkan akurasi 0%. Jika dilihat pada Gambar 3-3(c), lokasi yang seharusnya terkласifikasi sebagai kelas kosong dikelaskan sebagai kelas perairan.

Hasil akurasi ini juga sesuai dengan penuturan Kushardono, 1996 dan Wen, *et al.*, 2009 yang mengatakan jika akurasi klasifikasi yang didapat lebih baik ketika orientasi GLCM paralel dengan arah penglihatan dari sensor di mana pada satelit Sentinel-1 juga mengambil pada sudut orientasi yang lebih mendekati sudut 0° lebih baik ketika orientasi GLCM paralel dengan arah penglihatan dari sensor di mana pada satelit Sentinel-1 juga mengambil pada sudut orientasi yang lebih mendekati sudut 0°.

Tabel 3-3: CONFUSION MATRIX PADA BERBAGAI ARAH ORIENTASI (%)

Kelas	ORIENTASI 0°								Total
	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong		
Perairan	99.95	0	0.18	0.03	0	0	0	13.88	

Sawah bera	0	89.99	0.37	0.01	0	0.02	0	13.29
Sawah Veg 1	0	6.7	50.46	10.6	0.07	0.03	0	12.75
Sawah Veg 2	0	0.67	40.35	66.93	9.62	1.89	0	23.24
Kebun Campur	0	0.02	7.92	19.29	71.9	7.23	0	17.24
Pemukiman	0	2.61	0.71	3.13	18.42	90.83	0	14.36
Kosong	0.05	0	0	0	0	0	100	5.25
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 76.9943%

Kappa Coefficient = 0.7273

ORIENTASI 45°									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	99.04	0	0	0	0	0	0	13.71	
Sawah bera	0	89.84	0.64	0.02	0	0.13	0	13.33	
Sawah Veg 1	0.9	7.78	46.03	8.81	0.13	0.04	0	11.83	
Sawah Veg 2	0	0.89	43.62	64.49	7.51	1.74	0	23.04	
Kebun Campur	0	0.04	9.25	24.49	78.14	10.86	0	19.93	
Pemukiman	0	1.45	0.46	2.18	14.23	87.23	0	12.9	
Kosong	0.05	0	0	0	0	0	100	5.25	
Total	100	100	100	100	100	100	100	100	

Overall Accuracy = 76.0375%

Kappa Coefficient = 0.7160

ORIENTASI 90°									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	100	0.43	0.02	0	0.12	0	100	19.17	
Sawah bera	0	90.09	0.44	0.01	0	0.01	0	13.31	
Sawah Veg 1	0	6.29	52.75	13.47	0.14	0.15	0	13.74	
Sawah Veg 2	0	0.22	37.8	61.21	8.2	1.28	0	21.22	
Kebun Campur	0	0	8.13	21.75	60.77	5.34	0	15.88	
Pemukiman	0	2.97	0.85	3.57	30.77	93.22	0	16.68	
Kosong	0	0	0	0	0	0	0	0	
Total	100	100	100	100	100	100	100	100	

Overall Accuracy = 69.6069%

Kappa Coefficient = 0.6385

ORIENTASI 135°									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	99.98	0.07	0	0	0	0	0	13.85	
Sawah bera	0	82.9	0.24	0	0	0.01	0	12.22	
Sawah Veg 1	0	10.37	46.86	8.69	0.09	0.07	0	12.22	
Sawah Veg 2	0	0.46	42.74	64.7	7.11	1.39	0	22.76	
Kebun Campur	0	0	9.01	22.1	68.1	6.25	0	17.33	
Pemukiman	0	6.2	1.14	4.51	24.71	92.27	0	16.38	
Kosong	0.02	0	0	0	0	0	100	5.24	
Total	100	100	100	100	100	100	100	100	

Overall Accuracy = 66.9342%

Kappa Coefficient = 0.6046

ORIENTASI SEMUA ARAH									
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	99.96	0	0.07	0.01	0	0	0	13.85	
Sawah bera	0	89.05	0.49	0	0	0.01	0	13.17	
Sawah Veg 1	0	6.8	49.93	10.47	0.07	0.09	0	12.64	
Sawah Veg 2	0	0.66	40.74	66.06	7.33	1.41	0	22.72	
Kebun Campur	0	0.01	8.12	20.36	69.01	6.56	0	16.98	
Pemukiman	0	3.48	0.66	3.1	23.6	91.93	0	15.39	
Kosong	0.04	0	0	0	0	0	100	5.25	
Total	100	100	100	100	100	100	100	100	

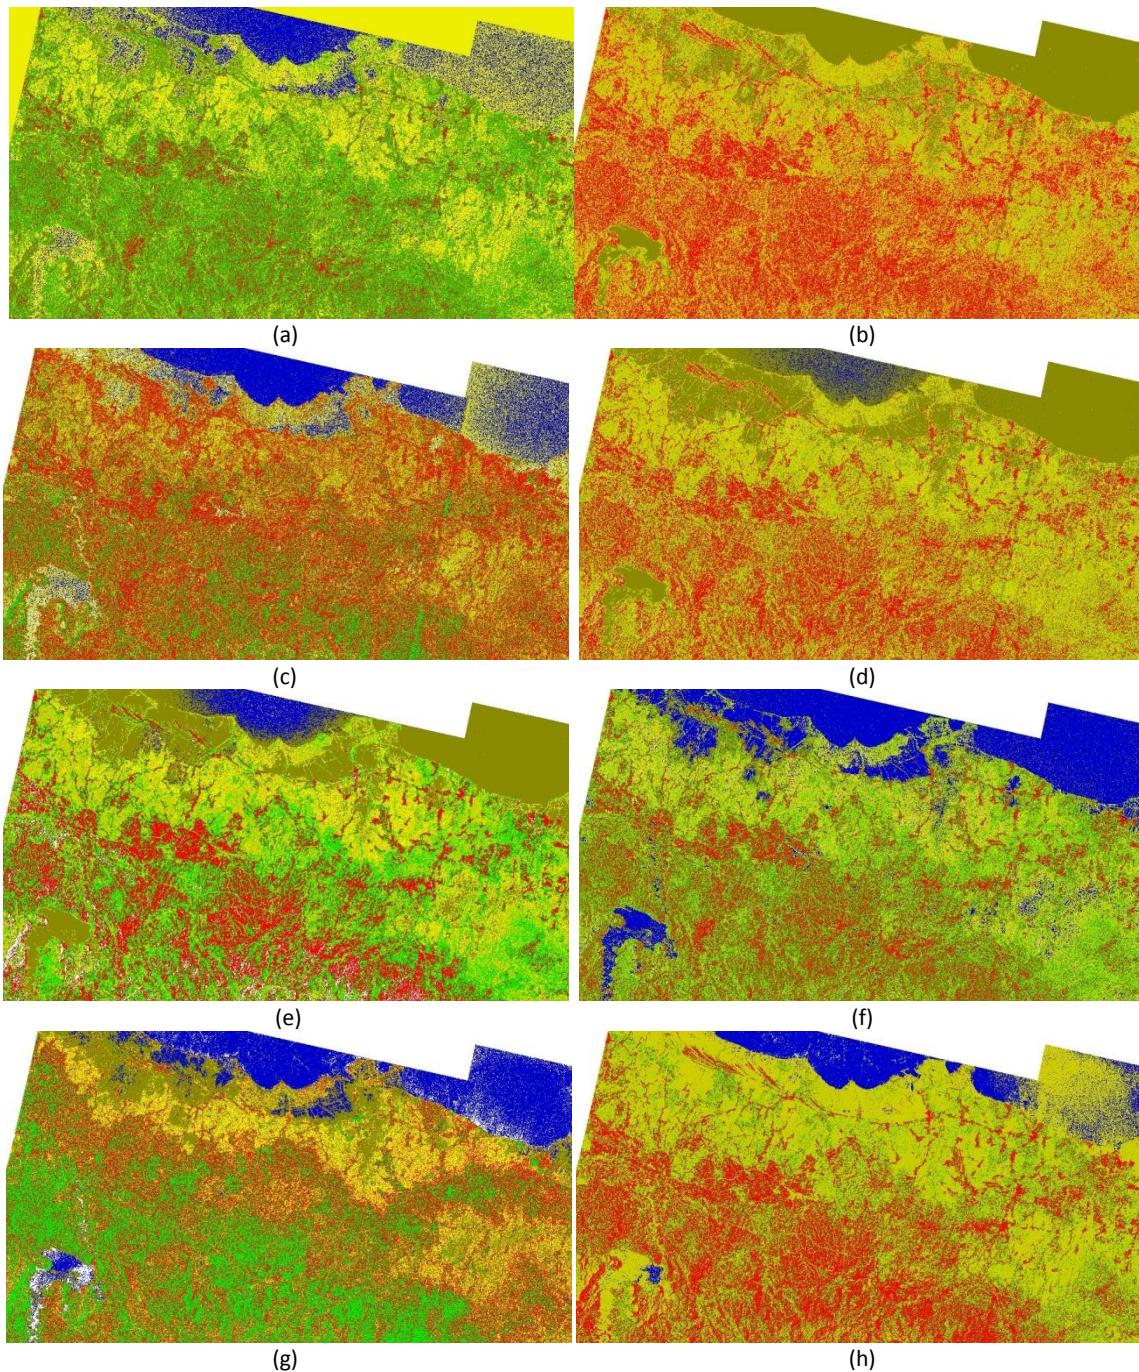
Overall Accuracy = 76.2611%

Kappa Coefficient = 0.7189

Tabel 3-4: PERBANDINGAN PRODUSER AKURASI DAN USER AKURASI BERDASARKAN ARAH ORIENTASI (%)

Kelas	Producer's Accuracy					User's Accuracy				
	0	45	90	135	All	0	45	90	135	All
Perairan	99.95	99.04	100	99.98	99.96	99.71	100	72.21	99.92	99.89
Sawah bera	89.99	89.84	90.09	82.9	89.05	99.43	98.94	99.35	99.61	99.28

Sawah Veg 1	50.46	46.03	52.75	46.86	49.93	75.01	73.71	72.76	72.67	74.83
Sawah Veg 2	66.93	64.49	61.21	64.7	66.06	59.45	57.75	59.53	58.67	59.99
Kebun Campur	71.9	78.14	60.77	68.1	69.01	63.39	59.59	58.18	59.72	61.78
Pemukiman	90.83	87.23	93.22	92.27	91.93	72.41	77.42	63.97	64.51	68.4
Kosong	100	100	0	100	100	99.87	99.86	0	99.95	99.9



Gambar 3-5: Hasil klasifikasi menggunakan fitur tekstur (a) *Angular Second Moment*, (b) *Contrast*, (c) *Correlation*, (d) *Dissimilarity*, (f) *Entropy*, (g) *Mean*, dan (h) *Variance*

Tabel 3-5: CONFUSION MATRIX PADA BERBAGAI FITUR TEKSTUR (%)

Kelas	ANGULAR SECOND MOMENT								Total
	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total	
Perairan	59.02	2.96	0.33	0.02	0	0	0	8.67	
Sawah bera	0.07	50.65	16.44	27.82	23.74	1.51	0	20.08	
Sawah Veg 1	40.9	27.51	78.37	55.83	3.42	0.09	100	41.84	
Sawah Veg 2	0	0	0.03	0.1	0.02	0	0	0.03	

Kebun Campur	0	16.85	4.73	15.38	47.4	11.58	0	15.08
Pemukiman	0	2.03	0.11	0.84	25.42	86.83	0	14.3
Kosong	0	0	0	0	0	0	0	0
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 47.6222%

Kappa Coefficient = 0.3764

Pada perlakuan yang ketiga adalah perlakuan terhadap fitur tekstur yang digunakan. Pada perlakuan ini digunakan ukuran *window* 5x5 dengan sudut orientasi semua arah. Klasifikasi dilakukan pada kedelapan jenis fitur tekstur secara individual dengan menggunakan kedua jenis polarisasi. Hasil klasifikasi dari tiap fitur tekstur ini dapat dilihat pada Gambar 3-5.

Hasil akurasi dari masing-masing fitur tekstur ini seperti terlihat pada Tabel 3-3. Hasil akurasi tertinggi didapat pada fitur *entropy* sebesar 59,1% dilanjutkan *mean* (59,1%), *homogeneity* (58,2%), *dissimilarity* (52,2%), *angular second moment* (47,6%), *contrast* (46,6%), *correlation* (44,3%), dan yang terendah adalah *variance* dengan hasil akurasi sebesar 40,1%.

CONTRAST								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	0	0	0	0	0	0	0	0
Sawah bera	99.91	83.66	5.08	1.28	10.86	1.17	0	29.13
Sawah Veg 1	0.09	5.38	5.17	0.97	0.56	0.03	0	2.07
Sawah Veg 2	0	6.53	84.19	82.86	30.25	5.49	0	39.23
Kebun Campur	0	1.16	0.89	0.89	2.11	0.33	0	0.88
Pemukiman	0	3.27	4.66	14	56.23	92.98	0	23.45
Kosong	0	0	0	0	0	0	100	5.24
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 46.5686%

Kappa Coefficient = 0.3650

CORRELATION								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	59.64	1.2	0.74	0.15	0.02	0.02	0	8.61
Sawah bera	0	23.12	18.05	14.27	2.42	1.19	0	10.26
Sawah Veg 1	11.39	5.57	11.55	4.49	0.36	0.15	0	5.58
Sawah Veg 2	23.58	15.58	44.37	33.67	5.21	0.68	0	21.78
Kebun Campur	0	5.76	8.78	16.02	52.24	7.67	0	14.63
Pemukiman	0	48.64	16.14	31.03	39.68	90.29	0	32.97
Kosong	5.38	0.14	0.36	0.37	0.07	0	100	6.16
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 44.3097%

Kappa Coefficient = 0.3481

DISSIMILARITY								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	16.48	0	0	0	0	0	0	2.28
Sawah bera	83.52	84.52	4.79	0.6	6.49	0.12	0	26
Sawah Veg 1	0	4.07	12.97	3.04	1.48	0.02	0	3.91
Sawah Veg 2	0	2.32	77.88	82.92	25.23	3.51	0	36.44
Kebun Campur	0	3.02	2.99	7.6	13.41	3.09	0	4.97
Pemukiman	0	5.16	1.37	5.85	52.86	93.26	0	20.94
Kosong	0	0.91	0	0	0.53	0	100	5.46
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 52.2177%

Kappa Coefficient = 0.4323

ENTROPY								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	32.93	9.91	0	0	1.49	0	0	6.24
Sawah bera	66.13	72.45	7.92	0	1.08	0	0	21.46
Sawah Veg 1	0	7.14	44.54	8.63	1.17	0	0	11.45
Sawah Veg 2	0	2.52	44.16	73.69	3.52	0.01	0	24.48

Kebun	0	1.16	3.32	17.57	25.5	2.29	0	8.56
Campur	0	4.63	0.07	0.1	60.14	97.7	0	21.04
Pemukiman	0.93	2.2	0	0	7.1	0	100	6.77
Kosong	100	100	100	100	100	100	100	100
Total								

Overall Accuracy = 59.1446%

Kappa Coefficient = 0.5176

HOMOGENEITY								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	98.16	17.91	4.3	0.53	0.13	0	0	17.16
Sawah bera	0.57	49.24	0.82	0.46	16.44	1.2	0	10.2
Sawah Veg 1	1.27	8.69	13.3	4.5	0.81	0.01	0	5.02
Sawah Veg 2	0	8.25	68.47	67.6	11.11	0.68	0	29.9
Kebun Campur	0	12.22	7.17	20.57	32.93	5.12	0	12.99
Pemukiman	0	3.68	0.65	3.16	38.52	92.98	0	17.82
Kosong	0	0	5.29	3.18	0.05	0	100	6.91
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 58.1845%

Kappa Coefficient = 0.5059

MEAN								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	93.07	0.01	0	0	0	0	0	12.89
Sawah bera	0	89.68	6.52	0.04	0	0.01	0	14.41
Sawah Veg 1	0	10.27	42.64	12.6	0.71	20.14	0	14.6
Sawah Veg 2	0	0	5.37	2.17	0	0	0	1.46
Kebun Campur	0	0	16.11	27.39	78.12	15.04	0	22.3
Pemukiman	0	0.03	29.36	57.81	21.17	64.8	0	28.13
Kosong	6.93	0	0	0	0	0	100	6.2
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 59.1146%

Kappa Coefficient = 0.5251

VARIANCE								
Kelas	Peraira n	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukima n	Koson g	Tota l
Perairan	37.58	0	0	0	0	0	0	5.2
Sawah bera	0	0	0	0	0	0	0	0
Sawah Veg 1	0	0	0	0	0	0	0	0
Sawah Veg 2	60.24	56.87	91.61	76.13	13.86	1.21	0	52
Kebun Campur	0	28.81	6.65	16.8	20.14	3.65	0	12.4
Pemukiman	0	14.32	1.73	7.06	66	95.14	0	24.8
Kosong	2.18	0	0	0	0	0	100	5.54
Total	100	100	100	100	100	100	100	100

Overall Accuracy = 40.1104%

Kappa Coefficient = 0.283

Jika akurasi dari tiap-tiap fitur tekstur dibandingkan dengan akurasi pada penggunaan semua fitur tekstur sebagai masukan, hasil akurasi yang didapat jauh lebih rendah dibandingkan klasifikasi menggunakan seluruh fitur tekstur yang mencapai 76.3%. Hal ini sesuai dengan pendapat dari Kushardono, 2012 di mana semakin banyak informasi yang dipergunakan dalam klasifikasi penutup lahan dengan data satelit penginderaan jauh, makin tinggi akurasi hasil klasifikasinya.

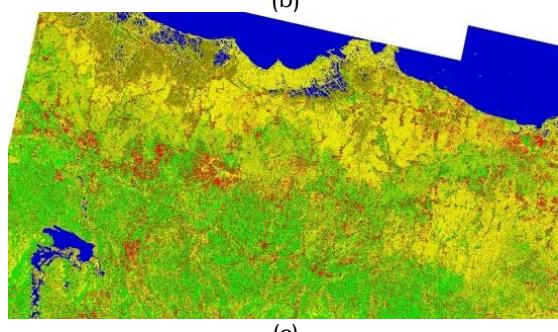
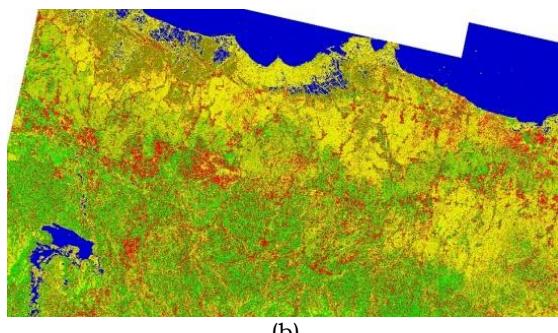
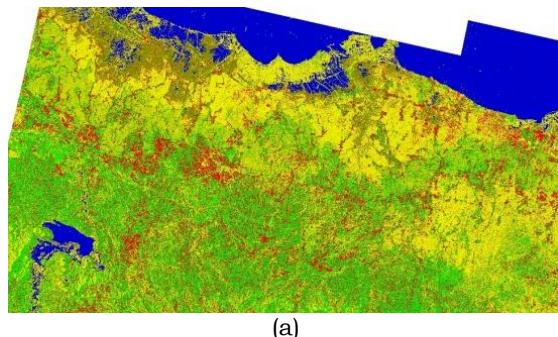
Menurut Baraldi dan Parmiggiani, 1995, tidak semua fitur tekstur perlu untuk digunakan, beberapa fitur akan saling berkorelasi namun juga ada fitur-fitur yang tidak berkorelasi. Baraldi dan Parmiggiani juga mengemukakan bahwa terdapat fitur-fitur yang tidak perlu digunakan seperti *correlation*. Jika dilihat dari akurasi yang didapat, *correlation* termasuk fitur tekstur yang mempunyai akurasi cukup rendah. Tabel 3-6 memperlihatkan perbandingan *producer* akurasi dan user akurasi antar fitur tekstur. Terlihat jika kebanyakan

tekstur menghasilkan produser dan user akurasi yang bervariasi namun

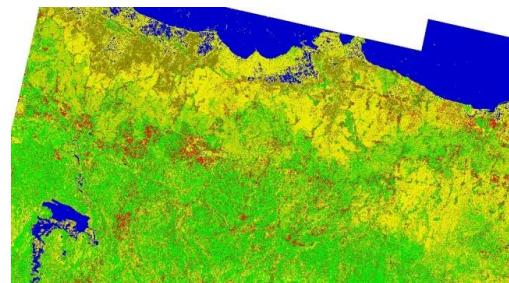
Tabel 3-6: PERBANDINGAN PRODUSER AKURASI DAN USER AKURASI BERDASARKAN FITUR TEKSTUR (%)

Kelas	User's Accuracy							
	ASM	Contrast	Correlation	Dissimilarity	Entropy	Homogeneity	Mean	Variance
Perairan	59.02	0	59.64	16.48	32.93	98.16	93.07	37.58
Sawah bera	50.65	83.66	23.12	84.52	72.45	49.24	89.68	0
Sawah Veg 1	78.37	5.17	11.55	12.97	44.54	13.3	42.64	0
Sawah Veg 2	0.1	82.86	33.67	82.92	73.69	67.6	2.17	76.13
Kebun Campur	47.4	2.11	52.24	13.41	25.5	32.93	78.12	20.14
Pemukiman	86.83	92.98	90.29	93.26	97.7	92.98	64.8	95.14
Kosong	0	100	100	100	100	100	100	100

Kelas	User's Accuracy							
	ASM	Contrast	Correlation	Dissimilarity	Entropy	Homogeneity	Mean	Variance
Perairan	94.23	0	95.89	100	73.07	79.18	99.99	100
Sawah bera	37.03	42.17	33.07	47.72	49.57	70.9	91.36	0
Sawah Veg 1	35.48	47.32	39.22	62.85	73.72	50.15	55.33	0
Sawah Veg 2	71.43	43.58	31.9	46.95	62.12	46.66	30.52	30.21
Kebun Campur	47.8	36.33	54.27	41.03	45.27	38.54	53.25	24.62
Pemukiman	69.53	45.41	31.35	51	53.16	59.75	26.37	43.9
Kosong	0	100	85.07	96.07	77.39	75.89	84.53	94.55



Gambar 3-6: Hasil klasifikasi tanpa menggunakan fitur tekstur (a) Correlation, (b) Variance, (c) Correlation dan Variance.



Gambar 3-7: Hasil klasifikasi menggunakan fitur tekstur *mean*, *variance*, dan *correlation*

Hal tersebut menunjukkan bahwa menghilangkan fitur tekstur yang mempunyai hasil akurasi rendah pada saat digunakan per fitur belum tentu menambah hasil akurasinya, malah bisa jadi hasil akurasinya menurun.

Fitur tekstur dapat dibagi-bagi ke dalam beberapa grup dan salah satunya adalah grup statistik yang terdiri dari *mean*, *variance*, dan *correlation* (Wen, et al., 2009). Hasil klasifikasi menggunakan grup statistik tersebut dapat dilihat pada Gambar 3-7.

Hasil akurasi dari klasifikasi menggunakan grup statistik ini dapat dilihat pada Tabel 3-6. Terlihat bahwa akurasi yang diperoleh menggunakan grup statistik ini menghasilkan akurasi 77.3 % dengan koefisien kappa sebesar 0.7308. Walaupun hanya menggunakan

tiga informasi tekstur dengan dua informasi tekstur merupakan informasi dengan akurasi rendah ketika dilakukan tiap fitur namun hasil akurasi ini lebih tinggi dibandingkan penggunaan semua

fitur tekstur sebagai masukan klasifikasi yang hanya memiliki akurasi sebesar 76.3% dan koefisien kappa 0.7189.

Tabel 3-7: CONFUSION MATRIX TANPA PENGGUNAAN BEBERAPA FITUR TEKSTUR (%)

HASIL UJI AKURASI TANPA FITUR TEKSTUR CORRELATION								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	99.73	0.48	0	0	0	0	0	13.88
Sawah bera	0	86.81	0.39	0	0	0.01	0	12.82
Sawah Veg 1	0	7.47	50.67	11.9	0.21	0.24	0	13.21
Sawah Veg 2	0.22	0.1	41.02	66.22	7.94	1.33	0	22.84
Kebun Campur	0	0	7.06	18	70.18	6.6	0	16.48
Pemukiman	0	5.15	0.87	3.87	21.68	91.83	0	15.53
Kosong	0.04	0	0	0	0	0	100	5.25
Total	100	100	100	100	100	100	100	100

HASIL AKURASI TANPA FITUR TEKSTUR VARIANCE								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	99.93	0	0	0	0	0	0	13.84
Sawah bera	0	83.03	0.67	0	0	0.04	0	12.32
Sawah Veg 1	0.07	12.57	43.17	5.51	0.01	0.12	0	11.19
Sawah Veg 2	0	0.56	46.36	69.06	8.76	2.53	0	24.74
Kebun Campur	0	0	7.34	17.16	67	5.32	0	15.73
Pemukiman	0	3.84	2.46	8.27	24.22	91.99	0	16.95
Kosong	0	0	0	0	0	0	100	5.24
Total	100	100	100	100	100	100	100	100

HASIL AKURASI TANPA FITUR TEKSTUR CORRELATION DAN VARIANCE								
Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	99.91	0	0	0	0	0	0	13.83
Sawah bera	0.01	85.41	1.28	0.01	0	0.27	0	12.82
Sawah Veg 1	0.08	12.4	46.24	8.61	0.07	0.19	0	12.4
Sawah Veg 2	0	0.32	44.37	69.27	11.25	3.26	0	24.83
Kebun Campur	0	0	6.72	16.61	74.28	8.77	0	17
Pemukiman	0	1.87	1.39	5.5	14.4	87.51	0	13.88
Kosong	0	0	0	0	0	0	100	5.24
Total	100	100	100	100	100	100	100	100

Tabel 3-8: CONFUSION MATRIX FITUR TEKSTUR MEAN, VARIANCE, CORRELATION (%)

Kelas	Perairan	Sawah bera	Sawah Veg 1	Sawah Veg 2	Kebun Campur	Pemukiman	Kosong	Total
Perairan	99.88	0	0	0	0	0	0	13.83
Sawah bera	0	88.14	0.23	0.01	0	0.22	0	13.01
Sawah Veg 1	0.01	10.61	47.7	8.06	0.07	0.13	0	12.28
Sawah Veg 2	0	0.23	43.83	68.58	8.77	2.05	0	24.06
Kebun Campur	0	0.01	7.95	21.74	81.3	12.35	0	19.77
Pemukiman	0	1.01	0.28	1.61	9.86	85.25	0	11.79
Kosong	0.11	0	0	0	0	0	100	5.26
Total	100	100	100	100	100	100	100	100

4 KESIMPULAN

Berdasarkan penelitian ini diketahui penggunaan fitur tekstur dalam klasifikasi penutup penggunaan lahan dengan data Sentinel-1 akan memberikan hasil yang bervariasi tergantung dari parameter yang digunakan. Beberapa parameter yang mempengaruhi nilai

akurasi dari hasil klasifikasi dengan menggunakan informasi spasial yaitu ukuran *window*, orientasi, dan fitur tekstur yang digunakan.

Dari penelitian ini parameter yang optimal dalam ekstraksi informasi tekstur untuk klasifikasi penutup penggunaan lahan pada daerah studi

dengan menggunakan data radar Sentinel 1 adalah, ukuran *window* 5x5 dengan sudut orientasi ketetanggaan 0° yang dapat menghasilkan akurasi sebesar 77%. Adapun fitur tekstur yang mempunyai akurasi tertinggi didapat pada penggunaan fitur *entropy*, tetapi semakin banyak jumlah fitur yang dijadikan masukan dalam klasifikasi dan pemilihan fitur tekstur yang tepat akan dapat meningkatkan akurasi hasil klasifikasinya.

UCAPAN TERIMA KASIH

Ucapan terima kasih kami ucapkan kepada Kepala Pusat Pemanfaatan Penginderaan Jauh yang telah memberikan dukungan pada penelitian ini.

DAFTAR RUJUKAN

- Baraldi, A., dan Parmiggiani, F., 1995. *An Investigation of the Textural Characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters*. IEEE Transactions on Geoscience and Remote Sensing, 33(2), 293-304.
- Barber, D. G. dan LeDrew, E. F., 1991. *SAR Sea Ice Discrimination Using Texture Statistics: A Multivariate Approach*. Photogrammetric Engineering and Remote Sensing, 57(4), 385-395.
- Cazals, C., Rapinel, S., Frison, P. L., Bonis, A., Mercier, G., Mallet, C., Corgne, S., dan Rudant, J. P., 2016. *Mapping and Characterization of Hydrological Dynamics in a Coastal Marsh Using High Temporal Resolution Sentinel-1A Images*. Remote Sensing 8(7), 570.
- Clausi, D. A., dan Jernigam, M. E., 1998. *A Fast Method to Determine Co-Occurrence Texture Features*. IEEE Transactions on Geoscience and Remote Sensing, 36(1), 298-300.
- Congalton, R. G., dan Green K., 2008. *Assessing the Accuracy of Remotely Sensed Data – Principles and Practices*. Second Edition. CRC Press/Taylor & Francis.
- Conners, R. W., dan Harlow, C. A., 1980. *A Theoretical Comparison of Texture Algorithms*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2(3), 204-222.
- Dekker, R. J., 2003. *Texture Analysis and Classification of ERS SAR Images for Map Updating of Urban Areas in The Netherlands*. IEEE Transactions on Geoscience and Remote Sensing, 41(9), 1950-1958.
- ESA, 2017. SNAP - ESA Sentinel Application Platform v2.0.2, <http://step.esa.int> diakses Januari 2017.
- Franklin, S. E., Wulder, M. A., dan Gerylo, G. R., 2001. *Texture Analysis of IKONOS Panchromatic Data for Douglas-Fir Forest Age Class Separability in British Columbia*. International Journal of Remote Sensing, 22(13), 2627-2632.
- Geudner, D., Torres, R., Snoeij, P., Davidson, M., dan Rommen, B., 2014. *Sentinel-1 System Capabilities and Applications*. Geoscience and Remote Sensing Symposium (IGARSS), 13-18 Juli 2014. Quebec City.
- Gong, P., Marceau, D. J., and Howarth, P. J., 1992. *A Comparison of Spatial Feature Extraction Algorithms for Land-Use Classification with SPOT HRV Data*. Remote Sensing Environment, 40, 137-151.
- Haralick, R. M., 1985. *Statistical and Structural Approaches to Texture*. 304-322. In Chellappa, R. dan Sawchuk A. A. (ed.) *Digital Image Processing and Analysis: Volume 2: Digital Image Analysis*. IEEE Computer Society Press, New York.
- Haralick, R. M., Shanmugam, K., dan Dinstein, I. (1973). *Textural Feature for Image Classification*. IEEE Transactions on Systems, Man and Cybernetics, 3(6), 610-621.
- Hasyim, B., Sulma, S., dan Hartuti, M., 2010. *Kajian Dinamika Suhu Permukaan Laut Global Menggunakan Data Penginderaan Jauh Microwave*. Majalah Sains dan Teknologi Dirgantara, 5(4), 130-143.
- He, D. C., dan Wang, L., 1990. *Texture Unit, Texture Spectrum, and Texture Analysis*. IEEE Transactions on

- Geoscience and Remote Sensing, 28(4), 509-512.
- Hutagalung, M. E., 2013. *Model Spasial Pendugaan dan Pemetaan Biomassa di atas Permukaan Tanah Menggunakan Citra ALOS PALSAR Resolusi 12.5 M*. Skripsi Institut Pertanian Bogor. 43.
- Kayitakire, F., Hamel, C., dan Defourny, P., 2006. *Retrieving Forest Structure Variables Based on Image Texture Analysis and IKONOS-2 Imagery*. Remote Sensing of Environment, 102, 390-401.
- Kruger, R. P., Thompson, W. B., dan Turner, A. F., 1974. *Computer Diagnosis of Pheumoconiosis*. IEEE Transactions on Systems, Man, and Cybernetics, 4(10), 40-49.
- Kushardono, D., 1996. *Metode Klasifikasi Citra Satelit Radar untuk Mengidentifikasi Penutup Lahan*. Warta Inderaja-MAPIN. VIII(2), 36-44.
- Kushardono, D., 2012. *Klasifikasi Spasial Penutup Lahan Dengan Data SAR Dual Polarisi Menggunakan Normalized Difference Polarization Index dan Fitur Keruangan Dari Matrik Kookurensi*. Jurnal Inderaja, 9(1), 12-24.
- Kushardono, D., 2016. *Klasifikasi Penutup/Penggunaan Lahan Dengan Data Satelit Penginderaan Jauh Hiperspektral (Hyperion) Menggunakan Metode Neural Network Tiruan*. Jurnal Inderaja. 13(2), 85-96.
- Kushardono, D., Fukue, K., Shimoda, H., dan Sakata, T., 1994. *A Spatial Landcover Classification with The Aid of Neural Networks*. In: *Image and Signal Processing for Remote Sensing*, edited by Desachy J., The Int. Soc. for Optical Engineering-SPIE, Pro. 2315, 702-710.
- Kushwaha, S. P. S., Kuntx, S., dan Oesten, G., 1994. *Applications of Image Texture in Forest Classification*. International Journal of Remote Sensing, 15(110), 2273-2284.
- Martono, D. N., 2008. *Aplikasi Teknologi Penginderaan Jauh dan Uji Validasinya untuk Deteksi Penyebaran Lahan Sawah dan Penggunaan/Penutupan Lahan*. Seminar Nasional Aplikasi Teknologi Informasi 2008, 21 Juni 2008. Yogyakarta.
- Miranda, N., dan Meadows, P. J., 2015. *Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF, ESA-EOPG-CSCOP-TN-0002*; European Space Agency: Paris, France.
- Miranda, N., Meadows, P. J., Pilgrim, A., Piantanida, R., Recchia, A., Giudici, A., Small, D., dan Schubert, A., 2016. *Sentinel-1B Preliminary Results Obtained During the Orbit Acquisition Phase [Work in Progress]*. Conference on ENTERprise Information Systems/International Conference on Project MANagement/ Conference on Health and Social Care Information Systems and Technologies, SENTERIS/ProjMAN / HCist 2016, 5-7 Oktober 2016. Porto.
- Mohanaiah, P., Sathyaranayana, P., dan Guru Kumar, L., 2013. *Image Texture Feature Extraction Using GLCM Approach*. International Journal of Scientific and Research Publications, 3(5), 1-5.
- Mouche, A., dan Chapron, B., 2015. *Global C-Band Envisat, RADARSAT-2 and Sentinel-1 Measurements in Co-Polarization and Cross-Polarization*. Journal of Geophysical Research: Oceans, 120(11), 7195-7207.
- Pacifici, F., Chini, M., dan Emery, W. J., 2009. *A Neural Network Approach Using Multi-Scale Textural Metrics from Very High-Resolution Panchromatic Imagery for Urban Land-Use Classification*. Remote Sensing of Environment, 113(6), 1276-1292.
- Panuju, D. R., Heidina, F., Trisasonoko, B. T., Tjahjono, B., Kasno, A., dan Syafril, H. A., 2009. *Variasi Nilai Indeks Vegetasi Modis pada Siklus Pertumbuhan Padi*. Jurnal Ilmiah Geomatika, 15(2), 9-16.
- Pesaresi, M., 2000. *Texture Analysis for Urban Pattern Recognition Using Fine-Resolution Panchromatic Satellite Imagery*. Geographical and Environmental Modelling, 4(1), 43-63.
- Prahasta, E., 2009. *Sistem Informasi Geografis: Konsep-Konsep Dasar (Perspektif*

- Geodesi dan Geomatika).* Informatika Bandung.
- Shanmugan, K., Narayanan, V., Frost, V. S., Stiles, J. A., dan Holtzman, J. C., 1981. *Textural Features for Radar Image Analysis.* IEEE Transactions on Geoscience and Remote Sensing, 19(3), 153-156.
- Simard, M., Saatchi, S.S., dan Grandi G. D., 2000. *The Use of Decision Tree and Multiscale Texture for Classification of JERS-1 SAR Data Over Tropical Forest.* IEEE Transactions on Geoscience and Remote Sensing, 38(5), 2310-2321.
- Soh, L. K., dan Tsatsoulis, C., 1996. *Texture Representation of SAR Sea Ice Imagery Using Multi-Displacement Co-Occurrence Matrices.* IEEE Transactions on Geoscience and Remote Sensing, 37(2), 780-795.
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N., and Shimamura, H., 2014. *Random Forest of Classification Crop Type Using Multi-Temporal TerraSAR-X Dual-Polarimetric Data.* Remote Sensing Letters, 5(2), 157-164.
- Su, W., Li, J., Chen, Y., Liu, Z., Zhang, J., Low, T. M., Suppiah, I., dan Hashim, S. A. M., 2008. *Textural and Local Spatial Statistics for The Object-Oriented Classification of Urban Areas Using High Resolution Imagery.* International Journal of Remote Sensing, 29(11), 3105-3117.
- Sutanto, A., Trisakti, B., dan Arimurthy, A. M., 2014. Perbandingan Klasifikasi Berbasis Obyek dan Klasifikasi Berbasis Piksel pada Data Citra Satelit Synthetic Aperture Radar untuk Pemetaan Lahan. *Jurnal Penginderaan Jauh dan Pengolahan Citra Digital*, 11(1), 63-75.
- Suwargana, N., 2008. *Analisis Perubahan Hutan Mangrove Menggunakan Data Penginderaan Jauh di Pantai Bahagia, Muara Gembong, Bekasi.* *Jurnal Penginderaan Jauh*, 5, 64-74.
- Suwarsono., Yudhatama, D., Trisakti, B., dan Sambodo, K. A., 2013. *Pemanfaatan Citra Pi-SAR2 untuk Identifikasi Sebaran Endapan Piroklastik Hasil Erupsi Gunungapi Gamalama Kota Ternate.* *Jurnal Penginderaan Jauh*, 10(1), 15-26.
- Tjahjono, B., Syafril, A. H. A., Panuju, D. R., Kasno, A., Trisasongko, B. H., dan Heidina, F., 2009. *Pemantauan Lahan Sawah Menggunakan Citra ALOS AVNIR-2.* *Jurnal Ilmiah Geomatika*, 15(2), 1-8.
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Flouri, N., Brown, M., Traver, I. N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., dan Rostan, F., 2012. *GMES Sentinel-1 Mission.* *Remote Sensing of Environment*, 120(2012), 9-24.
- Transactions on Geoscience and Remote Sensing*, 24(2), 235-245.
- Twelve, A., Cao, W., Plank, S., dan Martinis, S., 2016. *Sentinel-1-based Flood Mapping: A Fully Automated Processing Chain.* *International Journal of Remote Sensing*, 37(13), 2990-3004.
- Ulaby, F. T., Kouyate, F., Brisco, B., dan Williams, T. H. L., 1986. *Textural Information in SAR Images.* IEEE.
- Wen, C., Zhang, Y., dan Deng, K., 2009. *Urban Area Classification in High Resolution SAR Based on texture Features.* *Geospatial Solutions for Emergency Management*, 14-16 September 2009. Beijing.
- Weszka, J. S., Dyer, C. R., dan Rosenfeld, A., 1976. *A Comparative Study of Texture Measures for Terrain Classification.* *IEEE transactions on Systems, Man, and Cybernetics*, 6(4), 269-285.
- Wu, D., Yang, H., Chen, X., He, Yong., dan Li, X., 2008. *Application of Image Texture for The Sorting of Tea Categories Using Multi-Spectral Imaging Technique and Support Vector Machine.* *Journal of Food Engineering*, 88(4), 474-483.
- Xiaofeng, L., 2015. *The First Sentinel-1 SAR Image of a Typhoon.* *Acta Oceanologica Sinica*, 34(1), 1-2.

