

DETEKSI PERUBAHAN PENUTUP LAHAN BERDASARKAN ALGORITMA WAVELET À TROUST DENGAN MENGGUNAKAN CITRA SAR

Wihartini *, Sri Jatno W. *, dan Aniati Murni °

* Opto Elektroteknika dan Aplikasi Laser, Fakultas Teknik, Universitas Indonesia, Salemba Raya 4, Indonesia,

Fax : (61)(021)330188, e-mail: spsopto@bit.net.id

° Fakultas Ilmu Komputer, Universitas Indonesia, Depok, Indonesia

Fax(61)(021)7863415, e-mail: aniati@cs.ui.ac.id

ABSTRAK

Penggunaan citra SAR untuk mendeteksi obyek-obyek pada permukaan bumi tanpa kontak langsung, sangat cocok untuk daerah-daerah yang sering tertutup awan dan kabut seperti daerah Kalimantan, Indonesia. Penelitian ini akan membahas deteksi perubahan penutup lahan menggunakan multitemporal Synthetic Aperture Radar (SAR) JERS-1 pada daerah Kalimantan Tengah. Bising speckle yang merupakan sinyal tak bebas dan bekerja sebagai bising multiplikatif pada citra SAR akan di minimisasi dengan menggunakan algoritma wavelet à trous dan juga dilakukan uji signifikansi bising menggunakan Multiresolution Support. Penggunaan transformasi wavelet à trous adalah untuk mempermudah pengamatan struktur citra pada skala yang berbeda dengan tetap mempertahankan ukuran citra. Transformasi multiresolusi à trous menghasilkan satu set citra detil dengan skala yang berbeda dan satu citra aproksimasi skala tertinggi. Dari citra-citra detil akan dapat diperoleh informasi dari obyek-obyek dalam citra. Selanjutnya dilakukan unsupervised klasifikasi atau pengklusteran menggunakan *Self-Organizing Map* (SOM) dari Jaringan Syaraf Tiruan karena tidak tersedianya data groundtruth. Klasifikasi pada citra detil skala tinggi akan memperlihatkan struktur dari obyek-obyek frekuensi rendah. Sedang obyek-obyek dengan frekuensi tinggi hanya akan tampak pada beberapa citra skala rendah dan kemudian hilang. Deteksi perubahan penutup lahan pada penelitian ini menggunakan teknik *Image Differencing* yang dilakukan pada citra-citra detil multitemporal SAR.

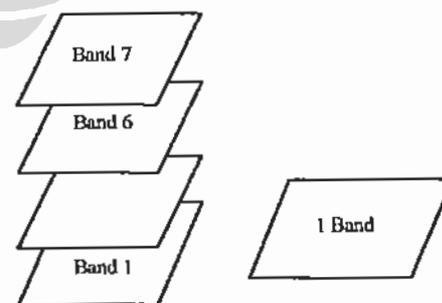
Kata kunci : algoritma à trous, transformasi wavelet multiresolusi, SAR, klasifikasi, SOM, deteksi perubahan area.

1. PENDAHULUAN

Pulau Kalimantan terletak pada daerah ekuator dengan area yang sangat luas serta memiliki bermacam-macam species. Beberapa aktifitas dan kejadian seperti

program pertanian, program transmigrasi dan kebakaran hutan yang terjadi di daerah ini menyebabkan beberapa jenis species tersebut menjadi berkurang dan rusak. Mengingat hal ini, serta untuk dapat tetap menjaga kondisi lingkungan dengan baik, maka perlu dilakukan monitoring terhadap perubahan penutup muka bumi yang disebabkan oleh perubahan lingkungan habitat. Oleh karena itu peranan penginderaan jauh menjadi sangat penting karena dapat dipakai untuk mengidentifikasi, mengukur dan menganalisa karakteristik dari obyek pengamatan dengan area yang sangat luas tanpa kontak langsung.

Penggunaan citra satellite dari SPOT, LANDSAT (citra cahaya gelombang nampak) atau dari SAR, ERS, JERS (citra gelombang mikro) untuk observasi muka bumi mempunyai potensi yang sangat besar. Karena daerah Kalimantan kondisinya sering berawan dan berkabut maka penelitian pada daerah ini lebih tepat menggunakan system penginderaan jauh menggunakan gelombang mikro yang dapat bekerja pada seluruh kondisi cuaca tanpa ada hambatan dari awan maupun kabut. Pada penelitian ini menggunakan citra SAR JERS-1 (Japanese Earth Resources Satellite-1) dengan sumber kesulitan pada pengolahan citranya adalah bising speckle. Data yang digunakan adalah citra multitemporal dari daerah Kalimantan Tengah yang diambil pada tanggal 20 Maret 97 dan 3 Agustus 1998.



a). Landsat TM

b). SAR

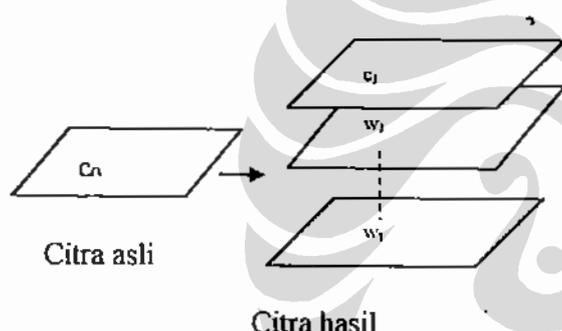
Gambar 1. Perbandingan band dari Landsat dan SAR

Makalah diterima [16 Oktober 2001]. Revisi Akhir [1 Mei 2002]

Pada penelitian ini akan dikembangkan teknik pemrosesan citra SAR yang dianalog-kan dengan teknik pemrosesan citra optis seperti LANDSAT TM yang terdiri dari 7 band berisi informasi, disebut dengan kunci interpretasi ("interpretation key") [1]. Sedangkan citra SAR hanya terdiri dari 1 band saja, maka sulit untuk menggali informasi yang terkandung didalamnya (lihat Gambar 1). Oleh karena itu kontribusi dari penelitian ini adalah mencari cara untuk menambah band dari citra SAR sehingga dapat diperoleh informasi yang lebih banyak. Guna mencapai maksud tersebut diusulkan dengan cara transformasi *à troust* dengan jalan menguraikan citra asli menjadi satu set citra detil dan satu citra aproksimasi.

Citra asli c_0 ditransformasikan kedalam citra aproksimasi atau disebut juga dengan produk skalar c_j ditambah satu set citra detil w_i dengan $i = 1, 2, \dots, j$, dimana j adalah skala tertinggi (lihat Gambar 2). Dari citra-citra detil tersebut akan dapat diperoleh lebih banyak informasi dari obyek-obyek dalam citra.

$$c_0 = c_j + w_1 + w_2 + w_3 + \dots + w_j \quad (1)$$



Gambar 2. transformasi *wavelet* citra SAR

Karena untuk melakukan deteksi perubahan area menggunakan citra multitemporal perlu persyaratan yaitu ukuran citranya harus sama, maka algoritma *à troust* merupakan pemilihan metoda yang sangat tepat. Hal ini sesuai dengan sifat transformasi *à troust* yaitu stasioner dan bersifat redundansi. Dengan transformasi stasioner maka ukuran citra tetap tidak berubah, selain itu sifat redundansi antara citra detil pada skala j dengan citra detil pada skala $(j-1)$, sangat membantu dalam mengidentifikasi obyek. Langkah selanjutnya, digunakan teknik klasifikasi tak terselia ("unsupervised classification") atau pengklasteran dengan metode Self Organizing Map (SOM) dari neural network karena tidak tersedianya data groundtruth. Klasifikasi pada citra detil skala tinggi akan memperlihatkan struktur dari obyek-obyek frekuensi rendah seperti sungai dan jalan raya. Sedang obyek-obyek frekuensi tinggi seperti scattered tree, woodland,

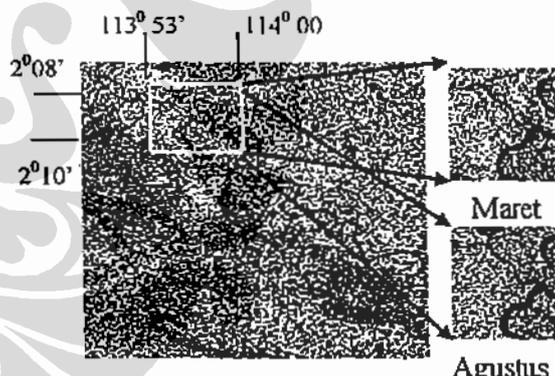
dll., hanya akan tampak pada beberapa citra skala rendah dan kemudian hilang.

Karena tidak tersedianya groundtruth maka pada proses verifikasi data, dalam penelitian ini menggunakan peta thematic yang diperoleh dari BAKOSURTANAL dan citra multitemporal Landsat bulan Maret 97 dan bulan Agustus 98 dari LAPAN.

Deteksi perubahan penutup lahan pada penelitian ini menggunakan teknik Image Differencing yang dilakukan pada citra-citra detil multitemporal SAR setelah proses pelabelan dan identifikasi obyek dari hasil pengklasteran diperoleh.

2. AREA PENELITIAN

Area penelitian adalah Kalimantan Tengah yang terletak pada longitude $113^{\circ}53' - 113^{\circ}57'$ dan latitude $2^{\circ}08' - 2^{\circ}10'$ (lihat Gambar 3). Area ini antara lain terdiri dari scattered Tree, swamp, woodland dan tanaman padi. Data yang digunakan dalam penelitian adalah JERS-1 SAR L-band scene (path-row: 96/304) diambil pada 20 Maret 1997 dan 3 Agustus 1998. Set data di proses pada level 2.1 dengan standard geocoded image di resample ke proyeksi UTM (Universal Transverse Mercator) oleh NASDA. Citra di register dengan memilih 25 GCP (Ground Control Point), menggunakan fungsi polynomial dengan ke akuratan kurang dari 1 pixel RMS (Root Mean Square) error, dengan ukuran $12.5 \text{ m} \times 12.5 \text{ m}$.



Gambar 3. Citra Kalimantan Tengah SAR JERS-1, 20 Maret 97 dan 3 Agustus 98

3. TEORI DASAR

3.1. Algoritma *À Troust*

Suatu transformasi *wavelet* untuk data diskrit dapat diperoleh melalui versi yang dikenal sebagai algoritma *à trous* (yang artinya : by "hole") [2-3]. Proses transformasi

algoritma à trous adalah stasioner selain itu juga transformasinya bersifat redundansi. Transformasi à trous dalam 1-dimensi akan menghasilkan satu set $\{w_j\}$ pada skala j yang berisi informasi detail dan satu produk skalar c_j yang berisi informasi struktur citra. Baik w_j maupun c_j , keduanya mempunyai jumlah pixel yang sama dengan citra aslinya.

$$c_0(k) = c_{ns}(k) + \sum_{j=1}^{ns} w_j(k) \quad (2)$$

dimana ns adalah skala tertinggi.

Dengan memisalkan bahwa sampel data $\{c_0(k)\}$ adalah produk skalar pada pixel k dari fungsi citra $f(x)$, dengan fungsi penyekalaan yang di translasikan $\phi(x-k)$:

$$c_0(k) = \langle f(x), \phi(x-k) \rangle \quad (3)$$

maka produk skalar pada skala j , adalah sebagai berikut:

$$c_j(k) = (1/2^j) \langle f(x), \phi(2^j(x-k)) \rangle \quad (4)$$

Jika fungsi wavelet $\phi(x)$ mengikuti persamaan dilasi $1/2 \phi(x/2) = \sum_l g(l) \phi(x-l)$ maka,

$$1/2 \phi(x/2) = \sum_n h(n) \phi(x-n) \quad (5)$$

Koefisien filter $h(k)$ diperoleh dari persamaan dilasi $\phi(x)$, persamaan (5). Dari persamaan (3) dan (4), jarak antara sampel bertambah dengan faktor 2 dari skala $(j-1)$ untuk $j > 0$ sampai skala j .

$c_j(k)$ dapat dihitung secara iterasi dengan mengikuti relasi sebagai berikut:

$$c_{j+1}(k) = \sum_n h(n) c_j(k + 2^n) \quad (6)$$

Fungsi spline $h(n)$ [5] yang akan digunakan adalah kubik sentral B-spline atau B_3 -spline:

$$h(n) = \{1/16; 3/8; 3/8; 1/16\}; \quad (-2 \leq n \leq 2) \quad (7)$$

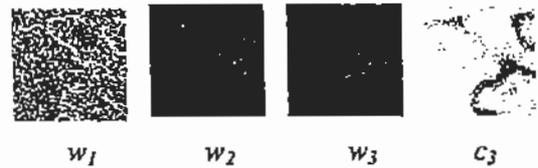
dan koefisien wavelet w_j diperoleh dari perbedaan antara dua produk skalar:

$$w_j(k) = c_{j+1}(k) - c_j(k) \quad (8)$$

Jika harga $(k + 2^n)$ dari $c_j(k + 2^n)$ berharga negatif, maka aturan "mirror" akan digunakan:

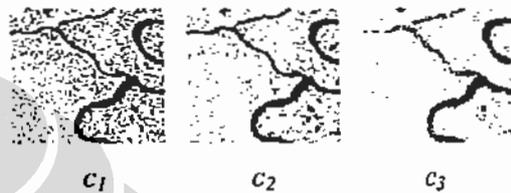
$$c(k-n) = c(k+n) \quad (9)$$

sedang rekonstruksi citra dapat dilakukan dengan menggunakan formula (2).



Gambar 4. Transformasi à trous dengan skala 3

Citra detail diperoleh dari $w_1 = c_0 - c_1$, $w_2 = c_1 - c_2$ dan $w_3 = c_3 - c_2$. Dari Gambar 4, terlihat bahwa citra detail pada skala tertinggi w_3 mempunyai garis tepi obyek yang lebih jelas.



Gambar 5. Citra aproksimasi

Gambar 5 menunjukkan satu set citra aproksimasi yang digunakan untuk menghasilkan citra detail. Skala tertinggi yang akan digunakan untuk meminimisasikan bising spekle pada pra pengolahan adalah $ns = 5$.

Tabel 2. Mean dan standard deviasi citra detail dan aproksimasi

Citra	Mean	Stand.deviasi
Origin	145.2342	78.5767
c_1	145.2308	0
c_2	145.2380	41.9245
c_3	145.2489	28.1238
w_1	0.0034	58.2762
w_2	-0.0072	17.6944
w_3	-0.0109	13.8098

Dari tabel 2 terlihat bahwa citra aproksimasi dari transformasi à trous berisi harga rata-rata (mean). Bila makin tinggi skala, harga rata-ratanya naik maka citra tersebut berisi obyek yang mempunyai harga digital number yang tinggi seperti tanah gersang, hutan dan lain-lain. Hal ini menyebabkan harga rata-rata citra detail menjadi negatif.

3.2. Denoising

Denoising atau proses pengurangan bising, berbeda dengan proses filtering. Filtering dilakukan dalam domain

frekuensi, yaitu menghilangkan daerah frekuensi yang tidak diinginkan dengan menggunakan thresholding sehingga beberapa struktur yang berbeda ikut hilang. Sedangkan pada transformasi *wavelet* yang mengubah waktu ke domain skala dan ruang, maka proses denoising yang menghilangkan bising pada frekuensi tertentu dan pada ruang tertentu tidak akan menghilangkan beberapa struktur yang berbeda.

Citra SAR di modelkan mengandung dua komponen, yaitu komponen deterministik dan komponen stokastik. Komponen deterministik adalah sinyal sedang komponen stokastik adalah bising. Ada dua model bising yaitu model bising additive Gauss dan model bising multiplikatif non-Gauss. *Speckle* adalah bising multiplikatif non-Gauss. Pada citra SAR, karena bisingnya adalah *speckle* yang bersifat multiplikatif maka kedua komponen tersebut akan dikalikan. Untuk memisahkan dua komponen tersebut maka dilakukan dengan mengambil harga logaritmanya. Model citra :

$$z = x \cdot v$$

$$\log(z) = \log(x) + \log(v) \quad (10)$$

dimana : $\log(z)$ adalah citra baru,
 $\log(x)$ adalah sinyal, dan
 $\log(v)$ adalah bising additive.

Karena bising $\log(v)$ adalah additive maka dapat dinyatakan dalam model Gaussian. Selanjutnya untuk mengukur tingkat keberhasilan proses pengurangan *speckle* dilakukan dengan pendekatan secara statistik. Dalam penelitian ini, untuk uji signifikansi bising digunakan *multiresolution support* [2-3].

Nilai standard deviasi yang sesuai pada skala j (σ_j) dalam ruang *wavelet* berikutnya ditetapkan dari standard deviasi bising σ_f yang ada dalam citra asli I dan dari pembelajaran mengenai bising dalam ruang *wavelet*. Pembelajaran ini terdiri dari simulasi citra yang mengandung bising Gaussian dengan standard deviasi sama dengan 1. Kemudian menghitung standard deviasi σ_j^f pada masing-masing skalanya. Hasil yang diperoleh dari transformasi *wavelet* adalah :

$$\sigma_j = \sigma_j^f \quad (11)$$

Jika distribusi $w_j(x,y)$ adalah Gaussian, dengan rata-rata nol dan standard deviasi sama dengan σ_j , maka dapat digunakan untuk membandingkan $w_j(x,y)$ terhadap $K\sigma_j$. Kebanyakan K dipilih berharga 3 [2-3], dengan ketelitian $\epsilon = 0.002$. Jika $w_j(x,y)$ berharga kecil, berarti citra tidak signifikan dan dapat dinyatakan sebagai bebas bising. Tetapi jika $w_j(x,y)$ berharga besar maka citra menjadi signifikan.

Jika $|w_j(x,y)| \geq K\sigma_j$, $w_j(x,y)$ signifikan

$$|w_j(x,y)| \leq K\sigma_j, w_j(x,y) \text{ tidak signifikan} \quad (12)$$

Dalam hal model bising Gaussian, maka perlu di estimasi harga standard deviasi dari bising pada masing-masing skala dari *Multiresolution support* sebagai berikut:

$$M_j(x,y) = 1; \text{ if } w_j(x,y) \text{ significant} \\ = 0; \text{ if } w_j(x,y) \text{ not significant} \quad (13)$$

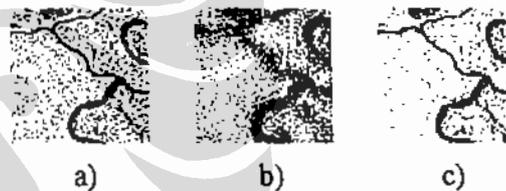
Untuk menentukan koefisien signifikansi dengan $M_j(x,y)$, masking-nya adalah sebagai berikut :

$$\sum_{j=1}^{ns} w_j(x,y) M_j(x,y) \quad (14)$$

dan rekonstruksi citranya menggunakan formula :

$$c_0(x,y) = c_{ns}(x,y) + \sum_{j=1}^{ns} w_j(x,y) M_j(x,y) \quad (15)$$

Penggunaan *multiresolution support*, menyebabkan $c_0(x,y)$ tampak mempunyai struktur yang tidak sebenarnya (*residual artifact*). Untuk itu perlu algoritma khusus untuk mengurangi *residual artifact*.



Gambar 6. a) citra asli, b) citra dengan residual artifact
 c) citra setelah pengurangan residual artifact

Gambar 6, memperlihatkan perbedaan dari citra asli, citra dengan residual artifact dan citra setelah proses pengurangan residual artifact.

Haar :



Mean (\bar{x}) :	145.201	145.196	145.187
Std.dev(σ) :	46.510	41.361	38.045
$\sigma_v(\frac{\sigma}{\bar{x}})$:	0.320	0.285	0.261

Daubechies (db-4) :



level-3 level-4 level-5

Mean (\bar{x}) :	142.621	141.825	140.897
Std,dev(σ) :	46.519	42.641	38.861
$\sigma_v(\frac{\sigma}{\bar{x}})$:	0.326	0.301	0.276

À trous :



level-3 level-4 level-5

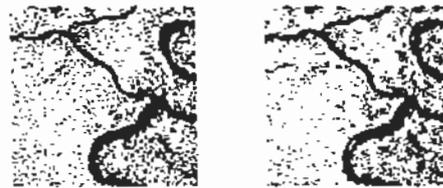
Mean (\bar{x}) :	145.197	145.225	145.225
Std,dev(σ) :	48.778	46.452	45.101
$\sigma_v(\frac{\sigma}{\bar{x}})$:	0.335	0.319	0.310

Gambar 7. Perbandingan citra hasil denoising menggunakan Haar, Daubechies dan *à trous*

Hasil denoising dengan algoritma *à trous* akan memperlihatkan keunggulannya dalam mempertahankan struktur obyek dalam citra dibanding dengan transformasi *wavelet* dengan Haar atau Daubechies, meskipun harga σ_v pada setiap level lebih besar. Hal ini menyatakan varian atau informasi *à trous* lebih besar dari Haar dan Daubechies. Gambar 7. akan memperlihatkan bahwa dengan menambah skala pada proses denoising, transformasi *wavelet* dengan Haar maupun Daubechies akan mengalami kerusakan informasi dengan munculnya spot pada citra Daubechies level 3,4, 5 dan distorsi struktur berupa kotak pada citra Haar. Sedang *à trous* tidak mengalami kerusakan informasi dengan bertambahnya skala

Dari Gambar 7 citra *à trous*, terlihat makin tinggi level atau skala resolusinya, struktur obyek makin jelas. Tapi performansi seperti ini tidak dapat di pertahankan terus. karena transformasi pada level-6 citra Maret 97, muncul spot yang menandakan ada informasi yang rusak

(lihat Gambar 8). Sedang citra Agustus 98 timbul spot setelah transformasi mencapai level-7.



Level-5 level-6

Gambar 8. Hasil denoising menggunakan algoritma *à trous* level-5 dan 6, Maret 97.

Oleh karena itu transformasi *à trous* untuk area penelitian ini, hasil denoising yang terbaik adalah pada level-5.

3.3. Self Organizing Map (SOM)

Pengorganisasian sendiri (Self Organizing) dalam jaringan adalah satu dari metode yang sangat banyak di aplikasikan dalam teknik neural network. Jaringan ini dapat melakukan pembelajaran untuk mendeteksi regularitas dan korelasi dari masukannya serta menyesuaikan tanggapannya terhadap masukan. *Self-Organizing Map* (SOM) belajar untuk melakukan klasifikasi vector masukan sesuai dengan bagaimana mereka dikelompokkan dalam ruang masukan. Metode ini dikembangkan oleh Kohonen (1984) [4]. Satu keandalan dari neural network adalah kemampuannya untuk belajar.

Ada dua konsep yang sangat penting pada proses pembelajaran yaitu paradigma pembelajaran dan aturan pembelajaran. Paradigma pembelajaran merupakan model interaksi jaringan syaraf terhadap lingkungannya, yaitu lingkungan informasi yang tersedia untuk jaringan tersebut. Sedang aturan pembelajaran merupakan proses yang digunakan untuk mengubah atau memperbaharui nilai penimbang dalam jaringan syaraf.

Terdapat dua paradigma pembelajaran pada neural network, yaitu pembelajaran terselia (Supervised) dan pembelajaran tak terselia (Unsupervised). Perbedaan dari kedua paradigma itu adalah dalam hal target keluarannya.

Pada pembelajaran terselia dapat diartikan sebagai adaptasi jaringan, melalui perubahan dalam jaringan, terhadap hubungan masukan ke keluaran. Setiap pola masukan yang diberikan kepada jaringan memiliki jawaban atau target yang telah diketahui sebagai kunci pengenalan untuk menghasilkan sejumlah attribute kelas. Back-propagation adalah metoda neural network dengan pelatihan terselia yang sangat populer.

Berbeda dengan pembelajaran terselia, pada pembelajaran tak terselia tidak diperlukan jawaban atau target yang telah diketahui sebelumnya. Metode klasifikasi tak terselia merupakan pendekatan dimana

penentuan kelas didasarkan pada daya pisah spectral masukan yang berarti bahwa jaringan membentuk kelas-kelas yang dapat dipisahkan secara spectral. Anggapan dasarnya adalah bahwa pola di dalam suatu jenis kelas akan berbeda dan dapat dipisahkan dengan pola kelas lainnya secara perbandingan. Klasifikasi tak terselia meng-adaptasi struktur internal jaringan untuk menuju kepada struktur properti masukan. Jaringan Kohonen merupakan salah satu yang termasuk ke dalam kelompok ini. Jaringan ini selain memiliki kemampuan pembelajaran yang cepat, juga memiliki kemampuan pengklasteran secara alamiah berdasarkan pada kemiripan dengan pola masukannya sendiri atau dikenal dengan sebutan *self-organizing map (SOM)* [4]. Pembelajaran ini tidak membutuhkan vector target untuk keluarannya, oleh karena itu tidak ada perbandingan yang dilakukan terhadap respon ideal yang ditetapkan sebelumnya. Rangkaian pembelajaran hanya berisi vektor masukan saja. Algoritma pembelajaran memodifikasi penimbang jaringan untuk menghasilkan vector keluaran yang konsisten. Artinya, penerapan salah satu vector pembelajaran atau vector yang serupa, akan menghasilkan pola keluaran yang sama. Proses pembelajaran berarti proses mengubah atau memodifikasi nilai penimbang dalam jaringan berdasarkan pada suatu aturan pembelajaran yang ditentukan.

4. KLASIFIKASI

Dalam penelitian ini menggunakan klasifikasi tak terselia ("unsupervised classification") karena tidak tersedianya data groundtruth mengenai target yang diinginkan. Peneliti-peneliti terdahulu, banyak yang telah berhasil menganalisa obyek menggunakan texture untuk daerah yang groundtruthnya tidak tersedia [5-6]. Pertambahan band dan sifat redundansi dari citra detail yang diperoleh dari penelitian ini, maka klasifikasi tak terselia atau pengklasteran dari SOM merupakan pilihan yang tepat. Dalam aturan ini neuron-neuron keluaran saling bersaing, sehingga pada akhirnya hanya satu unit neuron yang teraktivasi, yaitu neuron yang paling mirip dengan pola masukan. Pembelajaran kompetitif ini akan meng-klaster atau mengelompokkan data masukan. Pola-pola yang serupa akan dikelompokkan oleh jaringan dan diwakili oleh satu unit neuron. Pengelompokan ini dilakukan secara otomatis berdasarkan pada korelasi data.

Pembelajaran kompetitif yang sederhana memiliki satu lapisan keluaran. Setiap unit i pada lapisan keluaran terhubung dengan seluruh unit masukan (x_j) dengan penimbang w_{ij} , untuk $j = 1, 2, 3, \dots, n$. Sebagai hasil kompetisi, hanya satu unit i yang memiliki selisih terkecil terhadap vector pola masukan dan akan dinyatakan sebagai pemenang. Dampak dari aturan ini adalah membuat pola pemenang mendekati pola masukan.

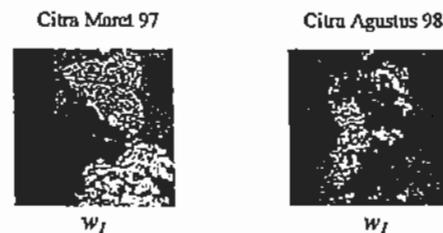
Langkah pertama adalah melakukan inialisasi pada proses competitive layer. Dalam penelitian ini menggunakan satu layer dan diperlukan parameter matriks dari harga maksimum dan minimum, yaitu dalam bentuk angka numerik dari 0 sampai 255. Selanjutnya dipilih jumlah neuron = 8 karena menghasilkan struktur yang paling jelas, Kohonen Learning Rate (KLR) = 0.01 dan Conscience Learning Rate (CLR) = 0.001.

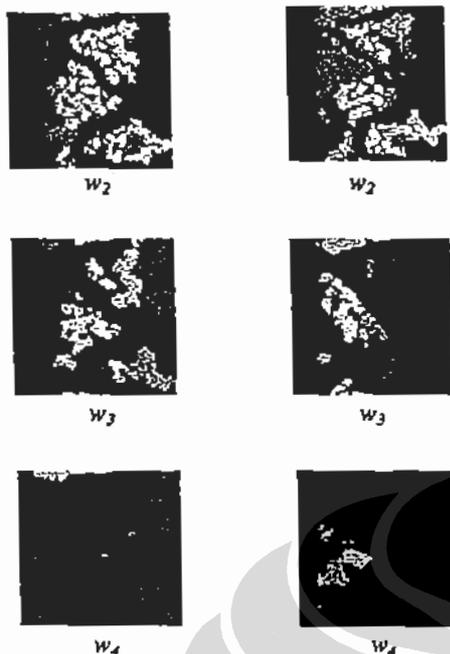
Sebelum proses training, citra 2-dimensi di ubah ke bentuk vector matriks. Setelah proses training (pelatihan) vector matriks dikembalikan kedalam bentuk 2-dimensi. Gambar 9, memperlihatkan citra Maret 97 dan Agustus 98 hasil denoising, ditransformasi pada skala 4 sehingga menghasilkan citra detail w_1, w_2, w_3 dan w_4 dari skala yang berbeda, struktur obyeknya akan tampak semakin jelas pada skala yang lebih tinggi.



Gambar 9. Pengklasteran citra detail

Langkah selanjutnya adalah proses pelabelan citra detail, yang hasilnya terlihat pada Gambar 10.





Gambar 10. Pelabelan citra detil Maret 97 dan Agustus 98

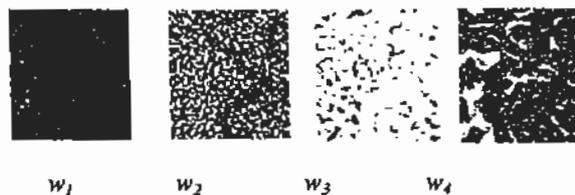
Setelah proses pelabelan dimana struktur obyek-obyek dalam citra sudah terlihat, langkah selanjutnya adalah deteksi obyek. Untuk melakukan verifikasi obyek biasanya digunakan data "groundtruth". Tapi karena tidak tersedianya groundtruth, verifikasi pada penelitian ini menggunakan peta Thematic dari BAKOSURTANAL dengan skala 1:250.000 dan citra Landsat TM dari LAPAN. Hal ini dilakukan karena skala dari peta Thematic terlalu besar. Hasilnya terdeteksi ada 5 klas. Klas tersebut adalah tumbuhan rawa atau swamp (biru muda), hutan yang bergerombol atau scattered tree (kuning), sungai yang dangkal (biru tua), sungai yang dalam (merah) dan tanaman padi (orange).

5. DETEKSI PERUBAHAN AREA

Deteksi perubahan penutup lahan menggunakan metode Perbedaan Citra ("Image Differencing") adalah metode deteksi perubahan yang paling sederhana. Penganalisaan deteksi perubahan dilakukan dengan pengurangan setiap citra detil Maret 97 dengan Agustus 96 dimana citra detil - citra detil tersebut dianalogikan dengan multiband pada proses citra optis. Hal ini berbeda dengan yang telah dilakukan oleh peneliti lain [7-8] yang menggunakan citra multitemporal. Proses dari Perbedaan Citra pada penelitian ini adalah :

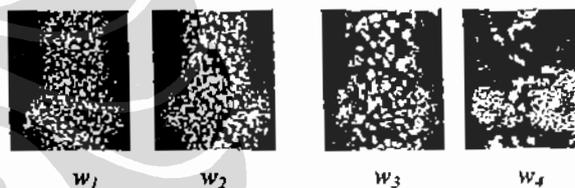
$$\text{Perbedaan Citra} = \text{Citra Agustus 98} - \text{Citra Maret 97} \quad (16)$$

Dalam pemrosesan ini dilakukan teknik deteksi perubahan citra menggunakan Image Differencing dari ERMAPPER seperti terlihat pada Gambar 11. Selanjutnya dilakukan pengklasteran menggunakan SOM



Gambar 11. Deteksi perubahan citra detil (Agustus 98 - Maret 97) menggunakan Image Differencing

Setelah dilakukan pengklasteran, proses selanjutnya adalah pelabelan untuk membedakan kluster yang ada dalam citra. Algoritma pelabelan pada deteksi perubahan ini sama dengan algoritma untuk klasifikasi citra pada proses sebelumnya.



Gambar 12. Deteksi perubahan citra detil (Agustus 98 - Maret 97)

Pada Gambar 12, citra detil w_4 memperlihatkan adanya perbedaan area pada daerah swamp yang dapat diamati dengan warna biru gelap dan biru muda. Sedang scattered tree ditandai dengan warna kuning. Obyek sungai yang dalam maupun dangkal hampir tidak terjadi perubahan yang signifikan. Area dengan warna merah muda, apabila dilakukan verifikasi dengan peta thematic menunjukkan daerah persawahan disekitar sungai yang dalam.

6. KESIMPULAN

Dari hasil penelitian, ada dua kesimpulan yang bisa diambil, yaitu:

Proses denoising menggunakan algoritma *à trous* mempunyai kelebihan dibanding denoising menggunakan mother *wavelet* yang sudah terkenal seperti Haar dan Daubechies. Algoritma *à trous* dalam proses denoisingnya tetap dapat mempertahankan informasi atau struktur dari citra. Sedang pada Haar atau Daubechie semakin tinggi skalanya, akan mengakibatkan rusaknya informasi dengan timbulnya spot pada citra.

Untuk menggali lebih banyak informasi dari citra SAR dapat dilakukan dengan menambah band menggunakan transformasi *à troust*. Band yang dimaksud pada penelitian ini adalah satu set citra detil w dengan skala berbeda. Selanjutnya dilakukan pengklasteran dengan SOM untuk mengidentifikasi obyek. Pengamatan pada skala yang berbeda akan memudahkan identifikasi obyek. Selain hal tersebut, karena sifat transformasi *à troust* adalah transformasi redundansi, maka korelasi obyek dari citra detil j dengan citra detil $(j-1)$ akan mempermudah pendeteksian obyek. Terlihat dari hasil pengklasteran, obyek-obyek dengan frekuensi rendah akan tampak lebih jelas pada skala tinggi, misal : sungai. Sebaliknya obyek-obyek dengan frekuensi tinggi akan tampak pada citra detil skala rendah, dan akan hilang dengan bertambahnya skala.

Sifat redundansi dari citra detil memudahkan deteksi perubahan lahan, dimana deteksi awal dimulai dari citra detil skala tinggi kemudian dicari korelasinya pada citra detil yang lebih rendah.

REFERENSI

- [1]. Japan Association on Remote Sensing, "*Remote Sensing Note*", 1996, Universitas of Tokyo, pp 110, 154
- [2]. J.L Starck, F. Murtagh, A. Bijaoui. *Image Processing and Data Analysis The Multiscale Approach*, Cambridge, 1998, pp 6-20, 21-30, 55-59
- [3]. J.C. Van Den Berg, "*Wavelet in Physics*", Cambridge, 1999, pp 88-89, 109
- [4]. Simon Haykin, "*Neural Networks A Comprehensive Foundation*", second edition, Prentice Hall, 1999, p446-461.
- [5]. Tianhorng Chang and C.C. Jay Kuo, "Texture Analysis and classification with tree-structured wavelet transform", 1993, *IEEE Transaction on image processing*, vol.2, 429-441
- [6]. Robert M. Haralick, K. Shanmugam, and Its'hak Dinstein, "Textural Features for Image Classification", *IEEE Transactions On Systems, Man, and Cybernetics*, vol. SMC-3, No. 6, Nov.1973
- [7]. J. Cihlar, T.J. Pultz and A.L. Gray, "Change detection with synthetic aperture radar", *Int. J. Remote Sensing*, 1992, vol. 13, NO. 3, 401-414.
- [8]. R.G. White, "Change detection in SAR imagery", *Int. J. Remote Sensing*, 1991, vol. 12, NO. 2, 339-360.

