

Klasifikasi Citra Penginderaan Jauh Menggunakan Teknik Logika Samar (*Fuzzy Logic*)

Johannes Manalu

Pusat Pengembangan Pemanfaatan dan Teknologi Penginderaan Jauh LAPAN

ABSTRACT

Many methods has been used for image classification. One of them is that Fuzzy Logic that consist of two algorithms 1) Hard Classifier and 2) Soft Classifier. Application of the Fuzzy Logic for classification can identifi mix pixel and decrease presentase of overlapping class and unclassified class. The unsupervised classification does depends on the condition of data or a priori class. The fuzzy Logic Classification depends on land cover heterogeneity.

ABSTRAK

Banyak cara yang digunakan dalam mengklasifikasi citra. Salah satu caranya dengan menggunakan Fuzzy Logic yang terdiri dari Metode Klasifikasi Tegas dan Metode Klasifikasi Samar. Hasil klasifikasi dengan menggunakan Fuzzy Logic dapat mengidentifikasi piksel campuran, sehingga dapat mengurangi persentase klas yang overlap dan yang *unclassified*. Model Klasifikasi Tak Terbimbing pada umumnya tidak mensyaratkan data yang berlebihan atau kelas tidak dikenal secara apriori. Metode Klasifikasi yang berdasarkan Logika Samar sangat memperhatikan heterogenitas kondisi permukaan bumi.

1. PENDAHULUAN

Selain dianalisis secara visual, citra penginderaan jauh sering juga dianalisis secara digital untuk mendapatkan informasi tematik. Klasifikasi multispektral adalah satu diantara metode yang sering digunakan untuk mengekstrak informasi, terutama informasi penutup lahan. Bila pada pengolahan citra digital, citra penginderaan jauh akan dianalisis secara kualitatif mengingat peran interpretasi visual yang kuat dalam perolehan informasi. Sedangkan klasifikasi multispektral menggunakan pendekatan kuantitatif dan mengurangi subyektifitas pada kegiatan interpretasi. Klasifikasi citra penginderaan jauh adalah suatu proses dimana semua pixel dari suatu citra yang mempunyai penampakan spektral yang sama akan diidentifikasi. Algoritma-algoritma yang dapat digunakan pada metode klasifikasi multispektral adalah : (1) Klasifikasi Tegas (Hard Classifier), (2) Klasifikasi Samar (Soft Classifier), dan (3) Klasifikasi Hibrid

(Jensen, 1996). Algoritma Klasifikasi Tegas pada umumnya terbagi menjadi dua kelompok besar yaitu Kelompok Terbimbing (Supervised) dan Kelompok Tak Terbimbing (Unsupervised).

Pada algoritma terbimbing, area yang representatif untuk masing-masing kelas harus ditentukan oleh pengguna (diketahui secara apriori). Satu hal yang penting diperhatikan dalam pengambilan sampel di sini adalah pencarian area yang homogen. Namun demikian kisaran variabilitas juga perlu diperhatikan untuk menghindari ketidakmampuan algoritma dalam mengklasifikasi. Informasi yang diperlukan dalam penetapan sampel area dapat diperoleh dari survei lapangan, foto udara, peta atau data-data yang lain. Ditinjau dari aspek statistika, sampel yang ditentukan haruslah mencukupi. Swain dan Davis (1978) menganjurkan 10 sampai 100 piksel per kelas untuk mendapatkan statistik kelas yang sesuai. Algoritma akan menghitung variabel-variabel statistika dasar yang diperlukan yaitu

rataan, deviasi standar, matriks kovarian, matriks korelasi, dan lain-lain untuk setiap area yang dijadikan sampel klasifikasi. Selanjutnya, algoritma akan mengevaluasi dan memetakannya ke dalam kelas yang memiliki peluang/kemiripan terbesar. Mengingat algoritma memetakan suatu piksel hanya ke dalam satu kelas saja, maka banyak penulis menggolongkan tipe algoritma-algoritma ini ke dalam Klasifikasi Tegas (Jensen, 1996). Klasifikasi terbimbing terdiri dari klasifikasi berdasarkan jarak minimum rata-rata kelas yang menggunakan strategi paling sederhana, yaitu dengan cara menentukan nilai rata-rata setiap kelas yang disebut vektor rata-rata. Klasifikasi berdasarkan strategi paralelepiped yang dapat memberikan kepekaan terhadap varian kategori dengan memperhitungkan kisaran nilai digital dari masing-masing rangkaian kategori nilai piksel training area. Klasifikasi berdasarkan fungsi normal Gauss kemiripan maksimum dengan cara mengevaluasi kuantitatif varian maupun korelasi pola tanggapan spektral pada saat mengklasifikasi piksel yang tidak dikenal.

Model Klasifikasi Tak Terbimbing pada umumnya tidak mensyaratkan data yang berlebihan atau kelas tidak dikenal secara apriori. Oleh karena itu, metode ini pada umumnya diterapkan pada citra yang kurang didukung oleh data kondisi permukaan lahan. Algoritma kemudian akan mengelompokkan piksel-piksel yang memiliki kesamaan ciri spektral ke dalam gerombol yang unik melalui kriteria statistika yang ditentukan. Pengguna kemudian mengkombinasikan dan/atau mengubah label gerombol ke dalam kelas yang sesungguhnya.

Metode Klasifikasi yang berdasarkan Logika Samar sangat memperhatikan heterogenitas kondisi permukaan bumi. Sebagai variasi, teknik ini juga dapat dipadukan dengan metode-metode konvensional yang telah dideskripsikan di atas. Metode ini banyak didasari

kenyataan bahwa pada kondisi yang umum dijumpai di lapang, batas-batas kelas penutupan lahan tidak dapat dibatasi dengan tegas. Pada kondisi yang demikian, penggunaan metode klasifikasi konvensional yang menggunakan batas himpunan yang tegas menjadi kurang relevan.

Pada klasifikasi dan pelabelan citra penginderaan jauh, informasi yang direpresentasikan pada umumnya menganut paham hubungan satu-satu yaitu satu piksel mengarah pada satu kelas. Namun pada kenyataannya, sebuah piksel mungkin merepresentasikan data campuran berbagai kelas penutup lahan atau merepresentasikan pola yang kompleks yang sangat sulit dideskripsikan dalam satu kelas tunggal. Dengan demikian, metode ini memiliki peluang yang besar dalam proses kehilangan informasi yang selanjutnya dapat menurunkan akurasi klasifikasi atau ekstraksi informasi yang buruk. Metode hubungan satu-satu didasarkan atas teori himpunan klasik yang cocok untuk obyek-obyek yang dapat dideskripsikan secara persis oleh keanggotaan penuh pada sebuah himpunan. Namun demikian, banyak fenomena geografis alami tidak dapat dideskripsikan secara akurat.

Bedard (1987) menyatakan bahwa konsep ketidakpastian pada pengolahan citra digital berawal dari adanya penyederhanaan suatu kegiatan dan biasanya memiliki paradigma alur yang disebabkan oleh sejumlah hubungan antara sub kegiatan pada sistem pengolahan. Salah satu teknologi yang populer saat ini adalah kontrol pintar (intelligent control) yang dipandang sebagai kombinasi dari teori kontrol, riset operasi dan intelegensi buatan (artificial intelligence). Di antara teknologi baru yang berkembang di intelegensi buatan, logika samar merupakan teknologi yang paling populer (Jamshidi, 1993). Zadeh dalam Kosko (1992) menyatakan bahwa baik secara terpisah maupun secara bersama-sama, logika

samar dan jaringan syaraf (neural network) telah membantu memecahkan masalah-masalah dari proses kontrol dan pengolahan sinyal sampai diagnosis kesalahan dan optimisasi sistem. Tulisan ini mengulas tentang teknik klasifikasi citra dengan Logika Samar serta contoh hasilnya. Diharapkan hal ini dapat memberi penjelasan dan gambaran tentang teknik tersebut secara ringkas dan praktis bagi para peneliti yang sering melakukan klasifikasi citra.

2. TINJAUAN TEORI

2.1 Tinjauan Umum tentang Himpunan Klasik/Tegas

Didefinisikan X adalah himpunan obyek dengan karakteristik yang sama, yang anggotanya dinotasikan sebagai x. Elemen tersebut dapat berbentuk diskrit dan terhingga atau kontinu dan tak terhingga. Juga didefinisikan *cardinality number* n_x sebagai nilai total elemen dalam X. Sebuah himpunan A terdiri dari beberapa elemen dalam X; himpunan A adalah subset dari *universe* X. Jadi,

$x \in X : x$ anggota X(2-1)

$x \in A : x$ anggota A(2-2)

$x \notin A : x$ bukan anggota A(2-3)

Untuk himpunan A dan B pada X, akan didapatkan

$A \subset B$: - A termasuk dalam B(2-4)
 - $\forall x \in A$ maka $x \in B$

$A \subseteq B$: - A sepenuhnya termasuk dalam B(2-5)

$A = B$ maka $A \subseteq B$ dan $B \subseteq A$ (2-6)

2.2 Tinjauan Umum tentang Himpunan Samar

Ross (1993) menyatakan hanya ada beberapa perbedaan antara teori himpunan klasik dengan himpunan samar. Teori himpunan samar sendiri dapat dipandang sebagai teori yang mendasar yang lebih luas dari teori himpunan klasik yaitu teori himpunan

samar memperhatikan nilai tak terhingga dari tingkat keanggotaan (degree of membership) pada sebuah himpunan antara nilai 0 dan 1 yang terdapat pada teori himpunan klasik. Dengan kata lain, himpunan klasik dapat dianggap sebagai bentuk yang terbatas dari himpunan samar.

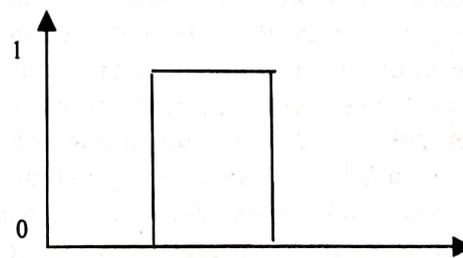
Pada himpunan klasik, transisi antara keanggotaan atau bukan pada suatu himpunan memiliki definisi sangat jelas. Di lain pihak, pada himpunan samar transisi bisa dalam bentuk gradual. Dengan demikian, batas dari himpunan samar tidak terekspresikan secara jelas (*vogue*) dan *ambiguous*.

Selanjutnya, himpunan samar dapat dipandang sebagai himpunan yang berisi elemen yang memiliki tingkat keanggotaan yang bervariasi. Paham ini bertolak belakang dengan himpunan klasik karena anggota dari himpunan klasik tidak akan menjadi anggota kecuali keanggotaan elemen tersebut penuh (nilai keanggotaannya bernilai 1). Elemen dalam himpunan samar dapat menjadi anggota dari himpunan samar lain pada *universe* yang sama (Ross, 1993).

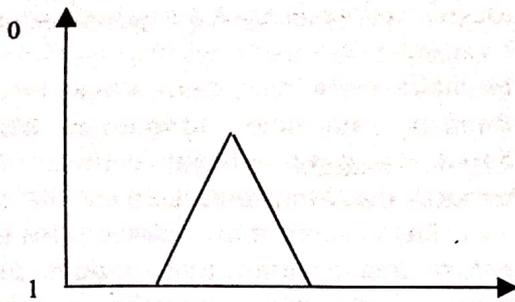
$\mu_A(x) \in [0,1]$ (2-7)

$A = (x, \mu_A(x) | x \in X)$ (2-8)

Himpunan samar dinotasikan dengan tanda tilde (~) seperti pada notasi di atas. Fungsi keanggotaan kedua himpunan disajikan pada gambar berikut:



Himpunan Klasik



Himpunan Samar

Gambar 2-1: Fungsi keanggotaan kedua himpunan

2.3 Konsep Ketidakpastian

Bedard (1987) telah mengidentifikasi adanya ketidakpastian dalam proses pengolahan citra yang ditinjau dari dua aspek. Pertama penyebab ketidakpastian selalu dikaitkan pada proses pembentukan model yang didefinisikan sebagai pendekatan dari realitas yang ada. Kedua ketidakpastian yang lain berasal dari manusia yang memiliki informasi beragam dan bersifat subyektif. Bentuk atau jenis dari ketidakpastian sendiri adalah ketidakjelasan (kekaburan) proses identifikasi pada proses klasifikasi, keterbatasan dalam penilaian kuantitatif, keterbatasan dalam penilaian kualitatif dan *meta-uncertainty* yang mengarah pada tingkat ketidakpastian

Model pendekatan dalam pengelolaan ketidakpastian dapat dilakukan dengan mereduksi ketidakpastian dan menyerap atau memotong peluang ketidakpastian. Reduksi ketidakpastian dapat dilakukan dengan menurunkan tingkat *fuzziness* (kesamaran) pada saat mengidentifikasi suatu obyek atau meningkatkan akurasi dan posisi pada saat mendeskripsikan suatu obyek. Sedangkan penyerapan ketidakpastian dapat dilakukan dengan meningkatkan akurasi alat atau melakukan standarisasi sehingga kesalahan alat atau metode maupun model yang digunakan dapat diprediksikan.

2.4 Logika Samar

Pada sistem samar, biasanya diasumsikan pasangan masukan-keluaran memiliki struktur dari *fuzzy if-then rules* yang memiliki kaitan dengan variabel samar. Tipe variabel ini memfasilitasi interpolasi dengan memberikan kisaran peluang yang cocok antara masukan dengan *rule*. Pada umumnya, sistem samar bekerja baik jika pengalaman digunakan untuk mengartikulasikan *fuzzy if-then rules*. Jika tidak dapat dilakukan, teknik jaringan saraf dibutuhkan untuk membangun *rules*. Metodologi ini dikenal dengan nama sistem samar adaptif (Adaptive Fuzzy Systems). Pengetahuan tentang prinsip logika samar dapat lebih dipahami dengan membandingkan himpunan samar (*fuzzy set*) dengan himpunan klasik (*crisp set*) yang akan diuraikan pada bagian berikut (Jamshidi, 1993).

3. PENERAPAN METODE LOGIKA SAMAR DALAM KLASIFIKASI CITRA

3.1 Metode Klasifikasi Tegas (*Hard Classifier*)

Pada metode ini, algoritma klasifikasi biasanya dikelompokkan menjadi dua kelompok besar yaitu algoritma terbimbing (*supervised*) dan tak terbimbing (*unsupervised*). Pada makalah ini, masing-masing kelompok hanya akan diambil satu contoh saja untuk mengilustrasikan ciri dari metode klasifikasi tegas. Algoritma terbimbing akan diwakili oleh algoritma kemiripan maksimum (*maximum likelihood*) dan algoritma tak terbimbing diwakili oleh algoritma gerombol.

3.1.1 Algoritma kemiripan maksimum

Sebelum menjalankan algoritma klasifikasi, seringkali pengguna menentukan training area yang digunakan untuk melihat ciri-ciri statistika masing-masing calon kelas. Mengingat data penginderaan jauh pada umumnya berkanal jamak, maka untuk setiap

contoh piksel akan didapatkan sebuah vektor pengukuran sebagai berikut:

$$X_c = [BV_{ij1}, BV_{ij2}, \dots, BV_{ijk}] \dots \dots \dots (3-1)$$

dengan BV_{ijk} menyatakan nilai piksel (*brightness value*) untuk piksel ke- i,j dan pada band ke- k . Selanjutnya akan didapatkan pula vektor pengukuran rata-rata untuk setiap kelas sebagai berikut:

$$M_c = [\mu_{c1}, \mu_{c2}, \dots, \mu_{ck}] \dots \dots \dots (3-2)$$

dengan μ_{ck} merepresentasikan nilai rata-rata dari data yang diperoleh untuk kelas c pada band k . Selain itu bisa didapatkan pula matrik kovarian pada setiap kelas c sebagai berikut:

$$V_c = V_{ckl} = \begin{bmatrix} Cov_{c11} & Cov_{c12} & \dots & Cov_{c1n} \\ Cov_{c21} & Cov_{c22} & \dots & Cov_{c2n} \\ \dots & \dots & \dots & \dots \\ Cov_{cn1} & Cov_{cn2} & \dots & Cov_{cnn} \end{bmatrix} \dots \dots \dots (3-3)$$

dengan Cov_{ckl} adalah kovarian dari kelas c dari band k sampai l . Pada umumnya notasi di atas dapat disingkat menjadi V_c .

Menurut Wang (1990) aturan keputusan dalam algoritma kemungkinan maksimum akan bertindak sebagai penentu penggolongan setiap piksel ke dalam kelas yang bersesuaian yaitu dengan menempatkan piksel atas dasar kemiripan atau kemungkinan yang paling tinggi. Hal ini mengasumsikan bahwa statistik dari data *training set* untuk setiap kelas dan setiap band menyebar secara normal (Gaussian). Aturan keputusan pada algoritma ini dapat dinotasikan sebagai berikut:

Tentukan X ada dalam kelas c , jika dan hanya jika:

$$P_c \geq P_i, i \text{ adalah kelas ke-} 1, 2, \dots, m \dots (3-4)$$

$$P_c = \{ -0.5 \log_e [\det(V_c)] \} - [0.5(X-M_c)^T V_c^{-1} (X-M_c)] \dots \dots \dots (3-5)$$

dengan $\det(V_c)$ adalah determinan dari matriks kovarian V_c . Untuk mengklasifikasikan vektor X dari sebuah piksel ke dalam suatu kelas, aturan keputusan akan menghitung nilai P_c untuk setiap

kelas. Barulah kemudian piksel tersebut akan dikelompokkan ke dalam kelas yang memiliki nilai maksimum.

Persamaan di atas mengasumsikan bahwa setiap kelas memiliki kemungkinan kejadian yang sama pada permukaan bumi. Kejadian pada data penginderaan jauh menunjukkan bahwa ada kemungkinan kejadian yang lebih tinggi bagi suatu kelas daripada kelas yang lain. Sebagai ilustrasi, bila kelas air mendominasi suatu citra, maka dapat diharapkan bahwa akan semakin banyak piksel yang akan dikelaskan sebagai air. Dengan demikian, dimungkinkan untuk memasukkan informasi *apriori* pada pengambilan keputusan dalam klasifikasi. Pemasukan informasi ini dapat dilakukan dengan pembobotan setiap kelas c dengan kemungkinan *apriori* a_c sehingga:

Tentukan X ada dalam kelas c , jika dan hanya jika:

$$P_c(a_c) \geq P_i(a_i), i \text{ adalah kelas ke-} 1, 2, \dots, m (3-6)$$

$$P_c(a_c) = \log_e(a_c) - \{ -0.5 \log_e [\det(V_c)] \} - [0.5(X-M_c)^T V_c^{-1} (X-M_c)] \dots \dots \dots (3-7)$$

Aturan keputusan Bayes di atas identik dengan aturan keputusan kemiripan maksimum, kecuali bahwa Bayes tidak mengasumsikan kesamaan kemungkinan pada setiap kelas.

3.1.2 Algoritma gerombol (*Clustering*)

Algoritma gerombol yang disajikan berikut ini beroperasi pada dua iterasi (*pass*). Pada iterasi pertama, algoritma membaca seluruh data dan secara sekuen membangun gerombol (kumpulan dari titik pada ruang spektral). Vektor rata-rata akan diasosiasikan dengan setiap gerombol. Pada iterasi kedua, metode klasifikasi jarak minimum (minimum distance to mean) digunakan pada seluruh data, piksel demi piksel pada rata-rata kelas yang terbentuk.

Pada iterasi pertama, algoritma membutuhkan masukan data seperti: jarak radius pada ruang spektral (R), jarak ruang spektral (C), Jumlah piksel

yang dievaluasi di antara penggabungan besar dari gerombol (N) dan Jumlah maksimum gerombol (Cmax). Pada kebanyakan perangkat lunak pengolahan citra penginderaan jauh, parameter ini dapat ditentukan secara default.

3.2 Metode Klasifikasi Samar (Soft Classifier)

Jensen (1996) menjabarkan proses yang dapat digunakan untuk mengaplikasikan metode klasifikasi samar. Proses pengumpulan data sampel (*training set data*) pada klasifikasi samar agak berbeda dengan teknik konvensional yang sering digunakan. Selain dapat mengambil sampel pada area yang homogen, pengguna dapat pula mengambil sampel pada area yang heterogen untuk lebih memahami kondisi lapangan atau membuat representasi alam yang lebih baik.

Partisi *feature space* tidak lagi sekedar mengelaskan pada kelas yang tersedia, tetapi lebih ke pembuatan model tingkat keanggotaan yang menyatakan bagaimana kedekatan suatu piksel yang sedang dianalisis pada vektor rata-ran kelas. Pada pemanfaatan data penginderaan jauh, partisi samar yang aktual adalah keluarga himpunan samar F_1, F_2, \dots, F_m pada X dimana setiap x adalah anggota X .

$$0 \leq f_{F_i}(x) \leq 1 \dots \dots \dots (3-8)$$

$$\sum_{x \in X} f_{F_i} > 0 \dots \dots \dots (3-9)$$

$$\sum_{i=1}^m f_{F_i}(x) = 1 \dots \dots \dots (3-10)$$

dimana F_1, F_2, \dots, F_m merepresentasikan kelas spektral, X menyatakan semua piksel pada himpunan data, m adalah jumlah kelas contoh, x adalah vektor piksel dan f_{F_i} adalah fungsi keanggotaan dari himpunan samar F_i ($1 \leq i \leq m$).

$$P_i^*(x) = \frac{1}{(2\pi)^{N/2} |V_i^*|^{1/2}} \exp[-0.5(x - \mu_i^*)^T V_i^{*-1} (x - \mu_i^*)] \dots \dots \dots (3-15)$$

Selanjutnya partisi samar dapat dinyatakan dengan bentuk matriks sebagai berikut.

$$\begin{bmatrix} f_{F_1}(x_1) & f_{F_1}(x_2) & \dots & f_{F_1}(x_n) \\ f_{F_2}(x_1) & f_{F_2}(x_2) & \dots & f_{F_2}(x_n) \\ \dots & \dots & \dots & \dots \\ f_{F_m}(x_1) & f_{F_m}(x_2) & \dots & f_{F_m}(x_n) \end{bmatrix} \dots \dots (3-11)$$

dimana n adalah jumlah piksel dan x_i adalah vektor piksel ke- i .

Selanjutnya logika samar dapat diaplikasikan untuk menghitung rata-ran samar dan matriks kovarian seperti yang dideskripsikan oleh Wang (1990) sebagai berikut:

$$\mu_c^* = \frac{\sum_{i=1}^n f_c(x_i) x_i}{\sum_{i=1}^n f_c(x_i)} \dots \dots \dots (3-12)$$

dimana n adalah jumlah vektor pengukuran dari piksel contoh, f_c adalah fungsi keanggotaan dari kelas c , dan x_i adalah vektor pengukuran dari piksel contoh ($1 \leq i \leq n$). Sedangkan matrik kovarian samar dinotasikan sebagai berikut:

$$V_c^* = \frac{\sum_{i=1}^n f_c(x_i) (x_i - \mu_c^*) (x_i - \mu_c^*)^T}{\sum_{i=1}^n f_c(x_i)} \dots \dots (3-13)$$

Untuk mempartisi *fuzzy feature space*, fungsi keanggotaan harus didefinisikan untuk kelas c sebagai berikut:

$$f_c(x) = \frac{P_c^*(x)}{\sum_{i=1}^m P_i^*(x)} \dots \dots \dots (3-14)$$

dimana N adalah dimensi vektor piksel, m adalah jumlah kelas dan $1 \leq i \leq m$. Tingkat keanggotaan dari vektor piksel x tergantung dari posisi x pada ruang spektral.

4. UJI COBA DAN ANALISIS TEKNIK LOGIKA SAMAR TERHADAP DATA LANDSAT THEMATIC MAPPER (TM)

4.1 Penggunaan Jenis Citra

Contoh data yang digunakan pada makalah ini adalah Landsat TM dengan lokasi Vancouver Kanada. Landsat TM digunakan sebagai bahan kajian karena memiliki resolusi spasial yang relatif tinggi sehingga cocok untuk daerah tersebut di atas yang memiliki tingkat homogenitas yang tinggi.

Citra Landsat TM merupakan hasil rekaman sensor Thematic Mapper yang dipasang pada satelit Landsat 4 dan Landsat 5. Sistem TM meliputi lebar sapuan (*scanning*) sebesar 185 Km, direkam dengan tujuh saluran panjang gelombang yang terdiri dari tiga saluran panjang gelombang tampak, tiga saluran panjang gelombang infra merah dekat dan satu saluran panjang gelombang inframerah termal dengan resolusi 30 m untuk kanal 1-5 serta 7 dan 120 m untuk kanal 6.

4.2 Prosedur Klasifikasi Citra

Prosedur ringkas klasifikasi citra dengan teknik logika samar adalah sebagai berikut :

1. Lakukan koreksi geometri dan koreksi radiometrik yang digunakan untuk memperbaiki kesalahan yang terjadi pada saat data direkam.
2. Pembuatan sampel yang bertujuan untuk mendapatkan training area terbaik.

3. Ekstraksi dan evaluasi data sampel sehingga diperoleh parameter statistik seperti rata-rata, variansi dan menghitung korelasi antara training area yang ada.
4. Modifikasi data training, bila terdapat dua atau lebih sampel yang memiliki tingkat korelasi cukup tinggi.
5. Model klasifikasi yang digunakan kemiripan maksimum dengan pendekatan logika samar.
6. Uji klasifikasi data training untuk mengetahui tingkat ketelitian klasifikasi sampel area. Informasi yang dihasilkan berupa matrik korelasi yang menggambarkan kontribusi pixel dari setiap training area untuk masuk kelas yang diharapkan.
7. Klasifikasi citra bila hasil evaluasi data sampel area menunjukkan tingkat ketelitian yang memadai.

4.3 Data Hasil Uji Coba

4.3.1 File dan parameter training area

Kombinasi band yang digunakan ada tiga (band 5, 4, 3) dan jumlah training area ada 9. Sesuai dengan jenis-jenis objek yang dapat diidentifikasi pada citra. Tabel 4-1 menunjukkan jumlah piksel dari setiap training area dengan training area air laut mempunyai jumlah piksel yang terbesar dan training area awan yang mempunyai jumlah piksel yang terkecil. Tabel 4-2 merupakan parameter statistik training area. Untuk setiap kanal nilai statistik rata-rata dan simpangan baku tertinggi adalah kelas awan (kelas 8), sedangkan nilai statistik rata-rata dan simpangan baku terendah adalah kelas air laut (kelas 1).

Tabel 4-1: JUMLAH PIKSEL SETIAP TRAINING AREA

No. Training	Nama Training Area	Jumlah Piksel
1	Air laut	2.615
2	Jalan/parkir	430
3	Pemukiman	486
4	Tumbuhan lebat	333
5	Daerah gersang	443
6	Tanaman muda	165
7	Daerah subur	104
8	Awan	36
9	Bayangan awan	60

Sumber : Ross (1993)

Tabel 4-2: PARAMETER STATISTIK TRAINING AREA

Kls Training	Kls 1	Kls 2	Kls 3	Kls 4	Kls 5	Kls 6	Kls 7	Kls 8	Kls 9
Kanal 0									
Rataan	4,65	97,77	69,31	37,78	67,55	80,11	70,43	159,14	12,4
Simp.Baku	1,12	11,5	12,91	7,65	8,92	9,67	10,27	48,68	6
Kanal 1									
Rataan	9,45	52,8	46,62	48,37	51,77	70,82	71,96	115,07	19,77
Simp.Baku	0,57	4,84	8,33	5,03	4,92	6,53	13,92	28,63	5,79
Kanal 2									
Rataan	16,76	44,01	52,16	21,72	26,35	31,59	24,69	132,36	17,29
Simp.Baku	1,02	7,19	10,3	1,7	2,53	2,92	3,14	39,76	2,23
Kanal 3									
Rataan	22,01	34,24	42,06	23	24,69	29,41	25,67	105,57	19,58
Simp.Baku	0,78	4,16	6,81	0,99	1,46	1,83	1,83	28,6	1,74

Sumber : Ross (1993)

4.3.2 Elemen matrik kovarian tiap kelas training area

Berikut ini disajikan matrik kovarian untuk setiap kelas training area.

(1) Kelas Air Laut

$$\begin{bmatrix} 1,2628 & 0,0650 & 0,1181 & 0,0817 \\ 0,0650 & 0,3198 & 0,1167 & 0,0649 \\ 0,1181 & 0,1167 & 1,0428 & 0,2431 \\ 0,0817 & 0,0049 & 0,2431 & 0,6140 \end{bmatrix}$$

(2) Kelas Jalan

$$\begin{bmatrix} 132,7006 & 36,0878 & 58,9903 & 28,6117 \\ 36,0878 & 23,4803 & 24,4187 & 14,4574 \\ 58,9903 & 24,4187 & 51,7988 & 28,1641 \\ 28,6117 & 14,4574 & 28,1641 & 17,3868 \end{bmatrix}$$

(3) Kelas Pemukiman

$$\begin{bmatrix} 167,0998 & 92,2259 & 92,8463 & 60,5955 \\ 92,2259 & 23,4803 & 49,6558 & 33,2813 \\ 92,8463 & 49,6558 & 106,4395 & 69,0754 \\ 60,5955 & 33,2813 & 69,0754 & 46,3358 \end{bmatrix}$$

(4) Kelas Tumbuhan Lebat

$$\begin{bmatrix} 58,7221 & 23,1259 & 8,9731 & 4,6725 \\ 23,1259 & 25,4411 & 3,6085 & 2,7797 \\ 8,9731 & 3,6085 & 2,8959 & 1,1746 \\ 4,6725 & 2,7797 & 1,1746 & 0,9773 \end{bmatrix}$$

(5) Kelas Daerah Gersang

$$\begin{bmatrix} 79,7614 & 26,0175 & 16,2362 & 7,2974 \\ 26,0175 & 24,2563 & 4,9416 & 3,9202 \\ 16,2362 & 4,9416 & 6,4322 & 2,7862 \\ 7,2974 & 3,9202 & 2,7862 & 2,1355 \end{bmatrix}$$

(6) Kelas Tanaman Muda

94,2694	46,1048	24,4896	14,1745
46,1048	42,9591	13,6579	9,9986
24,4896	13,6579	8,5642	4,6572
14,1745	9,9986	4,6572	3,3866

(7) Kelas Daerah Subur

106,8340	112,1012	12,9912	11,9599
112,1012	196,1328	2,8422	11,5735
12,9912	2,8422	9,9982	4,1042
11,9599	11,5735	4,1042	3,3929

(8) Kelas Awan

2457,1640	1405,9894	1902,6138	1337,3598
1405,9894	850,1429	1172,1217	834,8466
1902,6138	172,1217	1639,4974	1174,6772
1337,3598	834,8466	1174,6772	848,5503

(9) Kelas Bayangan Awan

36,7549	31,9748	6,8183	5,9557
31,9748	34,1804	5,6640	4,7961
6,8183	5,6640	5,0621	3,1241
5,9557	4,7961	3,1241	3,0933

4.3.3 Hasil klasifikasi

Citra hasil klasifikasi dengan metode konvensional dapat dilihat pada Gambar 4-1, citra hasil klasifikasi dengan metode fuzzy logic dengan apriori dapat dilihat pada Gambar 4-2 dan citra hasil klasifikasi dengan metode fuzzy logic tanpa apriori dapat dilihat pada Gambar 4-3 sedangkan informasi piksel hasil klasifikasi metode konvensional dapat dilihat pada Tabel 4-3, informasi piksel hasil klasifikasi metode fuzzy logic dengan apriori dapat dilihat pada Tabel 4-4 dan informasi piksel hasil klasifikasi metode fuzzy logic tanpa apriori dapat dilihat pada Tabel 4-5.



Gambar 4-1: Contoh citra hasil klasifikasi dengan metode konvensional (Ross 1993)

Tabel 4-3: INFORMASI PIKSEL HASIL KLASIFIKASI METODE KONVENSIONAL

Kelas	Nama Kelas	Jumlah Piksel	Persentase Piksel
1	Air laut	24.301	9,27
2	Jalan/parkir	16.292	6,21
3	Pemukiman	27.907	10,65
4	Tumbuhan lebat	69.471	26,5
5	Daerah gersang	67.359	25,7
6	Tanaman muda	8.361	3,19
7	Daerah subur	35.246	13,45
8	Awan	636	0,24
9	Bayangan awan	8.408	3,21
10	Kelas <i>overlap</i>	3.383	1,29
11	Tak Terklasifikasi	780	0,3

Sumber : Ross (1993)



Gambar 4-2: Contoh citra hasil klasifikasi dengan metode logika samar dengan apriori (Ross, 1993)

Tabel 4-4 :INFORMASI PIKSEL HASIL KLASIFIKASI DENGAN METODE LOGIKA SAMAR DENGAN APRIORI

Kelas	Nama Kelas	Jumlah Piksel	Persentase Piksel
1	Air laut	24.521	9,35
2	Jalan/parkir	16.135	6,16
3	Pemukiman	28.068	10,71
4	Tumbuhan lebat	68.622	26,18
5	Daerah gersang	73.201	27,92
6	Tanaman muda	9.224	3,52
7	Daerah subur	28.752	10,97
8	Awan	618	0,24
9	Bayangan awan	8.866	3,38
10	Kelas <i>overlap</i>	3.360	1,28
11	Tak terklasifikasi	777	0,3

Sumber : Ross (1993)



Gambar 4-3: Citra hasil klasifikasi metode fuzzy logic tanpa apriori (Ross, 1993)

Tabel 4-5: INFORMASI PIKSEL HASIL KLASIFIKASI DENGAN METODE FUZZY LOGIC TANPA APRIORI

Kelas	Nama Kelas	Jumlah Pikel	Persentase Pikel
1	Air laut	24.338	9,28
2	Jalan/parkir	16.368	6,24
3	Pemukiman	28.746	10,97
4	Tumbuhan lebat	71.281	27,19
5	Daerah gersang	70.197	26,78
6	Tanaman muda	8.685	3,31
7	Daerah subur	29.245	13,45
8	Awan	666	0,25
9	Bayangan awan	8.330	3,18
10	Kelas <i>overlap</i>	3.504	1,34
11	Tak terklasifikasi	784	0,3

Sumber : Ross (1993)

Dari hasil klasifikasi menggunakan metode Logika Samar dengan apriori diperoleh peningkatan jumlah piksel untuk kelas air laut, pemukiman, daerah gersang dan tanaman muda dibandingkan dengan klasifikasi metode konvensional, sedangkan untuk klasifikasi menggunakan metode Logika Samar tanpa apriori terdapat peningkatan jumlah piksel untuk kelas air laut, jalan/parkir, pemukiman, tumbuhan lebat, daerah gersang, tanaman muda dan awan. Dari sini terlihat bahwa klasifikasi dengan menggunakan metode Logika Samar tanpa apriori dapat mengakibatkan peningkatan jumlah piksel hampir di semua kelas, juga meningkatkan jumlah piksel kelas

yang tumpang tindih dan kelas yang tidak terkelaskan. Sedangkan untuk klasifikasi menggunakan metode Logika Samar dengan apriori diperoleh peningkatan jumlah piksel untuk beberapa kelas, tetapi untuk kelas yang tumpang tindih dan yang tidak terkelaskan jumlah pikselnya berkurang.

5. KESIMPULAN

Metode klasifikasi Logika Samar dengan apriori dapat meningkatkan jumlah piksel untuk suatu kelas dan di sisi lain mengurangi jumlah piksel untuk kelas yang lain sedemikian sehingga heterogenitas objek dapat

diakomodasi. Hal ini tidak dapat dilakukan oleh metode konvensional.

Contoh hasil klasifikasi citra Landsat TM menunjukkan bahwa dengan menggunakan metode Logika Samar masih dapat diusulkan kelas baru untuk mengatasi kelas yang tidak terkelaskan.

DAFTAR RUJUKAN

- Bedard, Y. 1987, *Uncertainties in Digital Image Processing*. Proceeding Auto Carto VIII. p. 175.
- Jamshidi, M. 1993, Introduction. in Jamshidi, M., N. Vadiie and T. J. Ross (eds.). *Fuzzy Logic and Control: Software and Hardware Applications*. Prentice Hall International Editions. Englewood Cliffs, New Jersey. p.397.
- Jensen, J. R. 1996, *Introductory Digital Image Processing: A Remote Sensing Perspective*. Second Edition. Prentice Hall. Upper Saddle River, New Jersey. p.316.
- Kosko, B. 1992, *Neural Networks and Fuzzy Systems: A Dynamical System Approach to Machine Intelligence*. Prentice Hall International Editions. Englewood Cliffs, New Jersey. p.449.
- Ross, T. J. 1993, *Set Theory – Classical and Fuzzy Sets*. in Jamshidi, M., N. Vadiie and T. J. Ross (eds.). *Fuzzy Logic and Control: Software and Hardware Applications*. Prentice Hall International Editions. Englewood Cliffs, New Jersey. p.397.
- Swain, P. H. and S. M. Davis. 1978, *Remote Sensing – The Quantitative Approach*. McGraw-Hill. New York. p.396.
- Wang, F. 1990, *Improving Remote Sensing Image Analysis through Fuzzy Information Representation*. *Photogrammetric Engineering and Remote Sensing*, Vol. 56, No. 8. p. 1163-1169.