

**LAPORAN PENELITIAN
DOSEN MUDA**



**STUDI BANDING METODE KLASIFIKASI
EXPLICIT FUZZY, FUZZY PARALLELEPIPED DAN
GAUSSIAN MAXIMUM LIKELIHOOD
PADA CITRA MULTISPEKTRAL DAERAH SAGULING**

**Oleh :
Dra. Lintang Patria M.Kom**

**DIBIYAI OLEH DIREKTORAT JENDERAL PENDIDIKAN TINGGI
DEPARTEMEN PENDIDIKAN NASIONAL
SESUAI DENGAN SURAT PERJANJIAN PELAKSANAAN HIBAH PENELITIAN
NOMOR: 003/SP2H/PP/DP2M/III/2007
TANGGAL 29 MARET 2007**

**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS TERBUKA
DESEMBER 2007**

**HALAMAN PENGESAHAN
LAPORAN HASIL PENELITIAN DOSEN MUDA**

1. Judul Penelitian : STUDI BANDING METODE KLASIFIKASI EXPLICIT FUZZY, FUZZY PARALLELEPIPED DAN GAUSIAN MAXIMUM LIKELIHOOD PADA CITRA MULTISPEKTRAL DAERAH SAGULING
2. Bidang Ilmu Penelitian : Pengolahan Citra
3. Ketua Peneliti
 a. Nama Lengkap dan Gelar : Dra Lintang Patria, M.Kom
 b. Jenis Kelamin : P
 c. NIP : 132052359
 d. Pangkat/Golongan : Penata / III/c
 e. Jabatan : Lektor
 f. Fakultas/Jurusan : FMIPA / Matematika
4. Jumlah Tim Peneliti : 1 (satu) orang
5. Lokasi Penelitian : Pusat Komputer, Universitas Terbuka
6. Bila penelitian ini merupakan peningkatan kerjasama kelembagaan sebutkan :
 a. Nama Instansi : -
 b. Alamat : -
7. Jangka Waktu Penelitian : 8 bulan
8. Biaya yang diperlukan : Rp 10.000.000,- (Sepuluh Juta Rupiah)

Jakarta, 10 Desember 2007

Mengetahui,
Dekan FMIPA UT


Dr. Yuni Tri Hewindati
NIP 131644274

Ketua Peneliti,


Dra. Lintang Patria, M.Kom
NIP 132052359

Menyetujui,
Ketua LPPM Universitas Terbuka


Drs. Agus Joko Purwanto, M.Si
NIP 132002049

RINGKASAN DAN SUMMARY

Permasalahan pada penelitian ini adalah bagaimana kinerja pengklasifikasi Explicit Fuzzy (EF), Fuzzy Parallelepiped (FP) dan Gaussian Maximum Likelihood (GML) pada daerah Saguling. Tujuan utama penelitian ini adalah membandingkan kinerja pengklasifikasi EF, GML dan FP pada aplikasi citra multispektral, agar dapat melakukan rekomendasi kapan EF, FP dan GML digunakan. Pengamatan kinerja dilakukan berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi. Penelitian ini dilakukan pada citra daerah Saguling. Citra yang digunakan adalah dari sistem sensor optik Landsat TM. Pemilihan sampel untuk pelatihan dan pengujian diperoleh dari nara sumber yaitu dari BPPT. Dilakukan ujicoba dengan berbagai jenis penggunaan band dan berbagai jenis prosentasi daerah pelatihan untuk melihat kinerja ketiga pengklasifikasi tersebut. Dari percobaan yang dilakukan pada daerah Saguling, dapat diambil beberapa kesimpulan yaitu :

1. Penggunaan semua band multispektral tidak menjamin hasil akurasi yang lebih baik dari penggunaan 2 band hasil PCT atau hasil seleksi band. Band band tersebut tidak selalu berkorelasi tinggi.
2. Pada umumnya nilai AP dan AU pengklasifikasi GML lebih tinggi dibandingkan dengan pengklasifikasi EF dan FP. Pengklasifikasi EF lebih baik dibandingkan dengan pengklasifikasi FP.
3. Nilai rata rata Δ_{max} EF lebih rendah dibandingkan dengan FP dan GML. Dengan demikian, pada daerah Saguling, EF lebih dapat menggeneralisasi permasalahan dibandingkan dengan FP dan GML.
4. Pada daerah Saguling, penambahan sampel memperbaiki pengenalan.
5. EF dan FP memerlukan waktu komputasi yang lebih lama dibandingkan dengan GML. Pada umumnya FP memerlukan waktu yang lebih lama dibandingkan dengan EF. Jika hanya mempergunakan 2 band hasil PCT atau seleksi, EF lebih cepat dibandingkan dengan FP dan GML.

PRAKATA

Puji syukur kami kepada Tuhan Yang Maha Esa atas selesainya penelitian yang berjudul “STUDI BANDING METODE KLASIFIKASI EXPLICIT FUZZY, FUZZY PARALLELEPIPED DAN GAUSIAN MAXIMUM LIKELIHOOD PADA CITRA MULTISPEKTRAL DAERAH SAGULING”.

Penelitian ini dibiayai oleh DIKTI dengan nomor 003/SP2H/PP/DP2M/III/2007 tanggal 29 MARET 2007

Saya mengucapkan penghargaan dan ucapan terima kasih kepada Ketua LPPM, seluruh staf LPPM, Dekan FMIPA dan seluruh rekan kerja yang telah memberikan kesempatan untuk melakukan penelitian ini.

Saya mengucapkan terima kasih kepada Kepala Pusat Komputer dan seluruh rekan di Pusat Komputer yang selalu memberikan semangat dalam melakukan penelitian ini. Akhirnya, saya berharap agar penelitian ini berguna bagi pembaca. Saya sadar bahwa penelitian ini masih jauh dari kesempurnaan, sehingga saran dan kritik tentang penelitian ini sangat saya harapkan. Terima kasih.

Jakarta, 10 Desember 2007

Peneliti,



Lintang Patria

NIP 132052359

DAFTAR ISI
LAPORAN AKHIR HASIL PENELITIAN DOSEN MUDA

LEMBAR IDENTITAS DAN PENGESAHAN.....	i
RINGKASAN DAN SUMMARY.....	ii
PRAKATA.....	iii
DAFTAR ISI.....	iv
DAFTAR TABEL.....	v
DAFTAR GAMBAR.....	vi
DAFTAR LAMPIRAN.....	viii
I. PENDAHULUAN.....	1
II. TINJAUAN PUSTAKA.....	4
III. TUJUAN DAN MANFAAT PENELITIAN.....	14
IV. METODE PENELITIAN.....	15
V. HASIL DAN PEMBAHASAN.....	22
VI. KESIMPULAN DAN SARAN.....	34
DAFTAR PUSTAKA.....	35
LAMPIRAN.....	36

Daftar Tabel

Tabel 2.1	Derajat keanggotaan pada crisp, statistik dan fuzzy	...5
Tabel 4.1	Jenis Kelas, Koordinat, Ukuran dan Jumlah Piksel Daerah Sampel	...17
Tabel 5.1.	Nilai Δ_{\max} pada daerah Saguling	...29
Tabel 5.2	Hasil ujicoba pada daerah Saguling	...30
Tabel 5.3	Waktu komputasi pada daerah Saguling	...30

Universitas Terbuka

Daftar Gambar

Gambar 2.1	Diagram Explicit Fuzzy	...6
Gambar 2.2	Skema Explisit Fuzzy untuk 2 band dan 3 kelas	...9
Gambar 4.1.	Citra asli daerah Saguling	...18
Gambar 4.2.	Skema rancangan eksperimen 1.	...19
Gambar 4.3.	Skema rancangan eksperimen 2.	...20
Gambar 4.4.	Skema rancangan eksperimen 3.	...20
Gambar 5.1	Grafik AP pada daerah pelatihan (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)	...22
Gambar 5.2	Grafik AP pada daerah pengujian (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)	...23
Gambar 5.3	Grafik AU pada daerah pelatihan (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)	...23
Gambar 5.4	Grafik AU pada daerah pengujian (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)	...24
Gambar 5.5	Waktu komputasi ujicoba pada daerah Saguling (sampel pelatihan 25% dan sampel pengujian 75%)	...25
Gambar 5.6	Nilai AP pada daerah pelatihan pada penggunaan semua band	...26
Gambar 5.7	Nilai AP pada daerah pengujian pada penggunaan semua band	...27
Gambar 5.8	Nilai AU pada daerah pelatihan pada penggunaan semua band	...27
Gambar 5.9	Nilai AU pada daerah pengujian pada penggunaan semua band	...28
Gambar 5.10	Nilai AP pada daerah pelatihan dengan mempergunakan berbagai jenis band dan sampel.	...31
Gambar 5.11	Nilai AU pada daerah pelatihan dengan mempergunakan berbagai jenis band dan sampel.	...32
Gambar 5.12	Nilai AP pada daerah pengujian dengan mempergunakan berbagai jenis band dan sampel.	...32

- Gambar 5.13 Nilai AU pada daerah pengujian dengan mempergunakan berbagai jenis band dan sampel. ...33
- Gambar 5.14 Waktu komputasi yang diperlukan pada penggunaan berbagai jenis band dan sampel. ...33

Universitas Terbuka

BAB I

PENDAHULUAN

I.1. Latar Belakang

Penginderaan jarak jauh sangat berguna dalam proses pengambilan keputusan suatu inventori dan evaluasi dari sumber alam. Tujuan utama dari penginderaan jarak jauh adalah untuk menghasilkan citra yang merupakan sekumpulan simbol atau warna yang merepresentasikan klasifikasi dari obyek, seperti hutan, laut, daerah pertanian, kota, jalan dan sebagainya. Aplikasi terbesar dari penginderaan jarak jauh adalah pemetaan (20% - 34%) dan pada kehutanan (25% - 28%). Aplikasi lain dari penginderaan jarak jauh adalah dalam pengembangan daerah seperti tata guna tanah, pertanian dan perikanan, geologi, pertambangan dan energi, perencanaan kota dan lokasi sumber air .

Penginderaan jarak jauh telah digunakan di Indonesia untuk mendukung program pengolahan sumber daya alam sejak Landsat-1 (ERTS -1) diperkenalkan pada tahun 1972. Citra multispektral dan foto udara telah dioperasikan selama lebih dari dua dekade. Selain foto udara, citra lansat TM dan SPOT telah dengan luas dipergunakan di Indonesia.

Pada umumnya teknik klasifikasi yang sering digunakan adalah metode Gaussian Maximum Likelihood (GML) yang mempunyai performansi yang baik . Metode GML merupakan metode utama pada paket pengolahan citra penginderaan jarak jauh (inderaja) seperti ERDAS dan ER Mapper dan sering dipergunakan sebagai pembanding didalam banyak penelitian mengenai pengklasifikasian citra digital. Pengklasifikasian tersebut cocok digunakan untuk citra inderaja sensor optik karena citra tersebut mempunyai kelas obyek yang distribusi tingkat keabuannya mendekati model Gaussian. Namun metode GML tersebut berdasar pada *hard* atau *crisp classification* ; satu piksel menjadi anggota satu kelas. Dengan kata lain, suatu piksel adalah anggota suatu kelas tertentu dan bukan anggota suatu kelas yang lain. Cara berfikir semacam ini tidak merepresentasikan langkah yang baik jika masalah yang dihadapi adalah daerah yang *mixed* (bercampur). Dilain pihak, klasifikasi yang berdasarkan pada pendekatan *fuzzy* menghitung kontribusi keanggotaan suatu piksel terhadap seluruh kelas. Prinsip *fuzzy* ini menyediakan informasi

yang lebih banyak dibandingkan dengan metode *hard classification* dan lebih mampu menangani uncertainty, sehingga pendekatan *fuzzy* diharapkan akan menghasilkan klasifikasi yang lebih baik. Beberapa metode pengklasifikasi citra yang berdasarkan pendekatan *fuzzy* adalah *Explicit Fuzzy* (EF) dan *Fuzzy Parallelepiped* (FP).

Penelitian ini dilakukan berdasarkan penelitian Farid Melgani dan Elena Console. Melgani telah membandingkan hasil klasifikasi EF dan GML untuk citra multispektral, dan Elena telah membandingkan hasil klasifikasi FP dan GML untuk citra multispektral. Menurut teori, umumnya pengklasifikasi *fuzzy* memerlukan waktu komputasi yang lebih lama daripada pengklasifikasi *crisp*, terutama karena penghitungan keanggotaan kelasnya. Namun hasil penelitian Farid Melgani menunjukkan bahwa EF jauh lebih cepat daripada GML. Pada penelitian ini, akan dibandingkan kinerja ketiga metode tersebut dan waktu proses yang digunakan.

I.2. Permasalahan

Berdasarkan penjelasan pada bagian pendahuluan, maka masalah pada penelitian ini adalah mengetahui bagaimana kinerja ketiga pengklasifikasi tersebut pada daerah Saguling. Hipotesis yang mendasari penelitian ini adalah bahwa pengklasifikasi EF dan FP memerlukan waktu yang lebih lama, dengan hasil klasifikasi yang lebih baik dibandingkan dengan GML. Pengujian hipotesis tersebut berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi.

I.3. Tujuan Penelitian

Tujuan utama penelitian ini adalah : Membandingkan kinerja pengklasifikasi EF, GML dan FP pada aplikasi citra multispektral, agar dapat melakukan rekomendasi kapan EF, FP dan GML digunakan. Pengamatan kinerja dilakukan berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi.

I.4. Daerah penelitian

Berdasarkan data yang tersedia, studi kasus dilakukan pada citra daerah Saguling. Citra yang digunakan adalah dari sistem sensor optik Landsat TM. Pemilihan sampel untuk pelatihan dan pengujian diperoleh dari nara sumber yaitu dari BPPT.

I.5. Metodologi

Metodologi penelitian ini adalah sebagai berikut :

1. Melakukan studi literatur pengklasifikasi yang potensial untuk citra multispektral yaitu EF, FP dan GML.
2. Menggunakan sebuah aplikasi perangkat lunak (dalam Matlab) yang dapat dipergunakan sebagai alat eksperimen dalam proses klasifikasi citra.
3. Melakukan ujicoba terhadap citra sensor optik yang digunakan.
4. Melakukan analisis terhadap hasil klasifikasi citra dengan kinerja pembandingan AP, AU serta waktu komputasi.

I.6. Kontribusi Penelitian

Kontribusi utama dari penelitian ini adalah :

1. Menerapkan metode klasifikasi multispektral yang potensial dengan pendekatan fuzzy dan statistik.
2. Menyempurnakan hasil penelitian yang telah dilakukan oleh Farid Melgani dan Elena Console.

I.7. Sistematika Penulisan

- Bab I : Pendahuluan
Bab II : Tinjauan Pustaka
Bab III : Tujuan dan Manfaat Penelitian
Bab IV : Metode Penelitian
Bab V : Hasil dan Pembahasan
Bab VI : Kesimpulan dan Saran

BAB II

TINJAUAN PUSTAKA

II.1. KONSEP DASAR FUZZY

Uncertainty dan *fuzzy* model

Uncertainty (ketidaktentuan) dalam suatu model matematika adalah merupakan suatu keadaan yang tidak tentu (tidak terdefinisi secara jelas) dan dapat mempengaruhi pemilihan sebuah model. Ada beberapa hal yang dapat menyebabkan timbulnya *uncertainty* dalam model matematika, antara lain adalah :

- (i) pengukuran yang tidak akurat
- (ii) kejadian kejadian acak
- (iii) deskripsi yang tidak jelas.

Uncertainty dapat timbul dengan cara seperti ini, misalkan terdapat suatu pertanyaan “Apakah si X tingginya mendekati 2 meter?”. Jika diberikan fungsi $h(x)$ yang menyatakan tinggi seseorang, maka pendekatan *crisp* akan memberikan kesimpulan bahwa si X tingginya mendekati 2 meter jika dan hanya jika $h(x) = 2$. μ_1 yang dihasilkan oleh pendekatan *crisp* hanya bernilai 1 jika $h(x) = 2$ dan bernilai 0 untuk $h(x) \neq 2$. Pendekatan statistik dengan tingkat probabilitas 0,95% akan memberikan kesimpulan bahwa si X mempunyai ketinggian mendekati 2 meter jika $h(x) = 2 \pm 0,005$ atau $h(x) \in [1,995; 2,005]$. Y yang mempunyai tinggi badan $h(y) = 2,0051$ meter atau $h(y) = 1,990$ meter akan disisihkan. Dengan kata lain, kita ditekankan dengan pendekatan statistik untuk menyimpulkan bahwa Y tingginya tidak mendekati 2 meter. μ_2 yang dihasilkan oleh pendekatan statistik hanya bernilai 1 jika $h(x) = 2 \pm 0,005$ dan bernilai 0 untuk orang yang tingginya 1,990 meter. Pendekatan *fuzzy*, yang mempergunakan *grade of membership* (derajat keanggotaan) lebih luwes dalam memberikan kesimpulan apakah seseorang mempunyai tinggi yang mendekati 2 meter. Diberikan suatu kriteria, terdapat beberapa μ_3 yang harus sesuai dengan kebutuhan kita. Sebagai contoh, kita bisa mendefinisikan model *fuzzy* diskrit seperti berikut:

$$\mu_3 = \begin{cases} 1 & \text{jika } 1,995 \leq h(x) \leq 2,005 \\ 0,95 & \text{jika } 1,990 \leq h(x) < 1,995 \\ \dots & \\ 0,05 & \text{jika } 0,50 \leq h(x) < 1,00 \end{cases} \quad \dots(2.1)$$

Diberikan μ_3 , andaikan diketahui $\mu_3(x) = 0,95$, informasi apa yang diberikan ?

Kita dapat menduga bahwa X mendekati 2 meter, karena μ_3 pada (2.1) menggambarkan definisi kita pada nilai yang mendekati dua meter. Lagipula, kita mempunyai batas batas pada $h(x)$. Dan akhirnya, dalam model ini kita mempunyai kapasitas untuk membuat keputusan kualitatif tentang tinggi relatif. Sehingga dengan segera kita ketahui bahwa jika $\mu_3(x) = 0,65$ akan tertentu untuk x , dan jika $\mu_3(z) = 0,95$, maka Z lebih mendekati 2 meter dibanding Y . Untuk menetapkan perbedaan diantara tiga model ini dibentuk Tabel 2.1, yang menggambarkan perbandingan bilai nilai bagian dari μ_1, μ_2, μ_3 pada titik titik yang berbeda dalam S . Perhatikan kedua tipe dan kuantitas informasi dalam kolom pada Tabel 2.1. kelihatannya cukup adil untuk menyatakan bahwa model *fuzzy* (pada kolom 3) lebih memaksimumkan informasi yang terisi tentang proses yang direpresentasikan, dan konsekuensinya, dan mengoptimalkan kemampuan kita untuk memanfaatkan model sebagai pembantu pengambilan keputusan.

Tabel 2.1. Derajat keanggotaan pada crisp, statistik dan fuzzy.

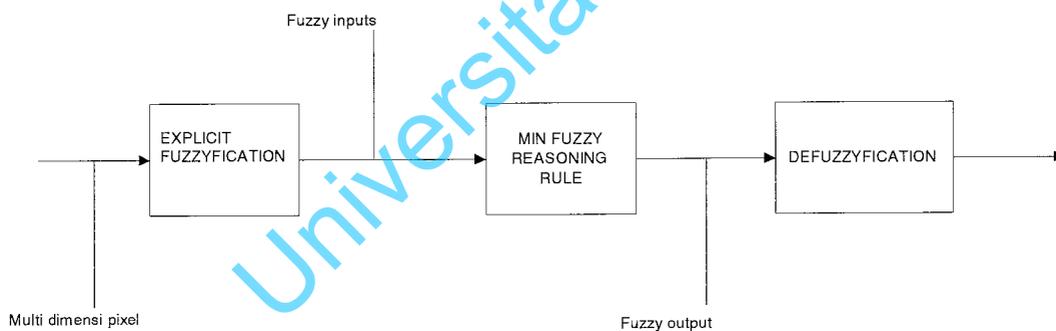
	tinggi	μ_1	μ_2	μ_3
X	$h(x) = 2,000$	1	1	1
Y	$h(y) = 1,997$	0	1	1
Z	$h(x) = 1,990$	0	0	0,95

Dengan kata lain, fuzzy menyediakan cara yang paling berguna untuk mendefinisikan suatu nilai dengan menggambarkan pada μ_3 , yang rata rata mendekati dua meter.

II.2. PENGKLASIFIKASI EXPLICIT FUZZY

Kebanyakan metode yang sering dipergunakan dalam penginderaan jarak jauh berdasarkan prinsip “satu piksel – satu kelas”. Dengan kata lain, suatu piksel merupakan anggota suatu kelas, atau bukan anggota suatu kelas. Logika ini tidak merepresentasikan langkah yang baik jika berhubungan dengan data yang secara alami bercampur atau bersifat heterogen. Suatu pendekatan *fuzzy*, dimana *fuzzy* mengasumsikan bahwa “satu piksel – beberapa kelas” menyediakan informasi yang lebih akurat dan tidak sama dengan metode *hard* atau *crisp classification*.

Klasifikasi dengan mempergunakan pendekatan *fuzzy* menjadi sangat menarik karena kemampuannya dalam menyediakan informasi yang berguna dalam penginderaan jarak jauh. Penelitian ini menggambarkan metode *explicit fuzzy* yang bisa dijabarkan dalam tiga langkah yaitu *explicit fuzzyfication*, *MIN fuzzy reasoning rule* dan *defuzzyfication*.



Gambar 2.1 Diagram Explicit Fuzzy

A. Proses Explicit Fuzzyfication

Proses pada *explicit fuzzyfication* adalah untuk mendapatkan estimasi dari kontribusi kelas pada setiap band dengan mengasumsikan distribusi Gaussian dari suatu kelas. *Domain fuzzy* terdiri dari beberapa *fuzzy set* yang merepresentasikan band, dan setiap *fuzzy set* (band) mengandung *fuzzy subset* yang merepresentasikan kelas. Setiap *fuzzy*

subset (kelas j), pada suatu band n didefinisikan oleh fungsi keanggotaan $f_{n,j}(x_n)$

dimana x_n adalah nilai keabuan pixel \underline{X} pada band n . Pixel \underline{X} pada dimensi N adalah

$$\underline{X} = [x_1, x_2, \dots, x_n, \dots, x_N]^T \quad \dots(2.2)$$

dimana N adalah band.

Fungsi keanggotaan disesuaikan dengan distribusi Gaussian karena distribusi tersebut merepresentasikan model distribusi yang secara umum baik dan mempunyai biaya komputasi yang minimal.

Mean dan standart deviasi dipergunakan untuk mendefinisikan membership function dari suatu piksel. Mean (μ) dari *signature* kelas merepresentasikan piksel yang ideal dari suatu kelas, yaitu suatu piksel yang jelas termasuk dalam suatu kelas tertentu.

Standart deviasi (τ) dari *signature* kelas akan menentukan panjang dari *fuzzy subset*.

Fungsi keanggotaan dari kelas j pada band n adalah

$$f_{n,j}(x_n) = \exp\left(-\frac{(x_n - \mu_{n,j})^2}{2\tau_{n,j}^2}\right) \quad \dots(2.3)$$

dimana $\mu_{n,j}$ adalah mean dari kelas j band n ,

dan $\tau_{n,j}$ adalah standart deviasi pada kelas j band n .

$$j = 1, \dots, J ; n = 1, \dots, N$$

Proses *fuzzyfication* digambarkan pada Gambar 2.2, menghitung derajat keanggotaan untuk suatu piksel untuk seluruh kelas j dan band n dengan mempergunakan fungsi keanggotaan yang didefinisikan dengan mempergunakan distribusi Gaussian dan ekstraksi statistik. Kita mendapatkan matriks *fuzzy input* \underline{Fip} dengan order $N \times J$ dimana

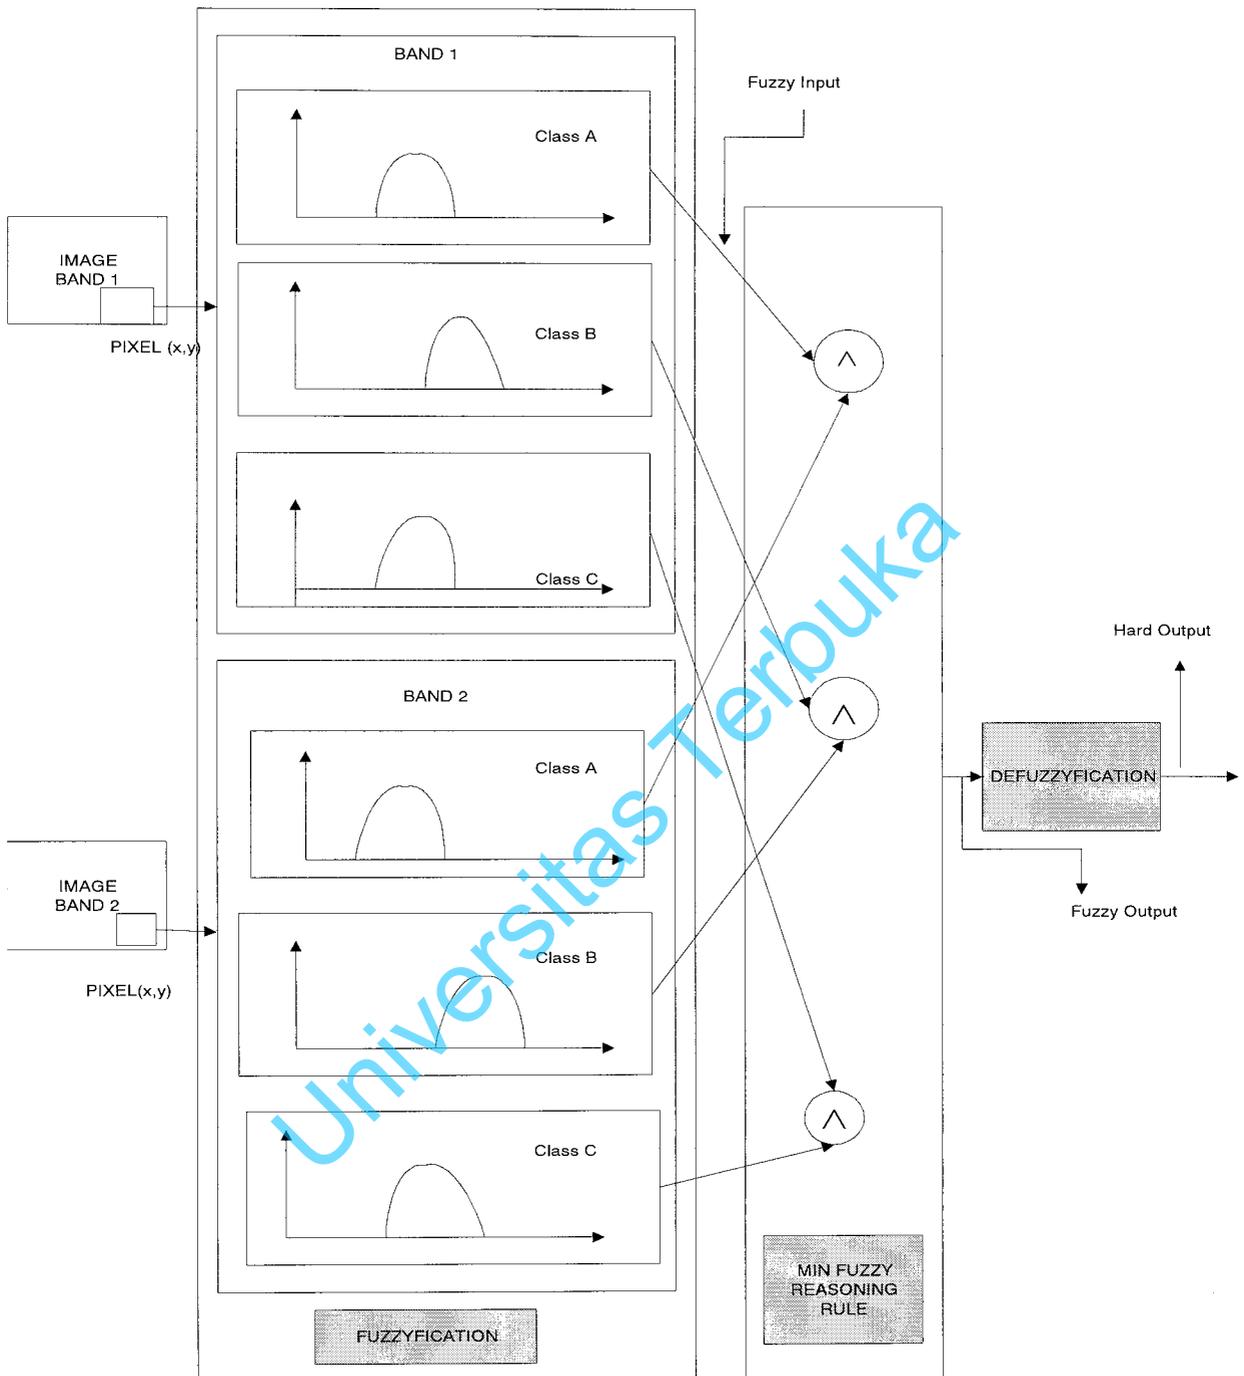
J adalah banyaknya kelas dan N banyaknya band. Untuk image yang multispektral, matriks *fuzzy input* \underline{Fip} dapat ditulis sebagai :

$$\underline{Fip} = \begin{bmatrix} f_{1,1}(x_1) & f_{1,2}(x_1) & \dots & f_{1,J}(x_1) \\ f_{2,1}(x_2) & f_{2,2}(x_2) & \dots & f_{2,J}(x_2) \\ \dots & \dots & \dots & \dots \\ f_{N,1}(x_N) & f_{N,2}(x_N) & \dots & f_{N,J}(x_N) \end{bmatrix} \quad \dots(2.4)$$

Sebagai contoh, untuk citra multispektral dengan 5 kelas dan 6 band, \underline{Fip} suatu piksel tertentu adalah

$$\underline{Fip} = \begin{bmatrix} 0,97 & 0,81 & 0,59 & 0,56 & 0,71 \\ 0,65 & 0,93 & 0,62 & 0,45 & 0,67 \\ 0,03 & 0,99 & 0,89 & 0,35 & 0,5 \\ 0 & 0,08 & 0,67 & 0,12 & 0 \\ 0 & 0,11 & 0,56 & 0 & 0 \\ 0 & 0,13 & 0,65 & 0 & 0 \end{bmatrix}$$

Universitas Terbuka



Gambar 2.2 Skema Explicit Fuzzy untuk 2 band dan 3 kelas

B. MIN Fuzzy Reasoning Rule

MIN Fuzzy Reasoning Rule diaplikasikan pada matriks *fuzzy input* yang dihasilkan pada langkah sebelumnya, untuk setiap kelas dengan derajat keanggotaan yang disediakan oleh *fuzzy set* (band) yang berbeda, dan mengambil derajat keanggotaan yang terkecil untuk merepresentasikan luas kelas pada piksel. Dengan mempergunakan operasi MIN yang digambarkan pada gambar 2.2 ke persamaan (2.9), kita mendapatkan primitif *fuzzy output* vektor

$$\underline{F}'_{op} = [F'_1(\underline{X}), F'_2(\underline{X}), \dots, F'_j(\underline{X})]^T \quad \dots(2.5)$$

dimana

$$F'_i(\underline{X}) = \min(f_{n,i}(x_n)) \quad \dots(2.6)$$

$$n = 1, \dots, N$$

Pada contoh diatas, operasi MIN pada \underline{F}_{ip} menghasilkan vektor

$$\underline{F}_{op} = [0 \quad 0,08 \quad 0,56 \quad 0 \quad 0]$$

C. DEFUZZYFICATION

Hard classification dapat dihasilkan dengan melakukan operasi MAX untuk merubah *fuzzy output* menjadi *hard output*. Kita akan memilih kelas yang bercampur pada piksel kelas J dengan luas terbesar sedemikian sehingga

$$\forall i \in 1, 2, \dots, N \text{ dan } i \neq j, F_j(\underline{X}) \geq F_i(\underline{X}) \quad \dots(2.7)$$

Pada contoh diatas, operasi MAX pada \underline{F}_{op} menghasilkan angka 0.56 (pada indeks 3) sehingga piksel tersebut diklasifikasikan sebagai kelas 3.

II.3. PENGKLASIFIKASI CITRA FUZZY PARALLELEPIPED

Langkah pertama pada pengklasifikasi Fuzzy Parallelepiped adalah mendiskripsikan fungsi keanggotaan untuk setiap kelas. Fungsi keanggotaan pada metode ini berbentuk trapesium, yang direpresentasikan oleh nilai minimum dan nilai maksimum *spectral signature* dari daerah yang diujicoba.

Fungsi keanggotaan didefinisikan sebagai berikut :

$$\text{Jika } \min_{j,n} < x_k < \max_{j,n} \text{ maka } \mu_j(x_k) = 1 \quad \dots(2.8)$$

$$\text{Jika } 0 < x_k < \min_{j,n} \text{ maka } \mu_j(x_k) = f_1(x_k) \quad \dots(2.9)$$

$$\text{Jika } \max_{j,n} < x_k < 255 \text{ maka } \mu_j(x_k) = f_2(x_k) \quad \dots(2.10)$$

Dimana

$\mu_j(x_k)$ = nilai fungsi keanggotaan piksel ke k pada kelas j

$\min_{j,n}$ = nilai minimum pada band ke n untuk kelas j

$\max_{j,n}$ = nilai maksimum pada band ke n untuk kelas j

$$f_1(x_k) = \frac{1}{\min_{j,n}} x_k$$

$$f_2(x_k) = \frac{1}{\max_{j,n} - 255} x_k - \left(\frac{255}{\max_{j,n} - 255} \right)$$

Untuk menentukan kelas dari suatu piksel tertentu, nilai fungsi keanggotaan piksel pada kelas ini dibandingkan pada seluruh band. Nilai keanggotaan akhir dari suatu piksel ke suatu kelas tertentu didapat dengan t-norm, dengan rumus

$$\mu_j(x_k) = \min_{n=1}^N \mu_{j,n}(x_k) \quad \dots(2.11)$$

Dimana

$$j = 1, \dots, J ; n = 1, \dots, N$$

Universitas Terbuka

II.4. PENGKLASIFIKASI CITRA GAUSSIAN MAXIMUM LIKELIHOOD

Jika $x = (x_1, x_2, \dots, x_N)^T$ menyatakan vektor pola dengan dimensi N , dan terdapat j kelas pola $\omega_1, \omega_2, \dots, \omega_j, j = 1, 2, \dots, J$. Jika setiap kelas diasumsikan mempunyai sebaran Gaussian, maka fungsi kepadatan Gaussian vektor vektor x dalam kelas pola ke j adalah mempunyai bentuk sebagai berikut :

$$p(x/\omega_j) = \frac{1}{(2\pi)^{B/2} |C_j|^{1/2}} \exp\left(-\frac{1}{2}(x - m_j)^T C_j^{-1} (x - m_j)\right), j = 1, 2, \dots, J \quad \dots(2.12)$$

Dengan m_j adalah mean vektor kelas ke j dan C_j adalah matriks kovariansi kelas ke j yang dinyatakan sebagai berikut :

$$m_j = \frac{1}{N_j} \sum_{x \in \omega_j} x \quad \dots(2.13)$$

dan

$$C_j = \frac{1}{N_j} \sum_{x \in \omega_j} xx^T - m_j m_j^T \quad \dots(2.14)$$

dimana N_j adalah vektor pola dari kelas ω_j dan $|C_j|$ adalah determinan dari matriks C_j .

Klasifikasi GML memasukkan pola x ke kelas ω_j bila nilai

$$d_j(x) = \ln P(\omega_j) - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad \dots(2.15)$$

Bernilai maksimum untuk j tertentu.

BAB III

TUJUAN DAN MANFAAT PENELITIAN

Tujuan Penelitian

Tujuan utama penelitian ini adalah : Membandingkan kinerja pengklasifikasi EF, GML dan FP pada aplikasi citra multispektral, agar dapat melakukan rekomendasi kapan EF, FP dan GML digunakan. Pengamatan kinerja dilakukan berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi.

Tujuan yang lebih terperinci adalah :

1. Mengetahui kinerja EF, FP dan GML jika menggunakan semua band dan jika hanya mempergunakan sebagian band hasil reduksi ataupun seleksi ciri.
2. Mengetahui kinerja EF, FP dan GML pada berbagai jenis prosentase daerah pelatihan.
3. Mengetahui tingkat generalisasi EF, FP dan GML.

Manfaat Penelitian

Manfaat utama dari penelitian ini adalah :

1. Menerapkan metode klasifikasi multispektral yang potensial dengan pendekatan fuzzy dan statistik.
2. Menyempurnakan hasil penelitian yang telah dilakukan oleh Farid Melgani dan Elena Console.
3. Memberikan rekomendasi penggunaan klasifikasi.

BAB IV

METODE PENELITIAN

IV.1. RINCIAN METODE PENELITIAN

Metodologi penelitian ini adalah sebagai berikut :

1. Melakukan studi literatur pengklasifikasi yang potensial untuk citra multispektral yaitu EF, FP dan GML.
2. Menggunakan sebuah aplikasi perangkat lunak (dalam Matlab) yang dapat dipergunakan sebagai alat eksperimen dalam proses klasifikasi citra berdasarkan pendekatan EF.
3. Menggunakan sebuah aplikasi perangkat lunak (dalam Matlab) yang dapat dipergunakan sebagai alat eksperimen dalam proses klasifikasi citra berdasarkan pendekatan FP.
4. Menggunakan sebuah aplikasi perangkat lunak (dalam Matlab) yang dapat dipergunakan sebagai alat eksperimen dalam proses klasifikasi citra berdasarkan pendekatan GML.
5. Melakukan ujicoba terhadap citra sensor optik yang digunakan.
6. Melakukan analisis terhadap hasil klasifikasi citra dengan kinerja pembandingan AP, AU serta waktu komputasi.

IV.2. PARAMETER KINERJA UJICoba PADA CITRA SENSOR

Pengukuran kinerja dilakukan dengan menggunakan *confusion matrix*. Misalkan jumlah kelas yang ada pada suatu citra adalah 5 kelas. *Confusion matrix* berbentuk seperti berikut :

Sampel	Diklasifikasikan sebagai				
	Kelas 1	Kelas 2	Kelas 3	Kelas 4	Kelas 5
Kelas 1	N_{11}	N_{12}	N_{13}	N_{14}	N_{15}
Kelas 2	N_{21}	N_{22}	N_{23}	N_{24}	N_{25}
Kelas 3	N_{31}	N_{32}	N_{33}	N_{34}	N_{35}
Kelas 4	N_{41}	N_{42}	N_{43}	N_{44}	N_{45}
Kelas 5	N_{51}	N_{52}	N_{53}	N_{54}	N_{55}

Setiap elemen N_{ij} menunjukkan berapa jumlah piksel sampel kelas ke - i yang diklasifikasikan menjadi kelas ke - j . Dari *confusion matrix* ini dapat dihitung beberapa jenis akurasi , yaitu AP, AU, kemudian juga dapat dihitung Δ_{\max} .

(a). AP

AP adalah rata rata akurasi untuk setiap kelas. Semakin tinggi nilai AP, semakin baik tingkat pengenalan suatu pengklasifikasi. Nilai maksimum AP adalah 100%.

$$\text{AP didapatkan dengan rumus : } \frac{1}{K} \sum_{i=1}^K \left(\frac{N_{ii}}{\sum_{j=1}^K N_{ij}} \right)$$

(b). AU

AU adalah rata rata jumlah piksel yang diklasifikasikan dengan benar pada kelas tertentu dibagi jumlah piksel yang masuk ke kelas tersebut. Semakin tinggi nilai AU, semakin baik tingkat pengenalan suatu pengklasifikasi. Nilai maksimum AU adalah 100%.

$$\text{AU didapatkan dengan rumus : } \frac{1}{K} \sum_{j=1}^K \left(\frac{N_{jj}}{\sum_{i=1}^K N_{ij}} \right)$$

(c). Δ_{\max}

Δ_{\max} adalah selisih AP dan AU. Semakin rendah nilai Δ_{\max} berarti suatu pengklasifikasi tersebut mempunyai tingkat generalisasi yang baik. Jika nilai Δ_{\max} tinggi, maka dapat dikatakan bahwa pengklasifikasi tersebut mempunyai tingkat generalisasi yang buruk.

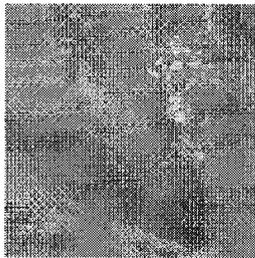
IV.3. CITRA YANG DIUJICоба

Citra yang diujicoba pada penelitian ini adalah satu set citra multispektral daerah Saguling yang berukuran 512×510 piksel dengan 256 derajat keabuan, 6 band. Pada penelitian ini digunakan metode penelitian terselia (*supervised*). Pada citra tersebut, diambil daerah daerah sampel yang berukuran 10×10 piksel (Lihat Tabel 4.1).

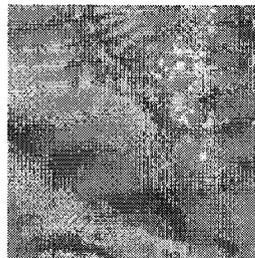
Tabel 4.1. Jenis Kelas, Koordinat, Ukuran dan Jumlah Piksel Daerah Sampel.

No	Kelas	Koordinat daerah sampel	Ukuran daerah sampel	Jumlah piksel daerah sampel
1	Sungai	(197,362), (44,39)	10×10	200
2	Hutan	(461,204), (269,413)	10×10	200
3	Kebun 1	(204,239), (250,281)	10×10	200
4	Kebun 2	(116,79), (253,203)	10×10	200
5	Pemukiman	(400,298), (352,115)	10×10	200

Berikut ini adalah citra Saguling



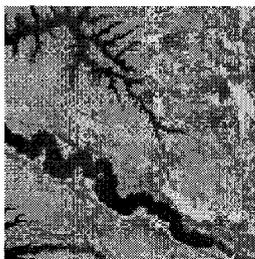
Band 1



Band 2



Band 3



Band 4



Band 5



Band 7

Gambar 4.1. Citra asli daerah Saguling (Sumber : Ketut Wikantika, BPPT)

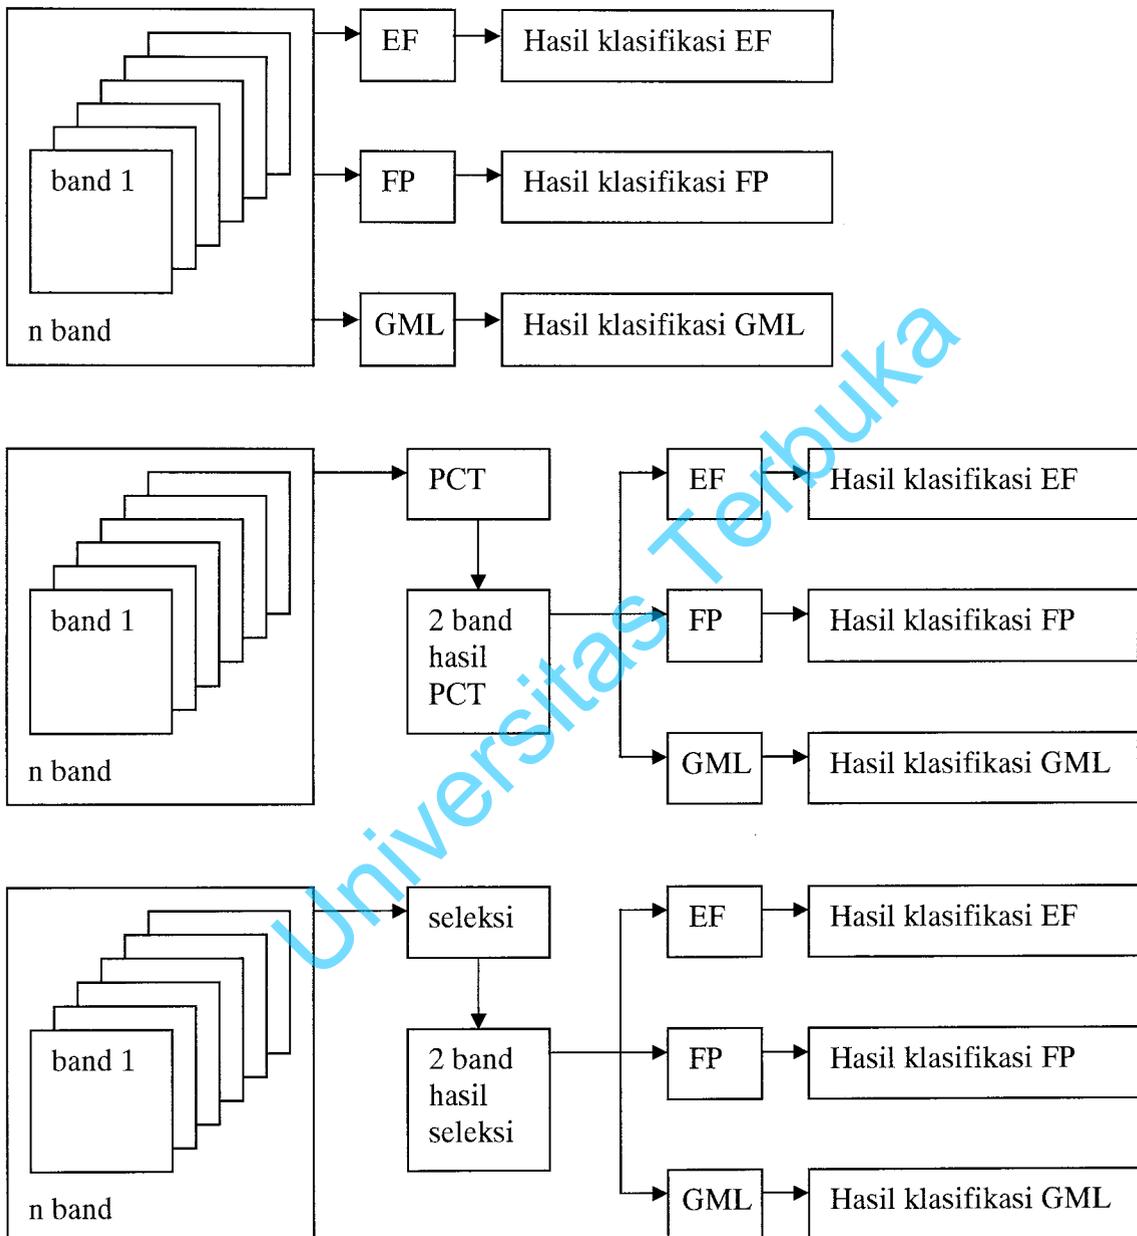
IV.4. RANCANGAN EKSPERIMEN

Ujicoba klasifikasi pada citra optik dilakukan pada implementasi perangkat lunak. Seperti telah disebutkan dalam Bab 1, tujuan utama penelitian ini adalah : Meneliti kinerja pengklasifikasi EF, FP dan GML pada citra multispektral. Beberapa tujuan yang lebih terperinci adalah :

1. Mengetahui kinerja EF, FP dan GML melalui percobaan dengan mempergunakan semua band dan percobaan yang hanya mempergunakan sebagian band hasil reduksi ataupun seleksi. Hal ini berguna untuk mengetahui pengaruhnya terhadap waktu komputasi.
2. Mengetahui kinerja EF, FP dan GML pada berbagai jenis prosentasi daerah pelatihan, untuk melihat konsistensi kemampuan pengenalan.
3. Mengetahui tingkat generalisasi EF , FP dan GML dengan mengamati selisih antara metrik akurasi klasifikasi yang digunakan.

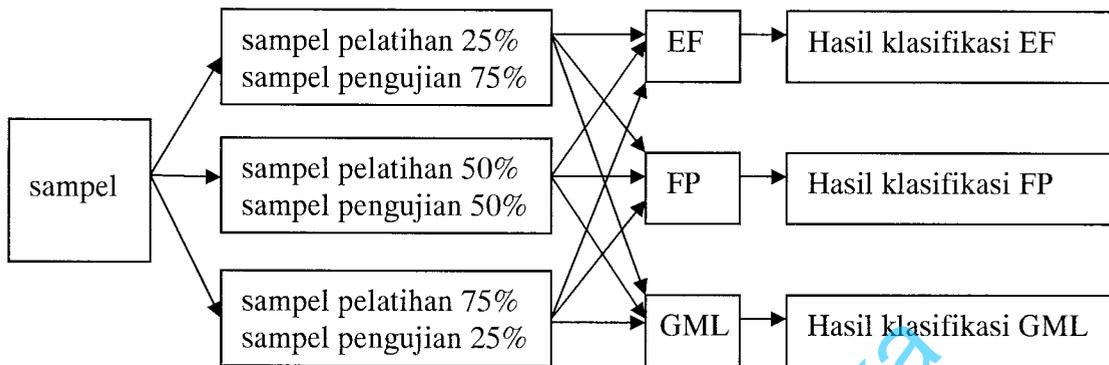
Secara sederhana, rancangan eksperimen dapat digambarkan sebagai berikut:

Rancangan eksperimen 1 : membandingkan pengaruh pemakaian jumlah dan jenis band.



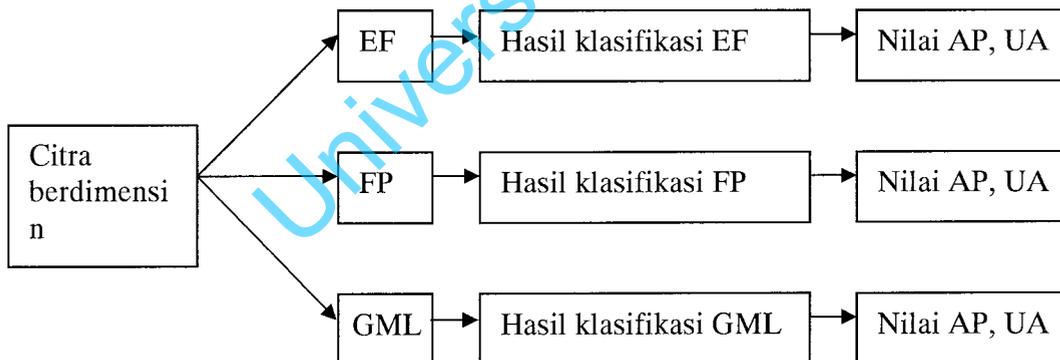
Gambar 4.2. Skema rancangan eksperimen 1.

Rancangan eksperimen 2 : membandingkan pengaruh penggunaan prosentase sampel pelatihan dan sampel pengujian yang berbeda.



Gambar 4.3. Skema rancangan eksperimen 2.

Rancangan eksperimen 3 : membandingkan tingkat generalisasi pengklasifikasi EF, FP dan GML.



Gambar 4.4. Skema rancangan eksperimen 3.

IV.4.1. Penggunaan jumlah band yang berbeda

Pada ujicoba ini digunakan jumlah band yang berbeda, yaitu semua band dan hanya dua band. Penggunaan band yang berbeda akan mempengaruhi beban komputasi. Penggunaan dua band bertujuan untuk mengetahui tingkat pengenalan pengklasifikasi jika hanya

menggunakan ciri yang lebih sedikit dan mengetahui waktu komputasinya. Kinerja dilihat dari segi tingkat pengenalan dan waktu komputasi yang digunakan.

Untuk mereduksi ciri tersebut, dilakukan dua cara, yaitu dengan menggunakan principal Component Transform (PCT) dan seleksi ciri. PCT merupakan metode yang sering dipergunakan untuk mereduksi ciri. Hasil PCT sangat baik untuk citra yang memiliki korelasi tinggi pada setiap dimensinya[3]. Seleksi ciri dilakukan dengan mencari 2 ciri terbaik dengan mencobakan semua kemungkinan (kombinasi 2 dari 6).

IV.4.2. Penggunaan prosentase sampel pelatihan dan sampel pengujian yang berbeda.

Terdapat beberapa prosentase sampel pelatihan dan sampel pengujian, yaitu :

1. 25% dari jumlah sampel dipakai sebagai sampel pelatihan dan sisanya (75%) untuk sampel pengujian
2. 50% dari jumlah sampel dipakai sebagai sampel pelatihan dan sisanya (50%) untuk sampel pengujian
3. 75% dari jumlah sampel dipakai sebagai sampel pelatihan dan sisanya (25%) untuk sampel pengujian

Perbedaan komposisi prosentase sampel pelatihan dan sampel pengujian berguna untuk mengetahui tingkat pengenalan pengklasifikasi jika diberikan sampel pelatihan yang sedikit prosentasenya atau sebaliknya. Pendekatan ini dapat digunakan untuk melihat apakah diskriminasi antara obyek sudah cukup baik atau sulit dibedakan.

Ujicoba ini bertujuan untuk melihat kinerja EF, FP dan GML pada berbagai jenis prosentase daerah pelatihan. Kinerja dilihat dari segi tingkat pengenalan.

IV.4.3. Tingkat generalisasi

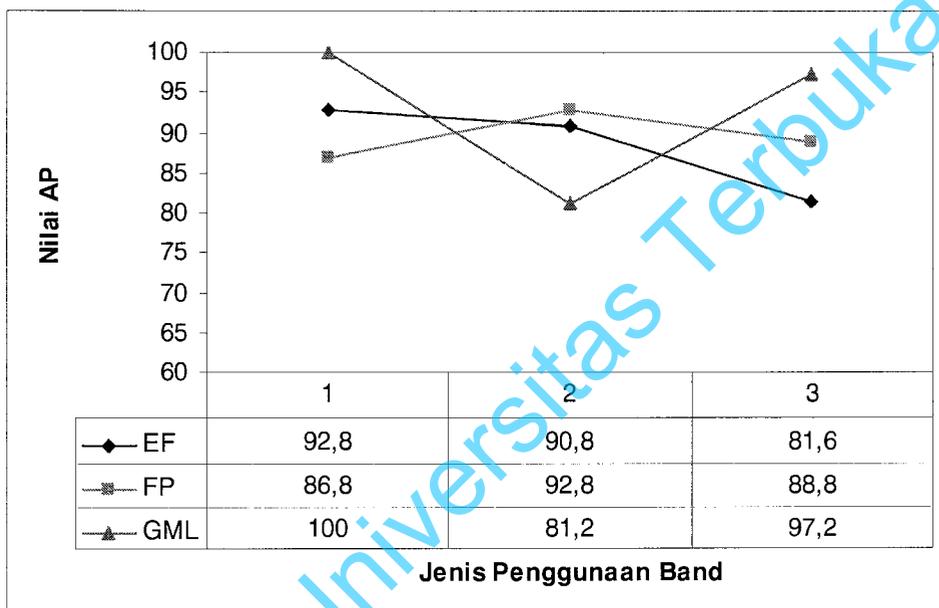
Ujicoba ini bertujuan untuk mengetahui tingkat generalisasi EF, FP dan GML. Seperti dijelaskan sebelumnya, tingkat generalisasi suatu pengklasifikasi dilihat dari Δ_{\max} .

BAB V

HASIL DAN PEMBAHASAN

V.1. Hasil ujicoba penggunaan jumlah band yang berbeda.

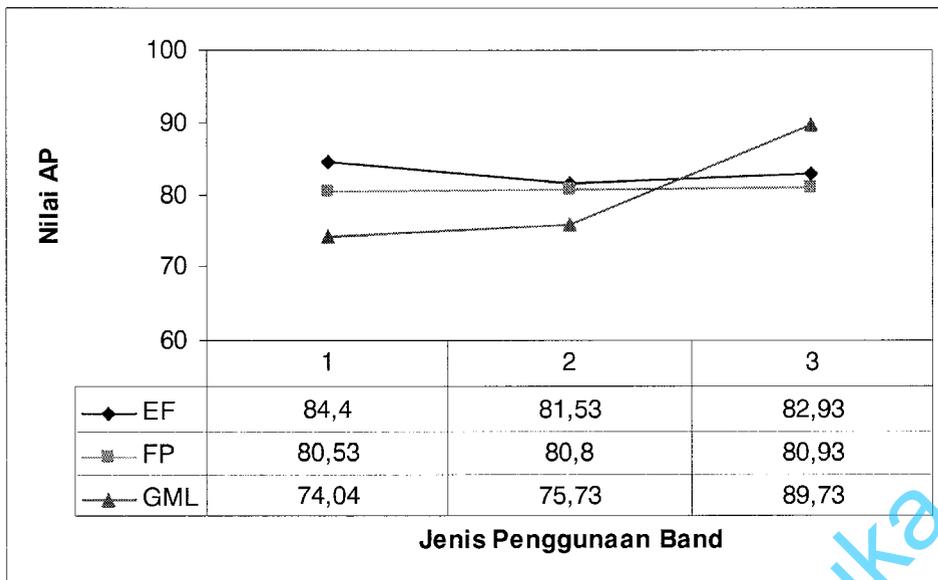
Hasil ujicoba penggunaan jumlah band yang berbeda pada daerah Saguling dapat dilihat pada grafik berikut :



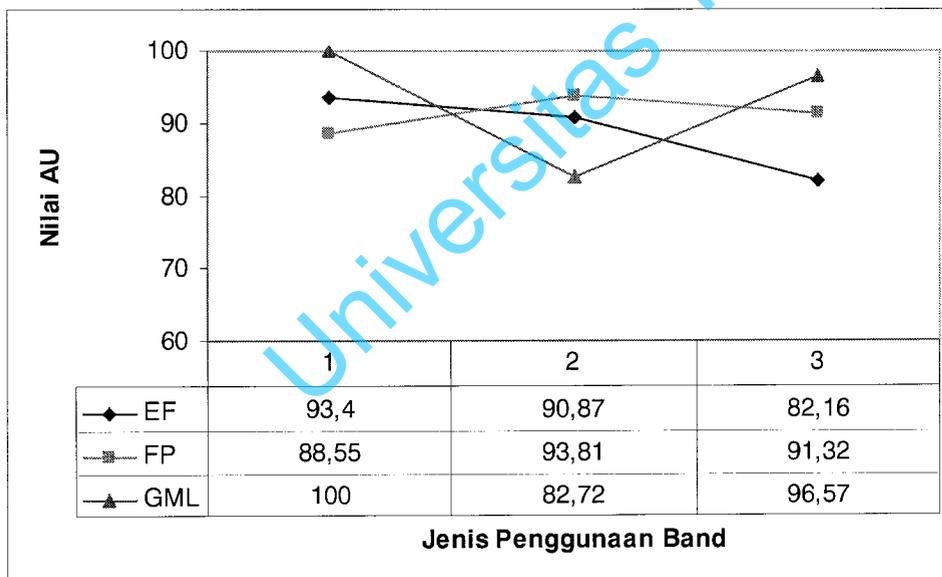
Gambar 5.1 Grafik AP pada daerah pelatihan (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)

Keterangan :

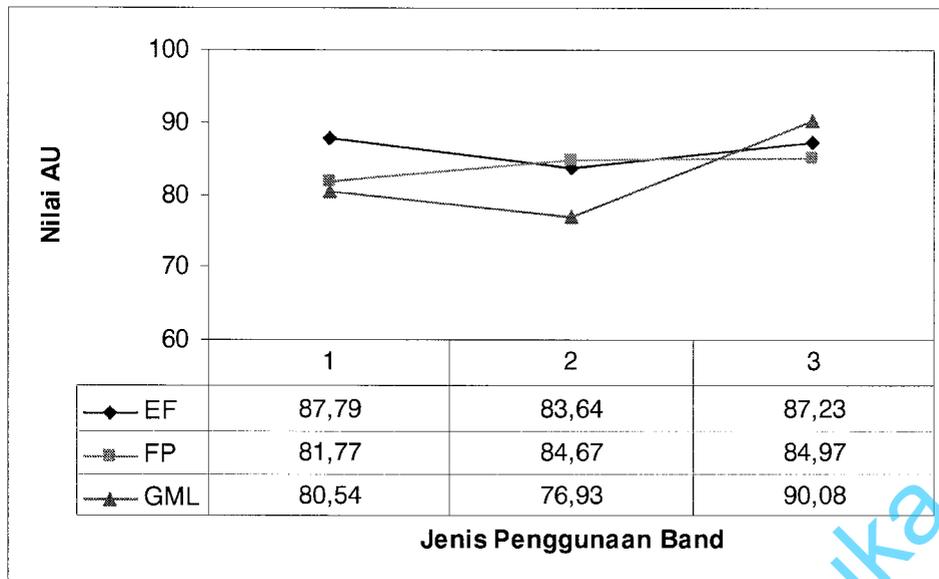
1. Penggunaan semua band
2. Penggunaan 2 band hasil PCT
3. Penggunaan 2 band hasil seleksi



Gambar 5.2 Grafik AP pada daerah pengujian (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)



Gambar 5.3 Grafik AU pada daerah pelatihan (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)



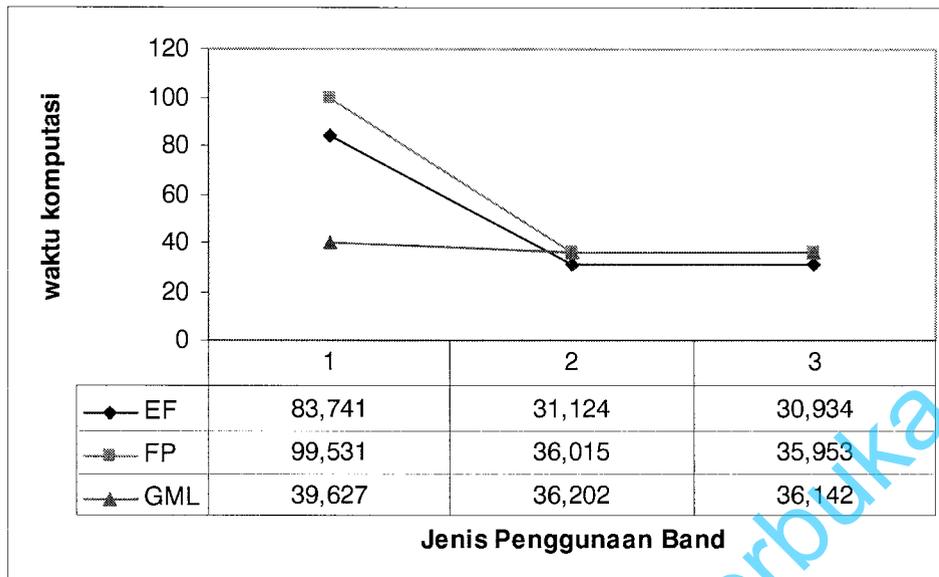
Gambar 5.4 Grafik AU pada daerah pengujian (pada percobaan penggunaan sampel pelatihan 25% dan sampel pengujian 75%)

Analisa Hasil :

Pada penggunaan sampel 25% dan sampel pengujian 75%, dapat dilihat bahwa :

1. EF mempunyai nilai AP dan AU tertinggi pada penggunaan semua band
2. Pada umumnya, FP mempunyai nilai AP dan AU tertinggi pada penggunaan semua band
3. EF mempunyai nilai AP dan AU yang cukup baik pada penggunaan band hasil PCT.
4. FP mempunyai nilai AP dan AU yang cukup baik pada penggunaan band hasil PCT.
5. Pada penggunaan 2 band hasil PCT, GML mempunyai nilai AP dan AU yang kurang baik dibandingkan EF dan FP.
6. Pada penggunaan 2 band hasil seleksi, GML mempunyai nilai AP dan AU yang lebih baik dibandingkan EF dan FP.

Waktu komputasi ujicoba pada daerah Saguling adalah sebagai berikut :



Gambar 5.5 Waktu komputasi ujicoba pada daerah Saguling (sampel pelatihan 25% dan sampel pengujian 75%)

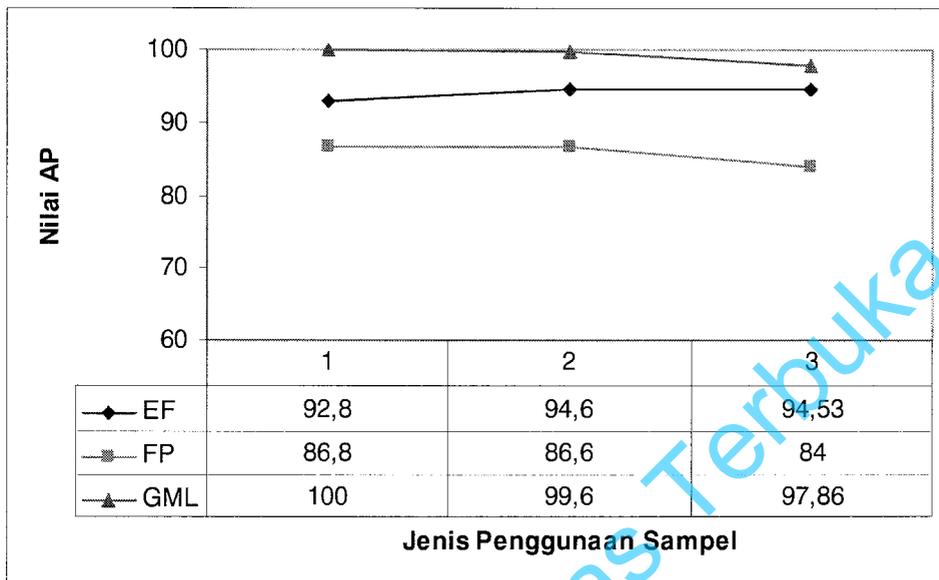
Dari segi waktu komputasi, terlihat EF dan FP memerlukan waktu komputasi yang lebih tinggi dibandingkan dengan GML pada penggunaan semua band, sedangkan pada penggunaan 2 band, EF lebih cepat dibandingkan dengan FP dan GML. Hal ini disebabkan karena EF dan FP menghitung fungsi keanggotaan suatu piksel tertentu untuk setiap band dan setiap kelas.

Kesimpulan yang dapat diambil berdasarkan ujicoba ini adalah :

1. Penggunaan semua band tidak menjamin nilai AP dan AU yang tinggi.
2. Penggunaan 2 band hasil PCT tidak selalu lebih baik dibandingkan jika menggunakan 2 band hasil seleksi ciri.
3. Waktu komputasi EF dan FP sangat tergantung pada penggunaan jumlah band, sedangkan GML lebih konstan.
4. Pada penggunaan dua band, waktu komputasi EF lebih sedikit dibandingkan FP dan GML.

V.2. Hasil ujicoba penggunaan prosentase ukuran sampel pelatihan dan sampel pengujian yang berbeda.

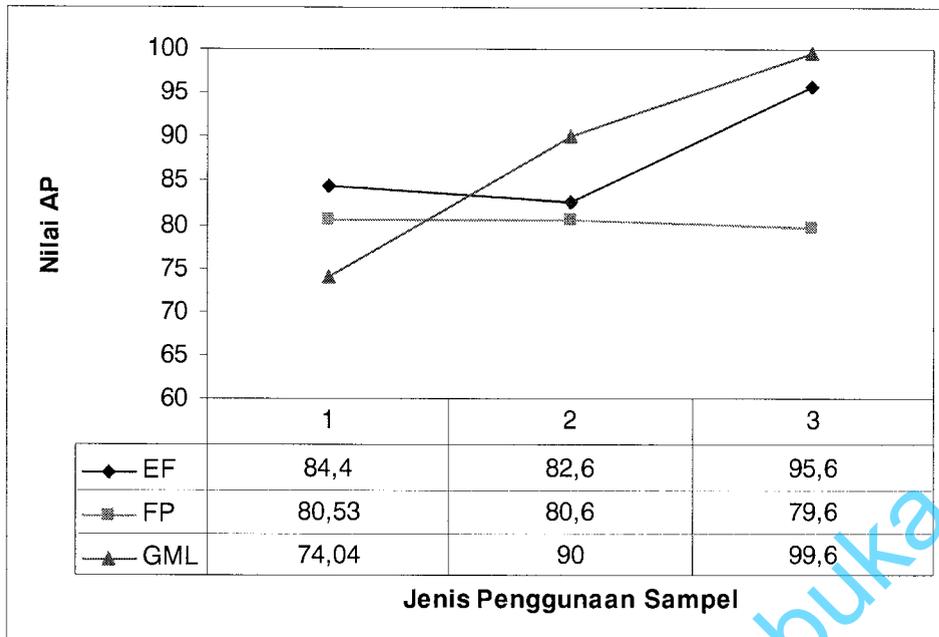
Hasil ujicoba penggunaan ukuran sampel pelatihan dan sampel pengujian yang berbeda dapat dilihat pada grafik berikut :



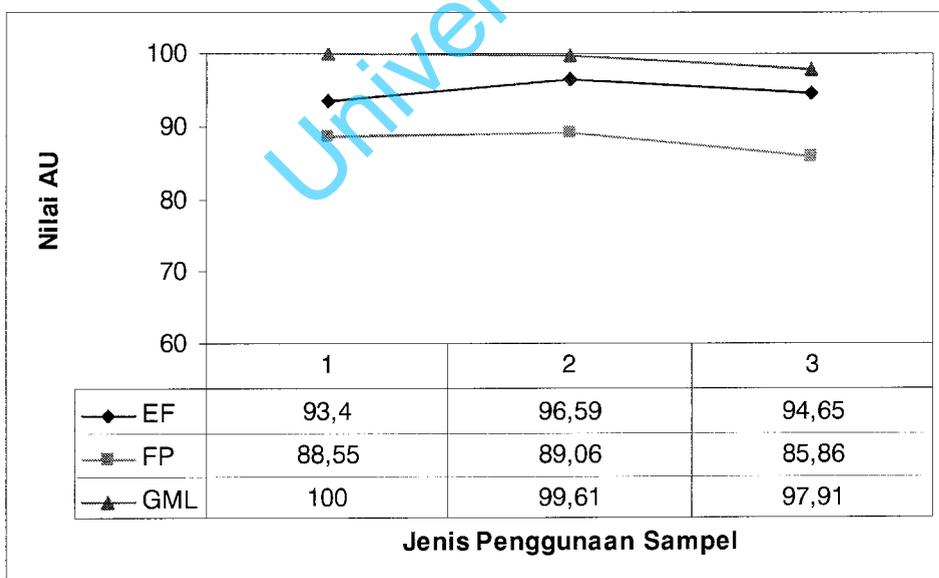
Gambar 5.6 Nilai AP pada daerah pelatihan pada penggunaan semua band

Keterangan :

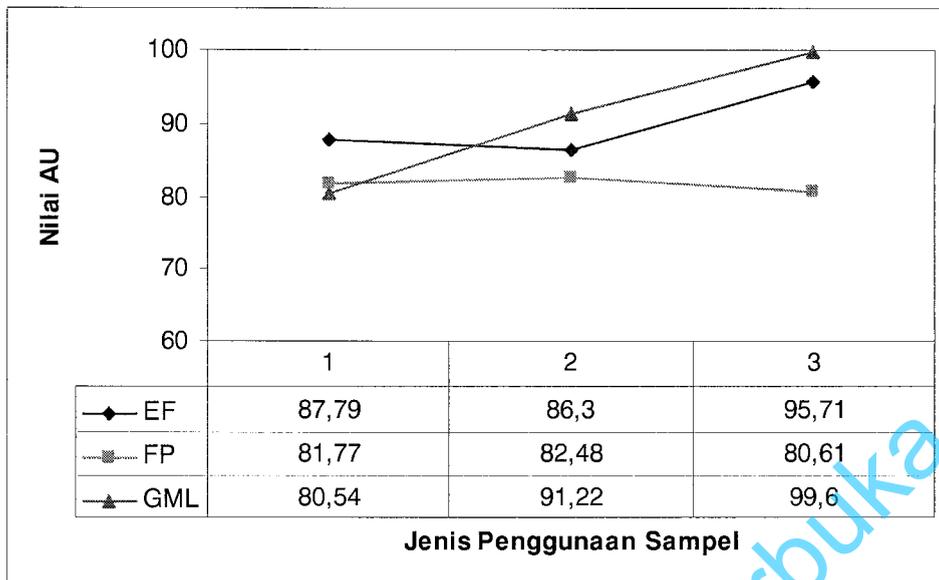
1. sampel pelatihan 25% dan sampel pengujian 75%
2. sampel pelatihan 50% dan sampel pengujian 50%
3. sampel pelatihan 75% dan sampel pengujian 25%



Gambar 5.7 Nilai AP pada daerah pengujian pada penggunaan semua band



Gambar 5.8 Nilai AU pada daerah pelatihan pada penggunaan semua band



Gambar 5.9 Nilai AU pada daerah pengujian pada penggunaan semua band

Analisa hasil :

Untuk pengklasifikasi EF, FP dan GML, nilai AP dan AU tertinggi dicapai jika digunakan sampel pelatihan sebanyak 75%. Pada citra Saguling, penggunaan sampel pelatihan yang banyak memberikan hasil AP dan AU yang baik.

Kesimpulan yang dapat diambil adalah :

1. Pada umumnya penambahan jumlah sampel pelatihan menaikkan tingkat pengenalan.
2. Penambahan jumlah sampel pelatihan tidak mempengaruhi waktu komputasi.

V.3. Hasil ujicoba tingkat generalisasi.

Seperti telah dijelaskan pada bab sebelumnya, tingkat generalisasi didapat dari Δ_{\max} .

Tabel 5.1. Nilai Δ_{\max} pada daerah Saguling

Hasil ujicoba 1 pada daerah Saguling			Sampel pelatihan 25% dan sampel pengujian 75%	Sampel pelatihan 50% dan sampel pengujian 50%	Sampel pelatihan 75% dan sampel pengujian 25%
Semua band	EF	SL	0,6	1,99	0,12
		SU	3,39	3,7	0,11
	FP	SL	1,75	2,46	1,86
		SU	1,24	1,88	1,01
	GML	SL	0	0,01	0,05
		SU	6,5	1,22	0
2 band hasil PCT	EF	SL	0,07	0,01	0,1
		SU	2,11	3,19	0,4
	FP	SL	1,01	1,18	3,9
		SU	3,87	5,45	2,15
	GML	SL	1,52	0,8	0,18
		SU	1,2	4,07	0,53
2 band hasil seleksi	EF	SL	0,56	0,24	0,22
		SU	4,3	2,99	0,94
	FP	SL	2,52	2,44	4,11
		SU	4,04	3,24	0,85
	GML	SL	0,63	5,07	0,1
		SU	0,35	1,87	1,24

Keterangan :

SL = sampel pelatihan ; SU = sampel pengujian

Analisa hasil :

Dari perhitungan berdasarkan tabel diatas, terlihat bahwa

1. rata rata Δ_{\max} EF = 1,3911
2. rata rata Δ_{\max} FP = 2,0561
3. rata rata Δ_{\max} GML = 1,4077

Dengan demikian dapat disimpulkan bahwa pada daerah Saguling, EF mempunyai tingkat generalisasi yang paling baik dibandingkan dengan FP dan GML.

Berikut adalah hasil ujicoba secara keseluruhan :

Tabel 5.2 Hasil ujicoba pada daerah Saguling

Hasil ujicoba 1 pada daerah Saguling			SL 25%, SU 75%		SL 50%, SU 50%		SL 75%, SU 25%	
			AP	AU	AP	AU	AP	AU
Semua band	EF	SL	92,8	93,4	94,6	96,59	94,53	94,65
		SU	84,4	87,79	82,6	86,3	95,6	95,71
	FP	SL	86,8	88,55	86,6	89,06	84,0	85,86
		SU	80,53	81,77	80,6	82,48	79,6	80,61
	GML	SL	100	100	99,6	99,61	97,86	97,91
		SU	74,04	80,54	90	91,22	99,6	99,6
2 band hasil PCT	EF	SL	90,8	90,87	94,2	94,21	92,4	92,5
		SU	81,53	83,64	81,8	84,99	93,6	94
	FP	SL	92,8	93,81	90,6	91,78	85,07	88,97
		SU	80,80	84,67	77,0	82,45	74,4	76,55
	GML	SL	81,2	82,72	90,2	91	94,4	94,58
		SU	75,73	76,93	75,2	79,27	95,6	96,13
2 band hasil seleksi	EF	SL	81,6	82,16	93,8	94,04	92,66	92,88
		SU	82,93	87,23	82,4	85,39	91,6	92,54
	FP	SL	88,8	91,32	87,4	89,84	85,2	89,31
		SU	80,93	84,97	79,2	82,44	74,8	73,95
	GML	SL	97,2	96,57	98,2	93,13	95,2	95,1
		SU	89,73	90,08	86,8	88,67	96	97,24

Keterangan :

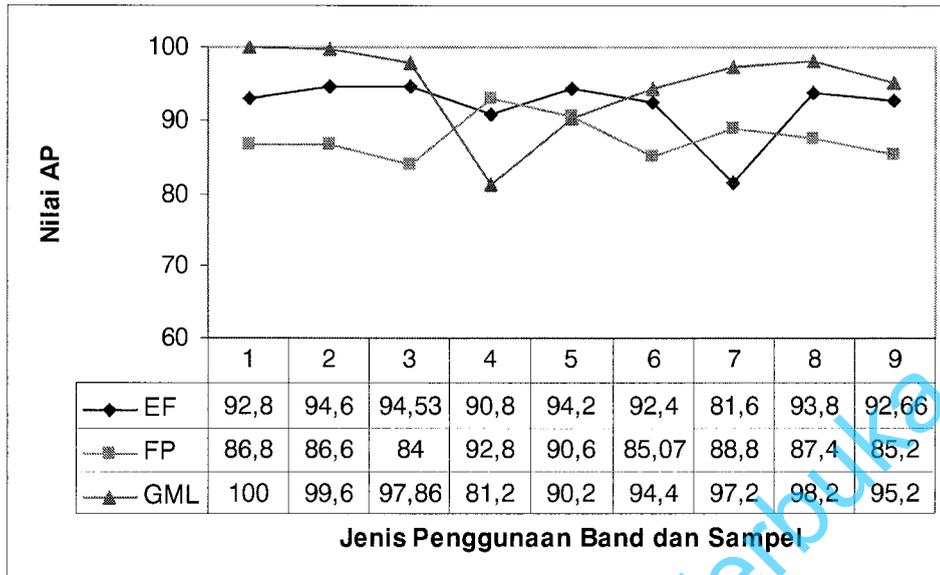
SL = sampel pelatihan

SU = sampel pengujian

Tabel 5.3 Waktu komputasi pada daerah Saguling

		Pengklasifikasi	SL 25%, SU 75%	SL 50%, SU 50%	SL 75%, SU 25%
Semua band	EF		83,741	83,77	84,441
	FP		99,531	99,563	99,813
	GML		39,627	39,266	39,627
2 band hasil PCT	EF		31,124	30,974	30,924
	FP		36,015	36,078	36,282
	GML		36,202	35,952	35,992
2 band hasil seleksi	EF		30,934	31,074	30,885
	FP		35,953	35,938	36,328
	GML		36,142	36,132	36,082

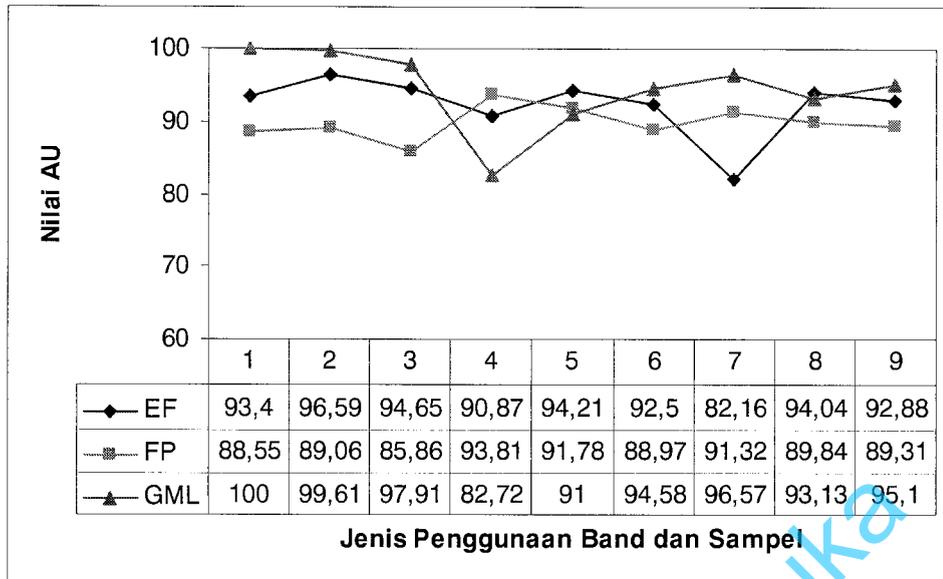
Secara keseluruhan, grafik AP dan AU pengklasifikasi EF, FP dan GML dapat disajikan sebagai berikut :



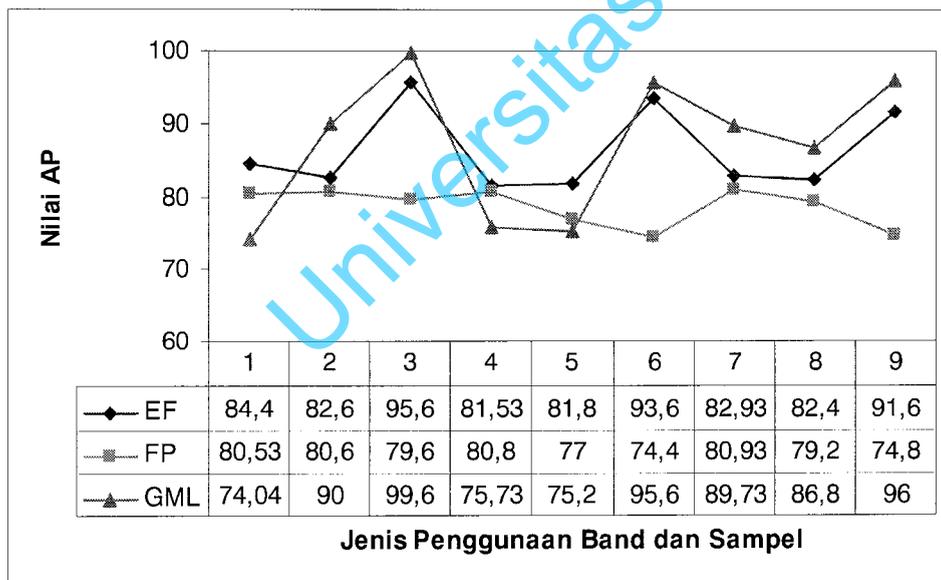
Gambar 5.10 Nilai AP pada daerah pelatihan dengan mempergunakan berbagai jenis band dan sampel.

Keterangan :

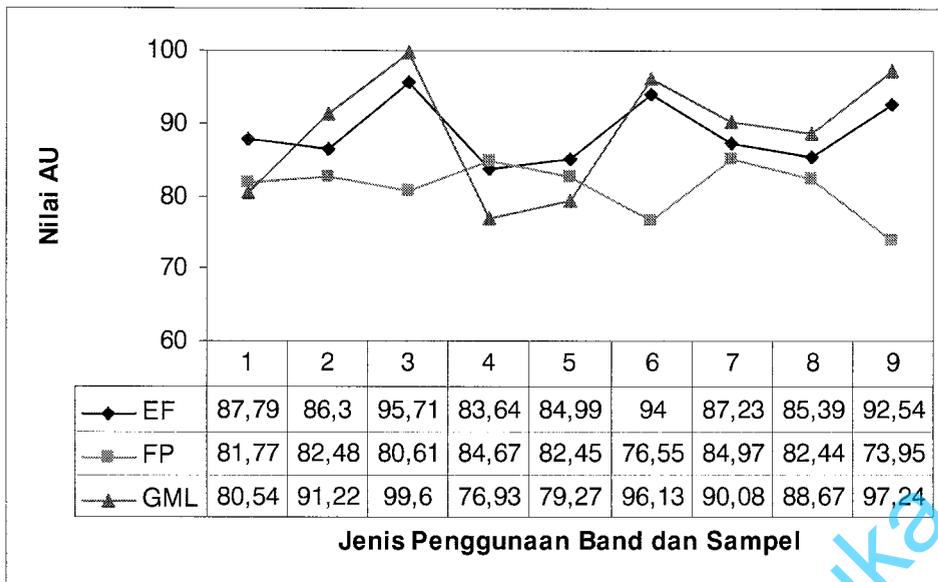
1. menggunakan semua band, sampel pelatihan 25% dan sampel pengujian 75%
2. menggunakan semua band, sampel pelatihan 50% dan sampel pengujian 50%
3. menggunakan semua band, sampel pelatihan 75% dan sampel pengujian 25%
4. menggunakan 2 band hasil PCT, sampel pelatihan 25% dan sampel pengujian 75%
5. menggunakan 2 band hasil PCT, sampel pelatihan 50% dan sampel pengujian 50%
6. menggunakan 2 band hasil PCT, sampel pelatihan 75% dan sampel pengujian 25%
7. menggunakan band 2 dan band 5, sampel pelatihan 25% dan sampel pengujian 75%
8. menggunakan band 2 dan band 5, sampel pelatihan 50% dan sampel pengujian 50%
9. menggunakan band 2 dan band 5, sampel pelatihan 75% dan sampel pengujian 25%



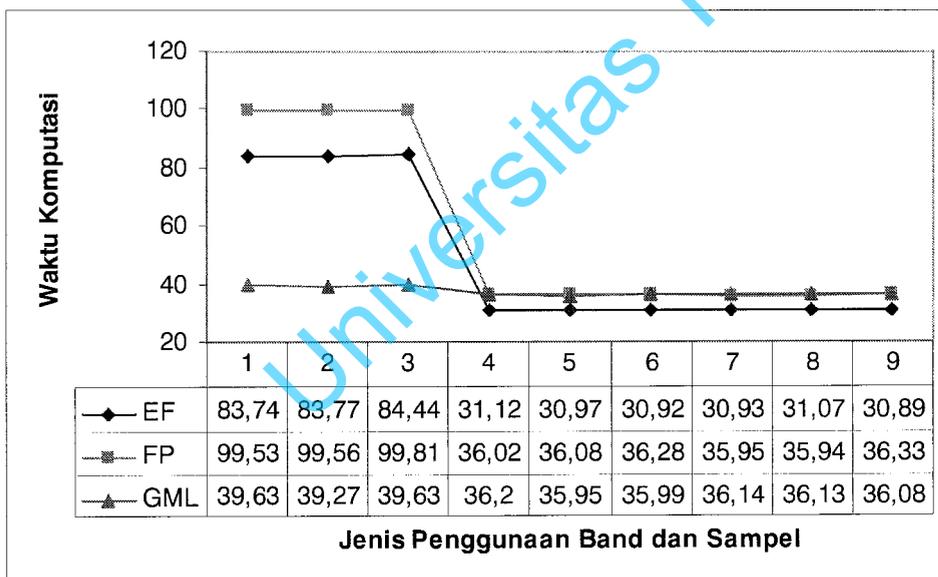
Gambar 5.11 Nilai AU pada daerah pelatihan dengan menggunakan berbagai jenis band dan sampel.



Gambar 5.12 Nilai AP pada daerah pengujian dengan menggunakan berbagai jenis band dan sampel.



Gambar 5.13 Nilai AU pada daerah pengujian dengan menggunakan berbagai jenis band dan sampel.



Gambar 5.14 Waktu komputasi yang diperlukan pada penggunaan berbagai jenis band dan sampel.

BAB VI

KESIMPULAN DAN SARAN

Dari percobaan yang dilakukan pada daerah Saguling, dapat diambil beberapa kesimpulan yaitu :

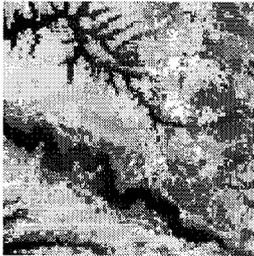
1. Penggunaan semua band multispektral tidak menjamin hasil akurasi yang lebih baik dari penggunaan 2 band hasil PCT atau hasil seleksi band. Band band tersebut tidak selalu berkorelasi tinggi.
2. Pada umumnya nilai AP dan AU pengklasifikasi GML lebih tinggi dibandingkan dengan pengklasifikasi EF dan FP. Pengklasifikasi EF lebih baik dibandingkan dengan pengklasifikasi FP.
3. Nilai rata rata Δ_{\max} EF lebih rendah dibandingkan dengan FP dan GML. Dengan demikian, pada daerah Saguling, EF lebih dapat menggeneralisasi permasalahan dibandingkan dengan FP dan GML.
4. Pada daerah Saguling, penambahan sampel memperbaiki pengenalan.
5. EF dan FP memerlukan waktu komputasi yang lebih lama dibandingkan dengan GML. Pada umumnya FP memerlukan waktu yang lebih lama dibandingkan dengan EF. Jika hanya mempergunakan 2 band hasil PCT atau seleksi, EF lebih cepat dibandingkan dengan FP dan GML.

DAFTAR PUSTAKA

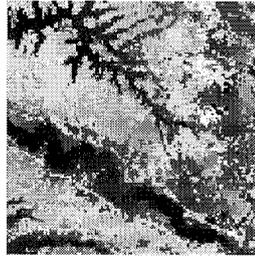
- Console, E dan Mouchot, MC. 1996. Fuzzy Classification Techniques in the Urban Area Recognition, IEEE, halaman 1373 – 1375
- Cahyati,D. 2003. Klasifikasi Citra Radar Berdasarkan Ciri Textur Gray Level Coocurrence Matrix (GLCM), Semivariogram dan Wavelet Stasioner, Tesis tidak diterbitkan pada Fasilkom Universitas Indonesia
- Duda, RO dan Hart PE.1973. *Pattern Classification and Scene Analysis*, New York, John Wiley & Sons Inc
- Gonzales,RC.1992.*Digital Image Processing*, Massachusetts, Addison Wesley
- Melgani, F.2000. An Explicit Fuzzy Supervised Classification Method for Multispectral Remote Sensing Images. *IEEE Trans on Geoscience Remote Sensing* vol 38, halaman 287-295
- Patria,L. Studi banding Metode Klasifikasi antara Pendekatan Explicit Fuzzy dan Gaussian Maximum Likelihood pada Aplikasi Citra Multispectral, Tesis tidak diterbitkan pada Fasilkom Universitas Indonesia

LAMPIRAN 1.

Hasil Klasifikasi EF, FP dan GML pada berbagai jenis penggunaan band dan sampel



EF, semua band



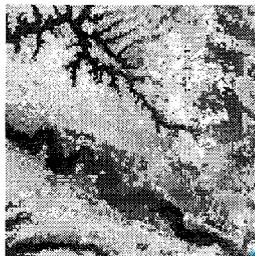
EF, 2 band hasil PCT



EF, band 2 dan band 5



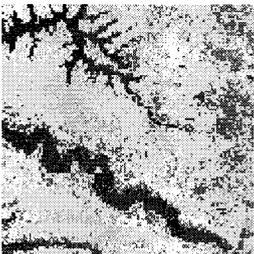
FP, semua band



FP, 2 band hasil PCT



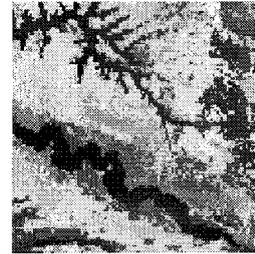
FP, band 2 dan band 5



GML, semua band



GML, 2 band hasil PCT

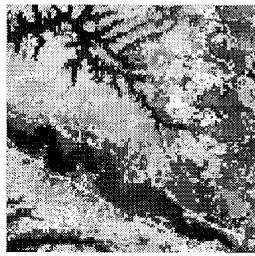


GML, band 2 dan band 5

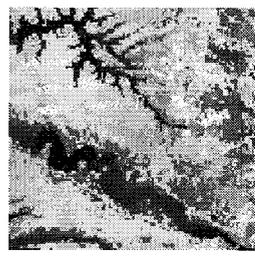
Hasil klasifikasi EF GML dan FP pada daerah Saguling dengan prosentase sampel pelatihan 25% dan sampel pengujian 75%.



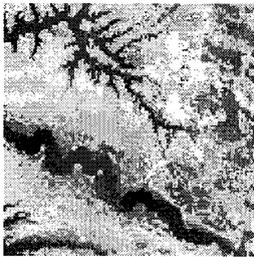
EF, semua band



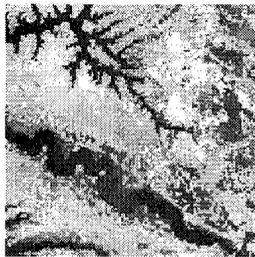
EF, 2 band hasil PCT



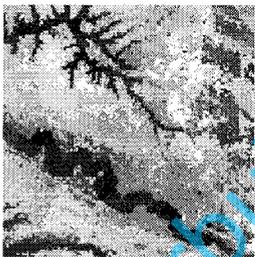
EF, band 2 dan band 5



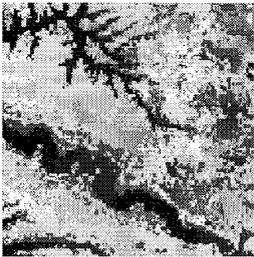
FP, semua band



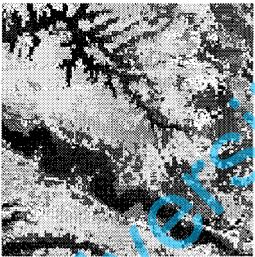
FP, 2 band hasil PCT



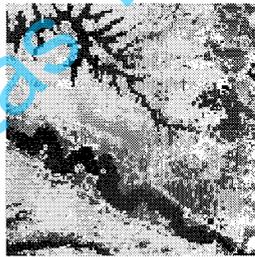
FP, band 2 dan band 5



GML, semua band

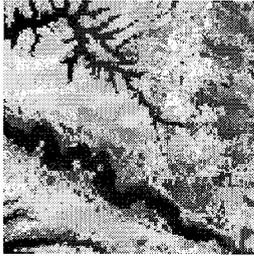


GML, 2 band hasil PCT

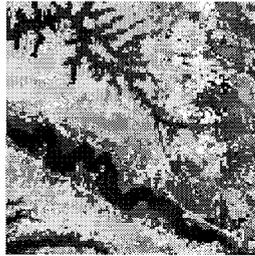


GML, band 2 dan band 5

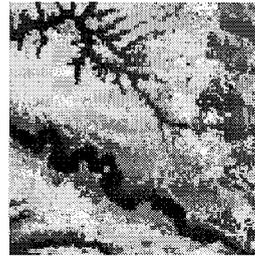
Hasil klasifikasi EF, GML dan FP pada daerah Saguling dengan prosentase sampel pelatihan 50% dan sampel pengujian 50%.



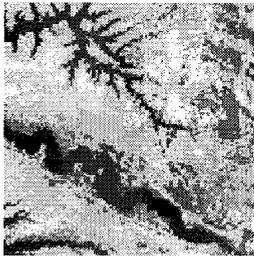
EF, semua band



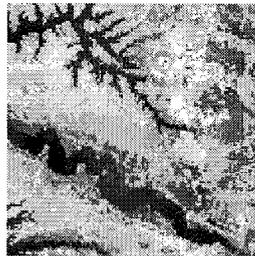
EF, 2 band hasil PCT



EF, band 2 dan band 5



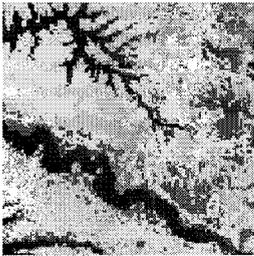
FP, semua band



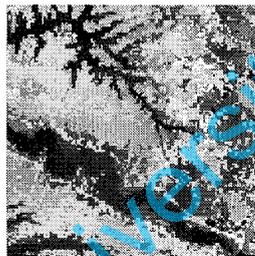
FP, 2 band hasil PCT



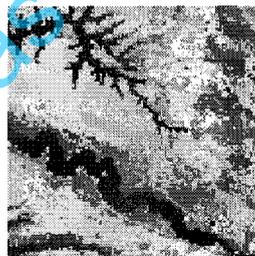
FP, band 2 dan band 5



GML, semua band



GML, 2 band hasil PCT



GML, band 2 dan band 5

Hasil klasifikasi EF , GML dan FP pada daerah Saguling dengan prosentase sampel pelatihan 75% dan sampel pengujian 25%

Lampiran 2 :**Matrix confusion daerah pelatihan dan daerah pengujian pada ujicoba daerah Saguling pada berbagai jenis penggunaan band dan sampel****Matrix confusion ujicoba pada daerah Saguling dengan sampel pelatihan 25% dan sampel pengujian 75%**

EF menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	47	3	0
Kebun2	0	0	11	39	0
Pemukiman	0	0	2	2	46

EF menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	150	0	0
Kebun2	3	12	46	89	0
Pemukiman	0	0	40	16	94

FP menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	12	19	19
Pemukiman	0	0	0	2	48

FP menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	144	0	6
Kebun2	9	6	41	56	38
Pemukiman	0	0	34	12	104

GML menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	0	50	0
Pemukiman	0	0	0	0	50

GML menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	144	6	0	0	0
Hutan	0	105	0	31	14
Kebun1	0	0	64	21	65
Kebun2	3	0	6	92	49
Pemukiman	0	0	0	0	150

EF menggunakan 2 band hasil PCT

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	41	7	2
Kebun2	0	0	11	39	0
Pemukiman	0	0	0	3	47

EF menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	141	9	0
Kebun2	15	9	49	73	4
Pemukiman	0	4	36	13	97

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	15	35	0
Pemukiman	0	0	0	3	47

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	150	0	0
Kebun2	3	6	63	63	15
Pemukiman	0	0	46	11	93

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	20	28	2
Kebun2	0	0	11	39	0
Pemukiman	0	0	0	6	44

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	125	25	0
Kebun2	13	0	43	79	15
Pemukiman	0	4	18	64	64

EF menggunakan band 2 dan 5
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	46	4	0	0	0
Hutan	9	41	0	0	0
Kebun1	0	0	35	15	0
Kebun2	0	0	15	35	0
Pemukiman	0	0	0	3	47

EF menggunakan band 2 dan 5
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	137	13	0
Kebun2	0	9	47	88	0
Pemukiman	0	0	34	19	97

FP menggunakan band 2 dan 5
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	6	44	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	19	31	0
Pemukiman	0	0	2	1	47

FP menggunakan band 2 dan 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	146	4	0	0
Kebun1	0	0	150	0	0
Kebun2	3	2	64	62	19
Pemukiman	0	0	40	11	99

GML menggunakan band 2 dan 5

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	48	0	2
Kebun2	0	0	2	48	0
Pemukiman	0	2	0	3	45

GML menggunakan band 2 dan 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	145	2	3
Kebun2	3	2	19	113	13
Pemukiman	0	0	18	17	115

Matrix confusion ujicoba pada daerah Saguling dengan sampel pelatihan 50% dan sampel pengujian 50%

EF menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	91	9	0
Kebun2	0	0	11	89	0
Pemukiman	0	0	0	7	93

EF menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	97	3	0
Kebun2	0	0	22	75	3
Pemukiman	0	0	40	19	41

FP menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	100	0	0
Kebun2	0	0	28	35	37
Pemukiman	0	0	0	2	98

FP menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	100	0	0
Kebun2	9	6	25	49	11
Pemukiman	0	0	34	12	54

GML menggunakan 6 band
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	98	0	2
Kebun2	0	0	0	100	0
Pemukiman	0	0	0	0	100

GML menggunakan 6 band
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	91	0	9	0
Kebun1	0	0	97	0	3
Kebun2	0	0	11	88	1
Pemukiman	0	0	20	6	74

EF menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	4	87	7	2
Kebun2	0	0	11	89	0
Pemukiman	0	0	0	5	95

EF menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	91	9	0
Kebun2	1	0	33	63	3
Pemukiman	0	4	30	11	55

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	100	0	0
Kebun2	0	0	34	58	8
Pemukiman	0	0	0	5	95

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	100	0	0
Kebun2	3	6	44	40	7
Pemukiman	0	0	46	9	45

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	4	78	16	2
Kebun2	0	0	11	89	0
Pemukiman	0	0	0	16	84

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	79	21	0
Kebun2	0	0	29	67	4
Pemukiman	0	4	18	48	30

EF menggunakan band 2 dan band 5
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	85	15	0
Kebun2	0	0	11	89	0
Pemukiman	0	0	0	5	95

EF menggunakan band 2 dan band 5
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	97	3	0
Kebun2	0	0	21	76	3
Pemukiman	0	0	26	35	39

FP menggunakan band 2 dan band 5
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	6	94	0	0	0
Kebun1	0	0	100	0	0
Kebun2	0	0	44	48	8
Pemukiman	0	0	2	3	95

FP menggunakan band 2 dan band 5
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	100	0	0
Kebun2	3	2	39	45	11
Pemukiman	0	0	40	9	51

GML menggunakan band 2 dan band 5
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	98	0	2
Kebun2	0	0	11	88	1
Pemukiman	0	0	20	6	74

GML menggunakan band 2 dan band 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	100	0	0	0	0
Hutan	0	100	0	0	0
Kebun1	0	0	95	2	3
Kebun2	0	0	15	84	1
Pemukiman	0	0	12	33	55

Matrix confusion ujicoba pada daerah Saguling dengan sampel pelatihan 75% dan sampel pengujian 25%

EF menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	137	13	0
Kebun2	0	0	21	129	0
Pemukiman	0	0	0	7	143

EF menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	0	50	0
Pemukiman	0	0	6	6	38

FP menggunakan 6 band

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	150	0	0
Kebun2	0	0	44	54	52
Pemukiman	0	0	16	8	126

FP menggunakan 6 band

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	9	6	6	25	4
Pemukiman	0	0	18	8	24

GML menggunakan 6 band
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	148	2	0
Kebun2	0	0	7	143	0
Pemukiman	0	0	2	5	143

GML menggunakan 6 band
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	0	50	0
Pemukiman	0	0	0	1	49

EF menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	128	22	0
Kebun2	1	0	27	122	0
Pemukiman	2	0	0	5	143

EF menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	5	45	0
Pemukiman	0	0	0	12	38

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	150	0	0
Kebun2	0	0	63	79	8
Pemukiman	0	0	20	12	118

FP menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	3	6	15	20	6
Pemukiman	0	0	26	8	16

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	141	9	0
Kebun2	0	0	27	122	1
Pemukiman	0	0	0	5	145

GML menggunakan 2 band hasil PCT
Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	0	50	0
Pemukiman	0	0	0	12	38

EF menggunakan band 2 dan band 5

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	146	4	0	0	0
Hutan	9	141	0	0	0
Kebun1	0	0	130	20	0
Kebun2	0	0	15	135	0
Pemukiman	0	0	0	7	143

EF menggunakan band 2 dan band 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	40	10	0
Kebun2	0	0	0	50	0
Pemukiman	0	0	6	6	38

FP menggunakan band 2 dan band 5

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	6	144	0	0	0
Kebun1	0	0	150	0	0
Kebun2	0	0	69	73	8
Pemukiman	0	0	24	4	122

FP menggunakan band 2 dan band 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	3	2	14	21	10
Pemukiman	0	0	18	16	16

GML menggunakan band 2 dan band 5

Matrix confusion sampel pelatihan

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	150	0	0	0	0
Hutan	0	150	0	0	0
Kebun1	0	0	143	5	2
Kebun2	0	0	21	128	1
Pemukiman	0	0	2	5	143

GML menggunakan band 2 dan band 5

Matrix confusion sampel pengujian

Sampel	Diklasifikasikan sebagai				
	Sungai	Hutan	Kebun1	Kebun2	Pemukiman
Sungai	50	0	0	0	0
Hutan	0	50	0	0	0
Kebun1	0	0	50	0	0
Kebun2	0	0	2	48	0
Pemukiman	0	0	6	0	44

Lampiran 3

Personalia Penelitian

Ketua Peneliti :

- a. Nama Lengkap : Dra Lintang Patria M.Kom
- b. Jenis Kelamin : Perempuan
- c. NIP : 132052359
- d. Disiplin Ilmu : MIPA
- e. Pangkat/Gol : Penata, III/c
- f. jabatan Fungsional : Lektor
- g. Fakultas / Jurusan : MIPA/Matematika
- h. Waktu untuk penelitian ini : 10 jam per minggu

Universitas Terbuka

PERFORMANCE COMPARISON STUDY OF EXPLICIT FUZZY, FUZZY PARALLELEPIPED AND GAUSSIAN MAXIMUM LIKELIHOOD METHODS FOR MULTIBAND LANSAT TM IMAGE CLASSIFICATION

Abstract

This paper evaluates the classification accuracy and complexity of Explicit Fuzzy (EF), Fuzzy Parallelepiped (FP) and Gaussian Maximum Likelihood (GML) methods for multiband Land Satellite (Landsat) Thematic Mapper (TM). Fuzzy approach has been expected to be more capable to solve uncertainties compared to the conventional statistical approach. The EF method consists of three steps: explicit fuzzification, minimum fuzzy reasoning rule and defuzzification. EF method has used a Gaussian model to compute the membership function, and FP method has used trapezoidal membership function. In the Saguling case study of using small number of bands (two bands), all methods give a comparable good classification accuracy and complexity. But when the number of band increases to six bands, the running time of EF and FP increase to twice or three times longer than the GML, while their classification accuracies remain about the same to the ones using only two bands.

I. Introduction

This study was carried out due to the claim that the use of Explicit Fuzzy (EF) method gives better classification accuracy and about the same complexity compared to the use of conventional Gaussian Maximum Likelihood (GML) method [1]. Fuzzy Parallelepiped method has proven to be more adequate than conventional methods for the classification of mixed areas [2]. According

to the theory [3], the fuzzy approach usually has more complexity compared to the statistical due to the computation of the membership function.

The GML is hard classification method which may not good for mixed-pixel area. The EF and FP are fuzzy classification methods that are expected to perform better in solving uncertain problems. Due to the claim made by Melgani [1] that the running time of EF is about the same to the GML, it be interested to have the EF method with the expectation that it may give better classification accuracy. In this study, we will compare performance of EF, FP and GML methods. Another interesting thing is that the EF method have used a Gaussian model to compute the membership function.

II.Data and Methodology

One set of six-band land Satellite (Landsat) Thematic Mapper (TM) data was used for experiments. The analysis was acquired over Saguling case study. The EF, FP and GML methods were implemented using MATLAB facility for comparison purpose.

The training and testing processes have been done using configuration of 25% samples for training and 75% samples for testing and configurations of 50%-50% and 75%-25%, respectively. These three configurations of sample data for training and testing are meant to see the influence of training sample data size. User accuracy and producer accuracy are used as classification accuracy measures and generalization measures. Running time measures are used as complexity measures of the EF, FP and GML methods.

III. The Explicit Fuzzy (EF) method

Hard or crisp classification uses a principal of “one pixel belongs to only one object class”, while fuzzy classification assumes that “one pixel may belong to several classes of object”. EF method consist of three steps: (i) explicit fuzzification;(ii) minimum fuzzy reasoning rule; and (iii) defuzzification [1].

III.1. Explicit Fuzzification

Explicit fuzzification estimates each band contribution to each class of object and is represented using Gaussian model. Fuzzy domain consists of several fuzzy sets that represented a band. Each fuzzy set consists of several fuzzy subsets that represent an object class. Each fuzzy subset of class j in fuzzy set band n , where $n = 1, 2, 3, \dots, N$, is defined by a membership function $f_{n,j}(x_n)$, x_n is the gray level intensity of pixel \underline{X} in band n . The representation of pixel \underline{X} in N dimensional is as follows:

$$\underline{X} = [x_1, x_2, x_3, \dots, x_n, \dots, x_N]^T, \quad (1)$$

where N is the number of bands. Gaussian is chosen to be a model of the membership function due to its robustness and simplicity.

The mean and standard deviation of each class intensity distribution within each band are used to compute the membership function of each pixel. The mean (μ) of each class signature represents the ideal pixel of the corresponding class that does clearly belong to a certain class of object. The standard deviation (τ) of each class signature represents the range of its fuzzy subset. The membership function of class j in band n can be represented as follows:

$$f_{n,j}(x_n) = \exp\left(\frac{(x_n - \mu_{n,j})^2}{2\tau_{n,j}^2}\right), \quad (2)$$

where $\mu_{n,j}$ is the mean of class j in band n , and $\tau_{n,j}$ is the standard deviation of class j in band n , $j = 1, 2, 3, \dots, J$, $n = 1, 2, 3, \dots, N$. J is the number of object classes and N is the number of bands.

Fuzzification process computes the degree of membership of each pixel for all class j and band n . As a result an input fuzzy matrix Fip with an order of $N \times J$ is obtained. For a multiband images that have j number of object classes and n number of bands, the input fuzzy matrix Fip can be represented as follows:

$$Fip = \begin{bmatrix} f_{1,1}(x_1) & f_{1,2}(x_1) & \dots & f_{1,J}(x_1) \\ f_{2,1}(x_2) & f_{2,2}(x_2) & \dots & f_{2,J}(x_2) \\ \dots & \dots & \dots & \dots \\ f_{N,1}(x_N) & f_{N,2}(x_N) & \dots & f_{N,J}(x_N) \end{bmatrix} \quad (3)$$

III.2. Minimum Fuzzy Reasoning Rule

Minimum fuzzy reasoning rule is applied to the input fuzzy matrix Fip . The most effective membership function over band n that characterizes an object class j is the minimum one. Finally, an output fuzzy vector Fop with an order of j is obtained as shown in equation(4).

$$F'op = [F'_1(\underline{X}), F'_2(\underline{X}), \dots, F'_j(\underline{X})]^T \quad (4)$$

where

$$F'_i(\underline{X}) = \min(f_{n,i}(x_n))$$

III.3. Defuzzification

Defuzzification is done by applying a maximum rule to the obtained Fop to get a single hard output. The maximum value represents the most similarity measure of a pixel belongs to a certain class. A pixel belongs to class j if only if :

$$\forall i \in 1, 2, \dots, N \text{ where } i \neq j, F_j(\underline{X}) \geq F_i(\underline{X}) \quad (5)$$

IV. Fuzzy Parallelepiped

FP method has used trapezoidal membership function .Trapezoidal membership function were chosen with the core of the function being represented by the interval bounded by the minimum and the maximum values determined for each class using the spectral signatures of the training sites. The function were defined like this:

$$\text{If } \min_{j,n} < x_k < \max_{j,n} \text{ then } \mu_j(x_k) = 1 \quad (6)$$

$$\text{If } 0 < x_k < \min_{j,n} \text{ then } \mu_j(x_k) = f_1(x_k) \quad (7)$$

$$\text{If } \max_{j,n} < x_k < 255 \text{ then } \mu_j(x_k) = f_2(x_k) \quad (8)$$

where

$\mu_j(x_k)$ = membership value of the k^{th} pixel to j^{th} class

$\min_{j,n}$ = minimum value in the n^{th} band for j^{th} class

$\max_{j,n}$ = maximum value in the n^{th} band for j^{th} class

$$f_1(x_k) = \frac{1}{\min_{j,n}} x_k$$

$$f_2(x_k) = \frac{1}{\max_{j,n} - 255} x_k - \left(\frac{255}{\max_{j,n} - 255} \right)$$

In order to belong to a class, a pixel must comply with the membership function of this class in all spectral bands. The final membership value of a pixel to a given class is then obtained by a t-norm, chosen here according to the Zadeh definition and such as:

$$\mu_j(x_k) = \min_{n=1}^N \mu_{j,n}(x_k) \quad (9)$$

Where $j = 1, \dots, J$; $n = 1, \dots, N$

V. Gaussian Maximum Likelihood

A pattern vector in N dimensional space can be represented as a vector

$\underline{X} = [x_1, x_2, x_3, \dots, x_n, \dots, x_N]^T$ and there are pattern classes $\omega_1, \omega_2, \omega_3, \dots, \omega_j$, $j = 1, \dots, J$. J is the number of pattern classes. If each pattern class is assumed to have a Gaussian distribution, then the Gaussian density function of pattern x given j^{th} pattern class [3,4], is shown in equation (10).

$$p(x/\omega_j) = \frac{1}{(2\pi)^{B/2} |C_j|^{1/2}} \exp\left(-\frac{1}{2}(x - m_j)^T C_j^{-1}(x - m_j)\right), j = 1, 2, \dots, J \quad (10)$$

m_j is the mean vector of object class j and C_j is the covariance matrix of object class j . The GML classifier will assign a pattern class x to an object class ω_j if only if the result of equation (11) has a maximum value for a certain j .

$$d_j(x) = \ln P(\omega_j) - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (11)$$

VI. Experimental Results

The experiments have used all band and two optimal combination of bands. Configurations of 25%-75%, 50%-50% and 75%-25% portions of samples for training and testing are used. Producer and user accuracies were used for measuring classification accuracies. Experimental result are shown in Table 1, Table 2, and Table 3. Table 1 shows the result of using 2 and 6

bands, using different portions for training and testing, and their classification accuracy based on the user and producer accuracies. Table 2 shows the computation complexity based on running time, and Table 3 shows the degree of generalization based on the difference between the user and producer accuracies.

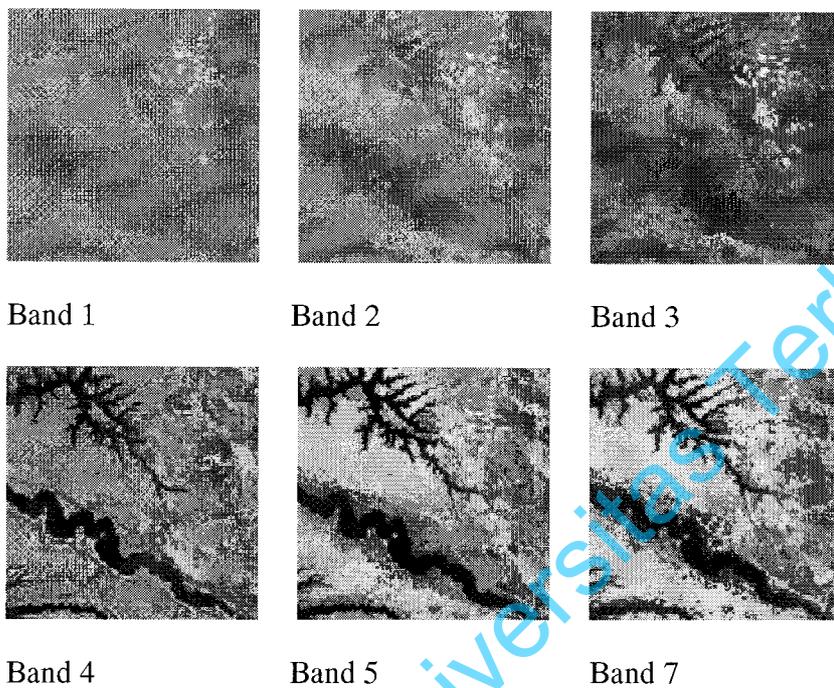


Figure 1. Image multispectral of Saguling (Source : Ketut Wikantika, BPPT)

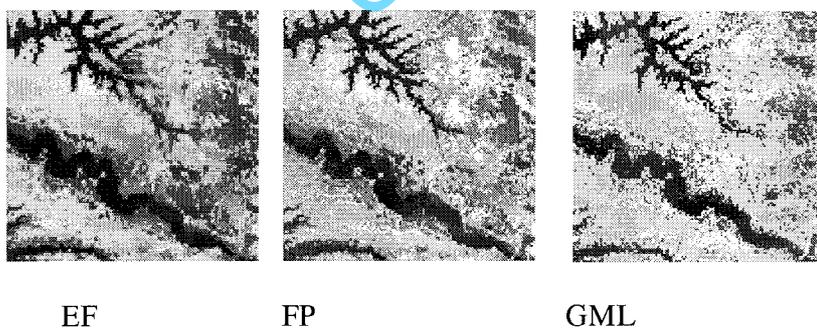


Figure 2. The result classification using six band , configuration of 25% samples for training and 75% samples for testing

Table 1. Classification accuracies for Saguling case study

Classification Accuracy			25% Training - 75% Testing		50% Training - 50% Testing		75% Training - 25% Testing	
			PA	UA	PA	UA	PA	UA
All bands are used	EF	Training	92,8	93,4	94,6	96,59	94,53	94,65
		Testing	84,4	87,79	82,6	86,3	95,6	95,71
	FP	Training	86,8	88,55	86,6	89,06	84,0	85,86
		Testing	80,53	81,77	80,6	82,48	79,6	80,61
	GML	Training	100	100	99,6	99,61	97,86	97,91
		Testing	74,04	80,54	90	91,22	99,6	99,6
2 bands of Principal Component Transform (PCT) are selected	EF	Training	90,8	90,87	94,2	94,21	92,4	92,5
		Testing	81,53	83,64	81,8	84,99	93,6	94
	FP	Training	92,8	93,81	90,6	91,78	85,07	88,97
		Testing	80,80	84,67	77,0	82,45	74,4	76,55
	GML	Training	81,2	82,72	90,2	91	94,4	94,58
		Testing	75,73	76,93	75,2	79,27	95,6	96,13
2 original bands(band2 and 5) are selected	EF	Training	81,6	82,16	93,8	94,04	92,66	92,88
		Testing	82,93	87,23	82,4	85,39	91,6	92,54
	FP	Training	88,8	91,32	87,4	89,84	85,2	89,31
		Testing	80,93	84,97	79,2	82,44	74,8	73,95
	GML	Training	97,2	96,57	98,2	93,13	95,2	95,1
		Testing	89,73	90,08	86,8	88,67	96	97,24

Table 2 Running time complexity for Saguling case study

Running time	Classifier	25% - 75%	50% - 50%	75% - 25%
All bands are used	EF	83,741	83,77	84,441
	FP	99,531	99,563	99,813
	GML	39,627	39,266	39,627
2 bands of Principal Component Transform (PCT) are selected	EF	31,124	30,974	30,924
	FP	36,015	36,078	36,282
	GML	36,202	35,952	35,992
2 original bands(band 2 and 5) are selected	EF	30,934	31,074	30,885
	FP	35,953	35,938	36,328
	GML	36,142	36,132	36,082

Table 3. Level of generalization for Saguling case study

$\Delta_{\max} = PA - UA $			25% - 75%	50% - 50%	75% - 25%
All bands are used	EF	Training	0,6	1,99	0,12
		Testing	3,39	3,7	0,11
	FP	Training	1,75	2,46	1,86
		Testing	1,24	1,88	1,01
	GML	Training	0	0,01	0,05
		Testing	6,5	1,22	0
2 bands of Principal Component Transform (PCT) are selected	EF	Training	0,07	0,01	0,1
		Testing	2,11	3,19	0,4
	FP	Training	1,01	1,18	3,9
		Testing	3,87	5,45	2,15
	GML	Training	1,52	0,8	0,18
		Testing	1,2	4,07	0,53
2 original bands (band 2 and 5) are selected	EF	Training	0,56	0,24	0,22
		Testing	4,3	2,99	0,94
	FP	Training	2,52	2,44	4,11
		Testing	4,04	3,24	0,85
	GML	Training	0,63	5,07	0,1
		Testing	0,35	1,87	1,24

Concluding Remarks

Based on the case study of Saguling area, the following conclusions can be summarized. In the case study of using small number of band (two bands), all classifier method give a comparable good classification accuracy, complexity, and level of generalization. But when the number of bands increases to six bands, the running time EF and FP increases to twice or three times longer than GML, while their classification accuracies remain about the same to the ones using only two band.

References

- [1] Melgani F., *An Explicit Fuzzy Supervised Classification Method for Multispectral Remote Sensing Images*, IEEE Transactions on Geoscience and Remote Sensing, Vol 38, January, 2000
- [2] Console, E and Mouchot, MC, *Fuzzy Classification Techniques in the Urban Area Recognition*, IEEE, page 1373-1375
- [3] Duda, RO and Hart PE, *Pattern Classification and Scene Analysis*, New York, John Wiley & Sons Inc, 1973
- [4] Gonzales, RC, *Digital Image Processing*, Massachusetts, Addison Wesley, 1992
- [5] Patria, L, Chahyati, D and Murni, A, *Performance Comparison Study of Explicit Fuzzy and Gaussian Maximum Likelihood Methods for Multi-band Landsat TM Image Classification*, 8th International Conference Quality in Research Proceeding, Faculty of Engineering, University of Indonesia, 2005

PROPOSAL PENELITIAN LANJUTAN

Pendahuluan

Penginderaan jarak jauh sangat berguna dalam proses pengambilan keputusan suatu inventori dan evaluasi dari sumber alam. Tujuan utama dari penginderaan jarak jauh adalah untuk menghasilkan citra yang merupakan sekumpulan simbol atau warna yang merepresentasikan klasifikasi dari obyek, seperti hutan, laut, daerah pertanian, kota, jalan dan sebagainya. Aplikasi terbesar dari penginderaan jarak jauh adalah pemetaan (20% - 34%) dan pada kehutanan (25% - 28%). Aplikasi lain dari penginderaan jarak jauh adalah dalam pengembangan daerah seperti tata guna tanah, pertanian dan perikanan, geologi, pertambangan dan energi, perencanaan kota dan lokasi sumber air .

Penginderaan jarak jauh telah digunakan di Indonesia untuk mendukung program pengolahan sumber daya alam sejak Landsat-1 (ERTS -1) diperkenalkan pada tahun 1972. Citra multispektral dan foto udara telah dioperasikan selama lebih dari dua dekade. Selain foto udara, citra lansat TM dan SPOT telah dengan luas dipergunakan di Indonesia.

Pada umumnya teknik klasifikasi yang sering digunakan adalah metode Gaussian Maximum Likelihood (GML) yang mempunyai performansi yang baik . Metode GML merupakan metode utama pada paket pengolahan citra penginderaan jarak jauh (inderaja) seperti ERDAS dan ER Mapper dan sering dipergunakan sebagai pembanding didalam banyak penelitian mengenai pengklasifikasian citra digital. Pengklasifikasian tersebut cocok digunakan untuk citra inderaja sensor optik karena citra tersebut mempunyai kelas obyek yang distribusi tingkat keabuannya mendekati model Gaussian. Namun metode GML tersebut berdasar pada *hard* atau *crisp classification* ; satu piksel menjadi anggota satu kelas. Dengan kata lain, suatu piksel adalah anggota suatu kelas tertentu dan bukan anggota suatu kelas yang lain. Cara berfikir semacam ini tidak merepresentasikan langkah yang baik jika masalah yang dihadapi adalah daerah yang *mixed* (bercampur). Dilain pihak, klasifikasi yang berdasarkan pada pendekatan *fuzzy* menghitung kontribusi keanggotaan suatu piksel terhadap seluruh kelas. Prinsip *fuzzy* ini menyediakan informasi yang lebih banyak dibandingkan dengan metode *hard classification* dan lebih mampu menangani uncertainty, sehingga pendekatan *fuzzy* diharapkan akan menghasilkan

klasifikasi yang lebih baik. Beberapa metode pengklasifikasi citra yang berdasarkan pendekatan *fuzzy* adalah *Explicit Fuzzy* (EF) dan *Fuzzy Parallelepiped* (FP).

Penelitian ini dilakukan berdasarkan penelitian Farid Melgani dan Elena Console. Melgani telah membandingkan hasil klasifikasi EF dan GML untuk citra multispektral, dan Elena telah membandingkan hasil klasifikasi FP dan GML untuk citra multispektral. Menurut teori, umumnya pengklasifikasi *fuzzy* memerlukan waktu komputasi yang lebih lama daripada pengklasifikasi *crisp*, terutama karena penghitungan keanggotaan kelasnya. Namun hasil penelitian Farid Melgani menunjukkan bahwa EF jauh lebih cepat daripada GML. Pada penelitian terdahulu, telah dibandingkan kinerja ketiga metode tersebut dan waktu proses yang digunakan. Pada penelitian ini, akan diteliti bagaimana kinerja ke tiga metode tersebut jika menggunakan pengklasifikasi citra yang lain misalnya dengan menggunakan fungsi keanggotaan segitiga ataupun *piecewise*.

Permasalahan

Berdasarkan penjelasan pada bagian pendahuluan, maka masalah pada penelitian ini adalah mengetahui bagaimana kinerja berbagai pengklasifikasi tersebut pada daerah Saguling. Hipotesis yang mendasari penelitian ini adalah bahwa pengklasifikasi EF dan FP memerlukan waktu yang lebih lama, dengan hasil klasifikasi yang lebih baik dibandingkan dengan GML. Pengujian hipotesis tersebut berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi.

Tujuan Penelitian

Tujuan utama penelitian ini adalah : Membandingkan kinerja pengklasifikasi EF, GML dan FP dan pengklasifikasi yang mempergunakan fungsi keanggotaan segitiga atau *piecewise* pada aplikasi citra multispektral, agar dapat melakukan rekomendasi kapan EF, FP dan GML dan pengklasifikasi yang baru digunakan. Pengamatan kinerja dilakukan berdasarkan *average producer's accuracy* (AP), *average user's accuracy* (AU) dan waktu komputasi untuk masing masing pengklasifikasi.

Daerah penelitian

Berdasarkan data yang tersedia, studi kasus dilakukan pada citra daerah Saguling. Citra yang digunakan adalah dari sistem sensor optik Landsat TM. Pemilihan sampel untuk pelatihan dan pengujian diperoleh dari nara sumber yaitu dari BPPT.

Metodologi

Metodologi penelitian ini adalah sebagai berikut :

1. Melakukan studi literatur pengklasifikasi yang potensial untuk citra multispektral yaitu EF, FP dan GML.
2. Menggunakan sebuah aplikasi perangkat lunak (dalam Matlab) yang dapat dipergunakan sebagai alat eksperimen dalam proses klasifikasi citra.
3. Melakukan ujicoba terhadap citra sensor optik yang digunakan.
4. Melakukan analisis terhadap hasil klasifikasi citra dengan kinerja pembandingan AP, AU serta waktu komputasi.

Kontribusi Penelitian

Kontribusi utama dari penelitian ini adalah :

1. Menerapkan metode klasifikasi multispektral yang potensial dengan pendekatan fuzzy dan statistik.
2. Menyempurnakan hasil penelitian yang telah dilakukan oleh Farid Melgani dan Elena Console.
3. Mengetahui pengklasifikasi yang paling optimal.